



ATELIER THEMATIQUE : N°2 - Transformation écologique et difficultés d’atteindre les ODD

TITRE DE LA COMMUNICATION :

La technologie peut-elle résoudre la crise alimentaire en Afrique ? Analyse de l'impact de l'intelligence artificielle sur l'insécurité alimentaire.

AUTEUR :

Fabrice Ewolo Bitoto^{1,2}

¹École d'Economie et de Gestion de Dschang, Université de Dschang, Cameroun – ewolofab@gmail.com

² Division économique, Nkafu Policy Institute, Cameroun

RÉSUMÉ :

Contexte : Compte tenu du fait que manger, et surtout bien manger, est l'un de nos besoins humains les plus fondamentaux, des millions de personnes en Afrique n'en ont toujours pas assez. Selon la FAO et al. (2022), environ 720 millions de personnes dans le monde étaient sous-alimentées en 2020, contre 821 millions en 2017 et 784 millions en 2015. Cela représente environ 8,9 % de la population mondiale, et 10 millions de personnes supplémentaires risquent de souffrir de la faim d'ici un an et près de 60 millions d'ici cinq ans. La plupart de ces personnes vivent dans des pays en développement, en particulier en Afrique, où l'objectif 2 des objectifs de développement durable (ODD) reste une priorité absolue (FAO et al., 2022). Le secteur agricole est actuellement confronté à de nombreux défis, tant au niveau mondial que local. La demande de denrées alimentaires et d'autres services écosystémiques fournis par l'agriculture augmente, tandis que des facteurs remettent gravement en question le potentiel de production agricole, tels que le changement climatique et la dégradation des sols (Tilman et al., 2011 ; FAO, 2018 ; Gouel et Guimbard, 2019). Par conséquent, la satisfaction des

besoins alimentaires est un défi pour de nombreuses régions et territoires. L'intelligence artificielle (IA) a fait des progrès rapides ces dernières années. Plus précisément, la numérisation de l'agriculture reste l'un des développements les plus importants pour répondre aux demandes économiques, écologiques et sociales croissantes dans le secteur agroalimentaire des pays en développement.

Objectif : L'objectif de ce travail est d'analyser l'impact de l'adoption de l'IA sur l'insécurité alimentaire en Afrique.

Méthodologie : En utilisant plusieurs méthodes récentes d'analyse d'impact, nous avons mené l'analyse empirique sur un panel de 54 pays africains à partir des données issues de la Banque mondiale et du FAO.

Résultats : Plusieurs résultats se dégagent. Premièrement, l'adoption de l'IA réduit en moyenne de manière significative l'insécurité alimentaire en Afrique. L'application de l'IA dans le secteur agroalimentaire permet d'augmenter l'efficacité, la productivité et la résilience des systèmes alimentaires.

Contribution : Ce travail apporte une contribution remarquable à la littérature à plusieurs à plusieurs niveaux. Tout d'abord, à notre connaissance, cet article est l'un des premiers à analyser l'impact de l'IA sur l'insécurité alimentaire en Afrique. De telles études étant particulièrement rare, il ouvre la voie à de futures recherches. Deuxièmement, cette recherche met en évidence le rôle essentiel de l'IA dans la réalisation des ODD de l'ONU, en particulier dans le contexte de l'Afrique, où l'application des technologies de pointe est extrêmement prometteuse.

Recommandations : Nous suggérons que les gouvernements africains et les parties prenantes qui s'engagent à atteindre la faim zéro investissent dans l'infrastructure technologique afin d'encourager l'investissement dans les technologies d'IA pour les rendre accessibles aux petits exploitants agricoles et encourager leur adoption à grande échelle. En outre, il est impératif de développer des programmes de formation et de soutien pour permettre aux agriculteurs et aux acteurs du secteur alimentaire d'utiliser efficacement les outils technologiques liés à l'IA. Enfin, les partenariats entre les acteurs africains, les organisations internationales et les centres de recherche doivent être renforcés afin d'échanger les meilleures pratiques et de promouvoir le partage des technologies et des connaissances.

MOTS CLÉS : intelligence artificielle ; innovation ; insécurité alimentaire ; Afrique ; productivité agricole

TEXTE PRINCIPAL DE LA COMMUNICATION :

Introduction

La sécurité alimentaire est un objectif important pour les décideurs économiques des pays en développement, car elle est étroitement liée à la stabilité sociale dans des régions où les taux de pauvreté peuvent être exceptionnellement élevés. Selon la FAO et al. (2022), environ 720 millions de personnes dans le monde étaient sous-alimentées en 2020, contre 821 millions en 2017 et 784 millions en 2015. Cela représente environ 8,9 % de la population mondiale, et 10 millions de personnes supplémentaires risquent de souffrir de la faim d'ici un an et près de 60 millions d'ici cinq ans. La plupart de ces personnes vivent dans des pays en développement, en particulier en Afrique, où l'objectif 2 des objectifs de développement durable (ODD) reste

une priorité absolue (FAO et al., 2022)¹. Le secteur agricole est actuellement confronté à de nombreux défis, tant au niveau mondial que local. La demande de denrées alimentaires et d'autres services écosystémiques fournis par l'agriculture augmente, tandis que des facteurs remettent gravement en question le potentiel de production agricole, tels que le changement climatique et la dégradation des sols (Tilman et al., 2011 ; FAO, 2018 ; Gouel et Guimbard, 2019). Par conséquent, la satisfaction des besoins alimentaires est un défi pour de nombreuses régions et territoires. En outre, des millions de personnes sont en situation d'insécurité alimentaire, en particulier dans les zones souffrant de pauvreté monétaire et non monétaire. Les deux tiers de ces personnes vivent principalement dans deux régions du monde, l'Afrique subsaharienne et l'Asie du Sud, qui abritent respectivement 237 millions et 277 millions de personnes souffrant de la faim (Sustainable-Development-Goals, 2021). L'agriculture est également confrontée à une série de chocs et de défis économiques, environnementaux et institutionnels, notamment des phénomènes météorologiques extrêmes, des perturbations du marché, des pandémies et des conflits, qui réduisent la résilience du secteur agroalimentaire (Meuwissen et al., 2021 ; Schmitt et al., 2022).

Dans le même temps, la numérisation remodèle rapidement des sociétés entières, y compris le secteur agroalimentaire, conduisant à ce que l'on appelle la "quatrième révolution" dans l'agriculture (Walter et al., 2017). Ces progrès permettent de relever des défis majeurs dans le secteur agricole, tels que l'augmentation de la productivité, la réduction de l'empreinte environnementale, la conservation des ressources naturelles et la contribution à la réalisation des Objectifs de développement durable (Basso et Antle, 2020 ; FAO, 2022 ; Khanna et al., 2022).

Au milieu d'une révolution technologique mondiale, l'utilisation de l'IA dans l'agriculture africaine représente une lueur d'espoir dans la lutte contre l'insécurité alimentaire persistante. Les statistiques révèlent une augmentation perceptible de l'intégration des technologies de l'IA dans le paysage agricole africain. Le secteur agricole exploite de plus en plus les nouvelles technologies numériques, telles que l'agriculture de précision, l'internet des objets, la télédétection, les drones, les applications basées sur les données, l'IA, les jumeaux numériques, la robotique, etc. En outre, les technologies numériques transforment les interactions au sein des chaînes de valeur alimentaires, des systèmes de gouvernance et des plateformes de communication (par exemple, Ehlers et al., 2021 ; Ehlers et al., 2022). Cette transformation a le potentiel d'améliorer et de révolutionner les décisions de production et de gestion, ainsi que d'atténuer les compromis, en facilitant les progrès en matière de productivité, de durabilité, de résilience et de bien-être animal simultanément (Walter et al., 2017 ; Wolfert et al., 2017).

Compte tenu des possibilités d'innovation offertes par l'IA pour la productivité agricole, cet article aborde une question d'actualité dans le contexte de l'insécurité alimentaire qui touche la majeure partie du continent. D'un point de vue théorique, cet article explore les théories économiques qui articulent le lien complexe entre l'innovation et la productivité agricole dans l'adoption de l'IA. La théorie schumpétérienne de l'innovation en est un exemple. Schumpeter (1934) postule que l'innovation, en particulier les avancées technologiques perturbatrices, propulse le développement économique. Dans l'agriculture africaine, l'intégration de l'IA est sur le point de devenir une force de transformation, perturbant les méthodes traditionnelles et ouvrant une nouvelle ère d'efficacité et de productivité. Une autre théorie est celle de la croissance endogène (voir Romer, 1990). Cette théorie postule qu'une croissance économique

¹ Le deuxième objectif des OMD des Nations unies vise à éradiquer la faim et la malnutrition en garantissant l'accès de tous à une alimentation saine, nutritive et adéquate.

soutenue est stimulée par des facteurs internes, tels que le progrès technologique. Le rôle de l'IA dans l'agriculture africaine s'aligne sur cette théorie, en promouvant des progrès continus en matière de productivité, de création de connaissances et de capacités technologiques globales. Le nombre de revues de premier plan publiant des recherches sur l'IA continue d'augmenter (Fu et al., 2021 ; Yang et Wang, 2023 ; Duan et al., 2023 ; Wu, 2023 ; Chen et al., 2024 ; Acemoglu, 2024). Toutefois, le nombre d'applications de l'IA dans l'industrie alimentaire, en particulier l'impact sur l'insécurité alimentaire, est très limité. Toutefois, les études qui s'approchent de cette question établissent généralement un lien entre les technologies de l'information et de la communication (TIC) et l'insécurité alimentaire (voir Kautiainen et al., 2005 ; DiFilippo et al., 2015 ; Domguia et al., 2023) ou Lee et al. (2024), qui constatent que l'IA a une fonction modératrice favorable sur les effets du vieillissement de la population sur la sécurité alimentaire en Chine. Cet article vise à combler cette lacune, en particulier pour l'Afrique, où les défis technologiques et alimentaires restent des équations non résolues.

Ce travail apporte une contribution remarquable à la littérature à plusieurs égards. **Tout d'abord**, à notre connaissance, cet article est l'un des premiers à analyser l'impact de l'IA sur l'insécurité alimentaire en Afrique. Ce travail étant particulièrement rare, il ouvre la voie à de futures recherches. **Deuxièmement**, cette recherche met en évidence le rôle essentiel de l'IA dans la réalisation des ODD de l'ONU, en particulier dans le contexte de l'Afrique, où l'application des technologies de pointe est extrêmement prometteuse. En effet, l'intégration de l'IA dans l'agriculture africaine est essentielle pour atteindre l'objectif 2 (Faim zéro). **Troisièmement**, en s'appuyant sur des résultats empiriques et des théories économiques, cette recherche fournit des recommandations politiques pratiques visant à favoriser le développement agricole durable en Afrique. Ces recommandations sont conçues pour exploiter les avantages de l'IA tout en abordant les défis potentiels. **Quatrièmement**, nous utilisons des outils économétriques sophistiqués et récemment développés tels que l'appariement par score de propension (PSM), la différence de différence hétérogène (HDID), l'effet de traitement par quantile (QTE) et l'effet de traitement hétérogène (HTE). Ces techniques présentent un certain nombre d'avantages car, contrairement aux méthodes habituelles d'analyse d'impact, elles permettent d'isoler l'impact réel de la variable d'intérêt sur la variable de résultat.

Le reste du document est structuré comme suit : La section 2 présente le contexte théorique de la relation entre l'IA et l'insécurité alimentaire. La section 3 présente les données et expose la stratégie méthodologique, tandis que la section 4 présente les résultats et la discussion. La section 5 conclut par des recommandations politiques.

2. Contexte théorique

La définition de la sécurité alimentaire de la FAO souligne l'importance de l'accès physique et économique à des aliments nutritifs pour parvenir à un mode de vie sain (FAO, 2008). L'insécurité alimentaire est un problème majeur de santé publique qui affecte la santé physique et mentale, en particulier chez les enfants (Clay, 2002). L'accès à la nourriture, décomposé en accessibilité physique, économique et sociale, est fondamental pour garantir la sécurité alimentaire (Riely et al., 1999 ; Shaw, 2007). En outre, la composante "utilisation des aliments", qui couvre la préparation et la conservation des aliments, est essentielle pour garantir des régimes alimentaires sains (Napoli et al., 2011).

La croissance rapide de la population, la diminution des ressources naturelles, le changement climatique et les défis agricoles ont créé un besoin accru d'une approche plus efficace des

systèmes agricoles et des moyens de subsistance (Sachs, 2015). La présente étude examine le potentiel de l'intelligence artificielle (IA) en matière de sécurité alimentaire mondiale, en mettant en évidence ses applications et ses implications dans le domaine de l'agriculture. Golay (2011) détaille les domaines d'application potentiels de l'IA pour la sécurité alimentaire, bien que son adoption soit actuellement lente. L'IA offre des opportunités dans divers aspects de la sécurité alimentaire, notamment la disponibilité, l'accessibilité, l'utilisation efficace de la nourriture et sa stabilité dans le temps. Toutefois, malgré son potentiel prometteur, son intégration complète dans les systèmes alimentaires est encore en cours (Lakshmi & Corbett, 2020). À mesure que la technologie progresse et que les pénuries de main-d'œuvre résultant du vieillissement de la population et des niveaux élevés d'automatisation deviennent nécessaires, les robots agricoles seront de plus en plus utilisés dans l'agriculture et l'industrie alimentaire (Issa et al., 2022). Les connaissances en matière d'agriculture augmentent parallèlement aux progrès rapides de l'économie numérique et à l'utilisation croissante des technologies de l'information dans le secteur agricole (Asongu et al., 2018). Les tâches clés qui contribuent à l'agriculture durable comprennent l'utilisation de technologies d'intelligence artificielle pour la culture des plantes, la prévision des maladies, la gestion des animaux, le contrôle des terres et de l'irrigation, et la prévision du climat (Filho et al., 2022 ; Shen et al., 2022 ; Shaikh et al., 2022). Les technologies d'intelligence artificielle pour l'agriculture sont utilisées à tous les stades de la production agricole.

L'augmentation de la demande alimentaire due à la croissance démographique exerce une pression supplémentaire sur les systèmes de production alimentaire existants, ce qui rend impérative l'adoption de technologies innovantes telles que l'IA (Chen et al., 2016). Toutefois, malgré son potentiel, l'adoption généralisée de l'IA dans l'agriculture est encore émergente et diverge selon les régions (Liao et al., 2018). L'IA, qui représente la reproduction des processus mentaux humains par des machines, englobe des aspects tels que l'apprentissage, l'inférence et la perception (Russell et Norvig, 2016). Malgré son potentiel, l'intégration de l'IA dans l'agriculture progresse plus lentement que dans d'autres secteurs (Nuthall et Old, 2018). La méthodologie de Liu et Hue (2017) utilisant des algorithmes d'apprentissage automatique illustre les efforts en cours pour améliorer le transport des denrées périssables, soulignant le potentiel des technologies avancées dans l'optimisation des chaînes d'approvisionnement alimentaire. En résumé, il ressort de ces développements que les applications potentielles de l'IA dans le contexte de la sécurité alimentaire mondiale dans de multiples domaines peuvent contribuer à améliorer la disponibilité, l'accessibilité, l'efficacité et la stabilité des aliments, tout en mettant en évidence les défis persistants et les progrès en cours dans ce domaine.

3. Données et méthodologie

Cette section se compose de deux thèmes principaux. Le premier concerne la présentation des données et la définition des variables et des sources de données (3.1), tandis que le second décrit la méthodologie et, en particulier, les méthodes d'analyse (3.2).

3.1. Données

Les données de cette étude couvrent 54 pays africains. Plus précisément, les données utilisées pour évaluer l'insécurité alimentaire et les variables de contrôle sont tirées de la base de données de la Banque mondiale (WDI, 2023). Le tableau 1 présente les statistiques des variables de l'étude, avec la matrice de corrélation en bas de page sur la période 1990-2022. La liste des pays de l'échantillon et la description des données sont données respectivement dans le tableau A1 et le tableau A2. Il convient toutefois de noter que la période d'étude et le nombre de pays sont conditionnés par la disponibilité des données des différentes sources.

3.1.1. Variable dépendante

Conformément à ce que nous avons appris de la littérature, nous avons opté pour la prévalence de la sous-alimentation (% de la population totale) comme mesure principale. Elle est tirée du WDI (2023). Dans la littérature, il n'y a pas de consensus sur la mesure principale de l'insécurité alimentaire. Outre les mesures proposées comme indices, les Nations unies, par l'intermédiaire de la FAO, ont proposé la prévalence de la sous-alimentation comme indicateur de l'insécurité alimentaire. Il est basé sur la moyenne des calories consommées mais prend également en compte les inégalités dans la consommation alimentaire en utilisant un coefficient de variation basé sur la stratification des revenus (indicateur 2.1.1 des OMD). Malgré les critiques largement discutées par Soriano et Garrido (2016), la méthodologie que nous utilisons pour saisir la prévalence de la sous-alimentation a été largement utilisée dans la littérature empirique (voir Soriano et Garrido, 2016 ; Candelise et al., 2021 ; Pondie et al., 2023).

3.1.2. Variables indépendantes

La variable relative à l'intelligence artificielle est une variable binaire dans laquelle "1" représente l'adoption de l'IA et "0" la non-adoption. Nous l'avons construite manuellement en fonction des différentes années d'adoption de la haute technologie, sur la base des clarifications également décrites par Martynenko (2017) et Chen et al. (2024). L'IA est largement utilisée dans les robots industriels, la reconnaissance vocale, les moteurs de recherche, les logiciels informatiques et d'autres domaines (Chen et al., 2024). L'IA étant encore une technologie jeune, il est difficile de déterminer son niveau réel d'avancement et sa portée en raison de son implication active dans une variété de secteurs et d'applications (Zhao et al., 2024). Certaines études quantifient l'IA en termes d'innovation technologique. Wang et al. (2023), par exemple, ont suivi la quantité de brevets liés à l'IA. Les chercheurs ont également utilisé les applications robotiques comme indicateurs de l'intelligence artificielle. Li et al. (2023), par exemple, ont suivi la quantité de brevets liés à l'IA.

par exemple, a étudié l'effet de l'IA sur l'efficacité des ressources en utilisant les données d'application des robots. En outre, le développement des robots industriels est le principal sujet d'intérêt de Wu (2023), Yang et Wang (2023), Fu et al. (2021), Duan et al. (2023) et Wu (2023). Les applications robotiques sont des indicateurs plus précis de la croissance de l'IA que les avancées technologiques telles que les brevets. En effet, de nombreux brevets technologiques restent souvent au stade théorique sans avoir d'applications dans le monde réel (Zhao et al., 2024). En revanche, les robots constituent une représentation plus précise du stade actuel de développement de l'IA, car ils font déjà partie de la production industrielle. Les robots représentent des technologies d'IA, et leur installation signifie que l'industrie de l'automatisation accepte l'IA et la fait mûrir. Ainsi, la mesure de l'IA choisie dans ce travail - les exportations de haute technologie, qui représentent pour un pays les produits à forte intensité de R&D tels que l'aérospatiale, les ordinateurs, les produits pharmaceutiques, les instruments scientifiques et les machines électriques - est proche de la conception de Zhao et al. (2024).

Tableau 1 : Statistiques descriptives

Variables	IA	Alimentation	PMT	InPIB	DEVFIN	RE
Obs	1782	1040	1749	1668	1612	1673
Moyenne	0.29	20.135	44.767	23.003	0.133	62.275
Std. Dev.	0.454	13.528	16.495	1.585	0.101	29.96
Min	0	2.5	13.24	18.867	0	0.06

Max	1	70.9	81.536	27.006	0.643	98.34
<i>Corrélations par paires</i>						
(1) Alimentation	1					
(2) IA	-0.161*	1				
(3) PMT	0.197*	-0.147*	1			
(4) InPIB	-0.269*	0.203*	-0.098*	1		
(5) DEVFIN	-0.342*	0.233*	-0.231*	0.336*	1	
(6) RE	0.595*	-0.101*	0.447*	-0.222*	-0.595*	1

IA : intelligence artificielle ; **PMT** : participation au marché du travail ; **DEVFIN** : développement financier ; **RE** : énergies renouvelables

Source : Auteurs

3.2 Méthodologie

3.2.1. L'appariement par score de propension (PSM)

En référence aux travaux influents de Kinda et Mien (2024), nous utilisons la méthode PSM. Le cadre d'analyse d'évaluation standard pour formaliser ce problème est l'approche des résultats potentiels ou le modèle Roy-Rubin (Roy, 1951 ; Rubin, 1974). Les principaux piliers de ce modèle sont les individus, le traitement et les résultats potentiels. Dans notre étude, le traitement est binaire, l'indicateur de *traitement* étant égal à un si le pays *i* reçoit la taxe environnementale et à zéro dans le cas contraire. Nous définissons ensuite les résultats potentiels comme Y_i (traitement) pour chaque pays *i*, où $i = 1 \dots N$ et N représente le nombre total de pays dans notre panel et Y_i représente l'inégalité. L'effet de traitement (T_i) pour le pays *i* peut être écrit comme suit :

$$T_i = Y_i(1) - Y_i(0) \quad (1)$$

La méthode d'appariement par score de propension repose sur la création d'un score de probabilité pour chaque observation, généralement calculé à l'aide d'un algorithme de régression logistique (Wager et Athey, 2018). Ce score mesure la probabilité qu'un individu reçoive le traitement, compte tenu d'un ensemble de caractéristiques ou de covariables. Ces covariables peuvent influencer la probabilité d'être traité. La formule suivante est utilisée pour calculer cette probabilité :

$$P(X = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (2)$$

où :

- P est le score de propension, qui représente la probabilité qu'un individu reçoive le traitement ($X=1$).
- X est un vecteur contenant les variables explicatives (X_1, X_2, \dots, X_k) qui sont utilisées pour prédire le score de propension.
- β sont les coefficients de régression estimant l'impact de chaque variable explicative sur la probabilité de recevoir le traitement.

L'objectif de la méthode PSM est de créer des groupes de traitement et de contrôle comparables en termes de caractéristiques observées et non observées des sujets. Pour ce faire, la méthode calcule d'abord un score de probabilité (score de propension) pour chaque sujet, qui représente la probabilité qu'il reçoive le traitement en fonction de ses

caractéristiques observées. Ensuite, la méthode apparie les sujets à l'aide de ces scores de propension, en veillant à ce que chaque sujet du groupe de traitement soit associé à un sujet du groupe de contrôle dont les scores de propension sont similaires. Après avoir calculé ces scores de propension, les chercheurs font correspondre les individus du groupe d'intervention avec ceux du groupe de contrôle qui ont des scores de propension similaires (Peters et al., 2017). Le nombre d'individus appariés peut varier en fonction de la méthode. Plusieurs méthodes, dont l'appariement exact, l'appariement avec le plus proche voisin, l'appariement pondéré ou l'appariement optimal des sous-classes, peuvent être utilisées pour réaliser l'appariement.

Une fois les groupes appariés, les résultats peuvent être comparés entre les deux groupes pour évaluer l'impact du traitement. Cette méthode est donc une alternative intéressante à l'utilisation de groupes aléatoires dans les études expérimentales et permet de tirer des conclusions plus solides dans les études d'observation. Il convient toutefois de rappeler que la méthode de l'appariement par score de propension ne peut pas éliminer tous les biais potentiels. Elle doit être utilisée en conjonction avec d'autres techniques pour minimiser le risque de biais. Étant donné que la méthode PSM estime l'ATT sur deux groupes et ne prend pas en compte l'aspect temporel et l'hétérogénéité, nous utilisons une méthode récemment développée par Echeverri (2023), à savoir la différence hétérogène dans la différence, qui prend en compte ces contraintes.

3.2.2. Différence hétérogène dans la différence (HDID)

La BIDD estime les cohortes de traitement (groupes traités à différents moments) et les paramètres ATET variables dans le temps (Echeverri, 2023). La signification de chacun de ces ATET est identique à celle des paramètres d'une différence dans les différences (DID) à deux moments et dans deux groupes. On parle d'effets de traitement hétérogènes ou de DID hétérogènes car il y a plusieurs paramètres DID. En comparaison, l'estimation d'un seul ATET implique qu'il n'y a pas de fluctuation dans le temps ou dans la cohorte.

3.2.3. Effet de traitement par quantile (QTE)

La méthode des effets de traitement par quantile est une approche utilisée dans la recherche scientifique pour évaluer l'impact des traitements ou des interventions sur différents quantiles de la distribution des résultats plutôt que sur la moyenne, comme c'est le cas avec les méthodes traditionnelles. Cette approche permet de mieux comprendre comment un traitement affecte les différentes parties d'une distribution plutôt que de considérer simplement son effet moyen (Domguia, 2023). L'utilisation de la méthode des effets de traitement par quantile implique généralement une présentation détaillée de la méthodologie utilisée pour estimer les effets sur les différents quantiles, ainsi que l'évaluation de la robustesse des résultats. Selon Domguia (2023), les avantages de cette méthode par rapport aux approches traditionnelles incluent sa capacité à capturer des effets hétérogènes que les méthodes basées sur la moyenne pourraient négliger. En résumé, la méthode des effets de traitement par quantile permet une analyse approfondie des effets de traitement dans différentes parties de la distribution des résultats, offrant une perspective plus nuancée et plus détaillée de l'impact des interventions étudiées.

3.2.4. Effet de traitement hétérogène (HTE)

Nous utiliserons des méthodes d'apprentissage automatique pour explorer cette hétérogénéité des effets de traitement. Les effets de traitement moyens conditionnels nous indiquent s'il existe des groupes identifiables de personnes (par X) pour lesquels les effets de traitement varient. Étant donné que les effets de traitement moyens conditionnels impliquent

des attentes conditionnelles, les méthodes d'apprentissage automatique sont utiles.

En calculant les effets hétérogènes du traitement et en identifiant les sous-groupes les plus touchés par une politique, la causalité peut contribuer à une répartition équitable des politiques. Toutefois, le calcul de l'hétérogénéité des effets de traitement, également connu sous le nom d'effet de traitement moyen conditionnel (CATE), peut présenter des difficultés. L'économétrie offre plusieurs méthodes d'estimation de l'ATE.

Si l'effet du traitement est hétérogène, il est possible de le conditionner à une covariable pour calculer le CATE. Cette méthode est utile pour identifier les individus pour lesquels le traitement est positif et ceux qui bénéficieront le plus d'un traitement, essentiellement une estimation de l'allocation optimale des politiques (Athey et Imbens, 2019). Cependant, nous sommes confrontés au "problème fondamental de l'inférence causale" (Holland, 1986), selon lequel le CATE ne peut pas être observé directement pour une unité, ce qui rend impossible l'observation des effets causaux au niveau de l'unité. Nous ne pouvons jamais observer directement la condition contrefactuelle d'une unité d'observation.

Une forêt causale est simplement la moyenne de nombreux arbres causaux, où les arbres diffèrent en raison du sous-échantillonnage (Athey et Imbens, 2019). Pour créer une forêt causale à partir d'arbres causaux, il est nécessaire d'estimer une fonction de pondération et d'utiliser les poids résultants pour résoudre un modèle local afin d'estimer le CATE. Pour gérer le surajustement, les forêts causales utilisent une condition d'honnêteté, dans laquelle un arbre est honnête si, pour chaque échantillon d'apprentissage (i), il utilise uniquement la réponse (Y_i) pour estimer l'effet de traitement dans la feuille ou pour décider où placer l'arbre divisé, mais pas les deux (Jacob, 2021). La division de l'échantillon est utilisée pour créer des arbres honnêtes, où la moitié des données est utilisée pour estimer la structure de l'arbre, un sous-échantillon divisé, et l'autre moitié est utilisée pour estimer l'effet du traitement dans chaque feuille, un sous-échantillon d'estimation.

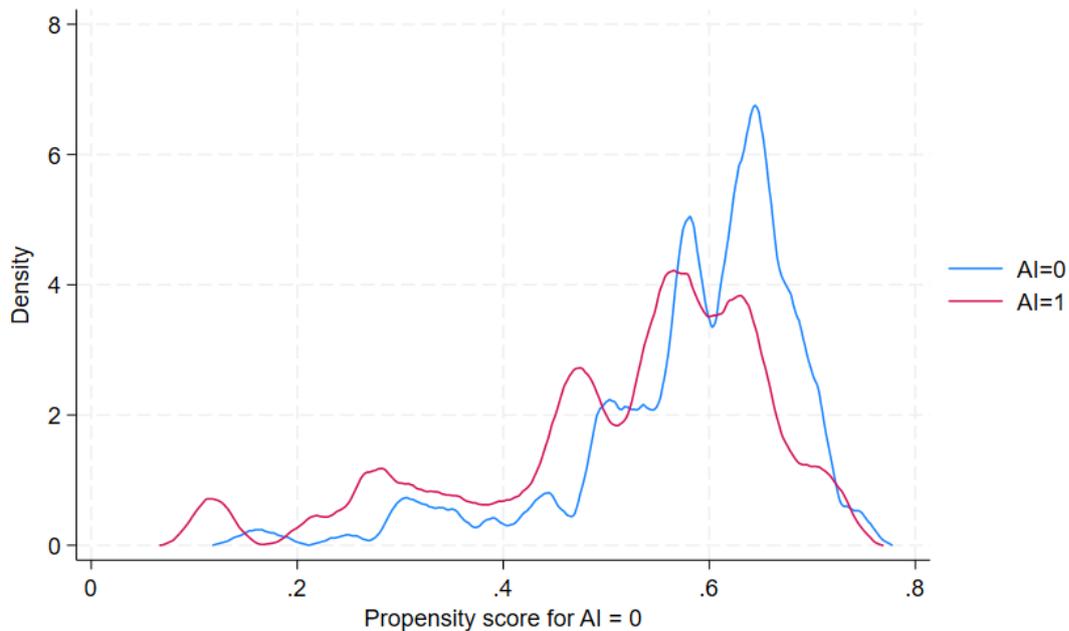
4. Les résultats

4.1. Résultats du MAF

4.1.1. Correspondance

La figure 1 illustre les scores de propension pour les groupes de traitement et de contrôle utilisés pour évaluer l'impact de la politique d'IA. La proximité des deux lignes sur l'axe des abscisses (score de propension) indique que l'appariement des scores de propension est réussi, ce qui signifie que les groupes de traitement et de contrôle présentent des caractéristiques similaires. Cela renforce la crédibilité de toute analyse future comparant les résultats entre les groupes afin d'évaluer l'effet réel de la politique d'IA. Toutefois, pour déterminer définitivement l'impact, il est essentiel d'examiner d'autres résultats. Il peut s'agir de chiffres présentant l'effet réel du traitement (différences de résultats entre les groupes) et d'informations sur les tâches ou décisions spécifiques que l'IA stratégique est censée soutenir. La compréhension de ces aspects permettra une interprétation plus complète de l'influence de l'IA sur la variable de résultat étudiée.

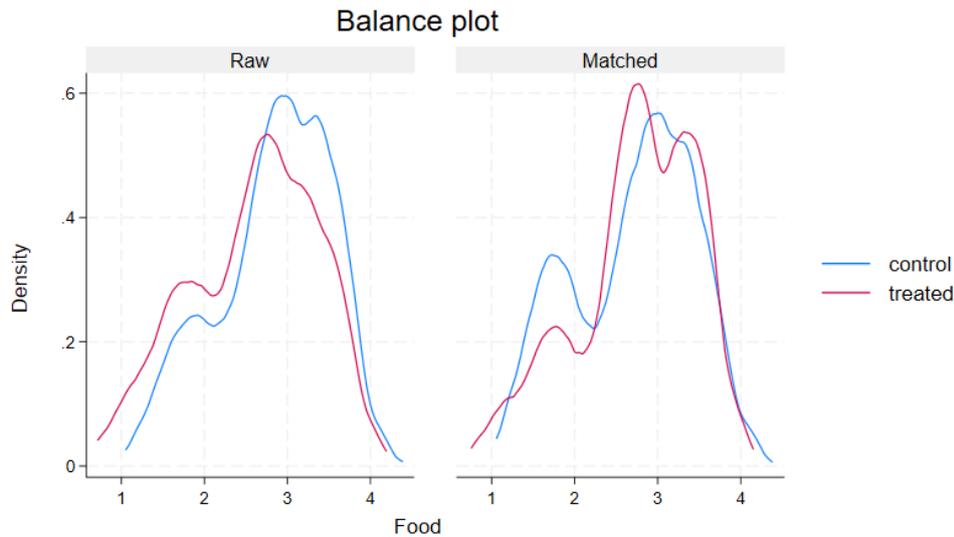
Figure 1 : Scores de propension



Source : auteurs

La distribution de l'insécurité alimentaire pour les ensembles de données brutes et appariées, avec des lignes distinctes pour le groupe témoin et le groupe traité, est présentée dans la figure 3. Il est à noter que les tendances (formes) des lignes dans chaque graphique (données brutes et appariées) sont très similaires. Cela suggère que les groupes témoins et traités suivent la même distribution sous-jacente dans les deux ensembles de données. Bien qu'il puisse y avoir de légères variations dans la position ou la répartition des lignes dans chaque graphique, il est difficile d'en déterminer l'importance à partir de cette image. Cette similitude des tendances dans les données brutes et appariées est un signe positif. Cette constatation implique que le processus d'appariement n'a probablement pas modifié de manière significative la distribution de la variable, ce qui renforce l'analyse des effets du traitement entre les groupes de contrôle et les groupes traités.

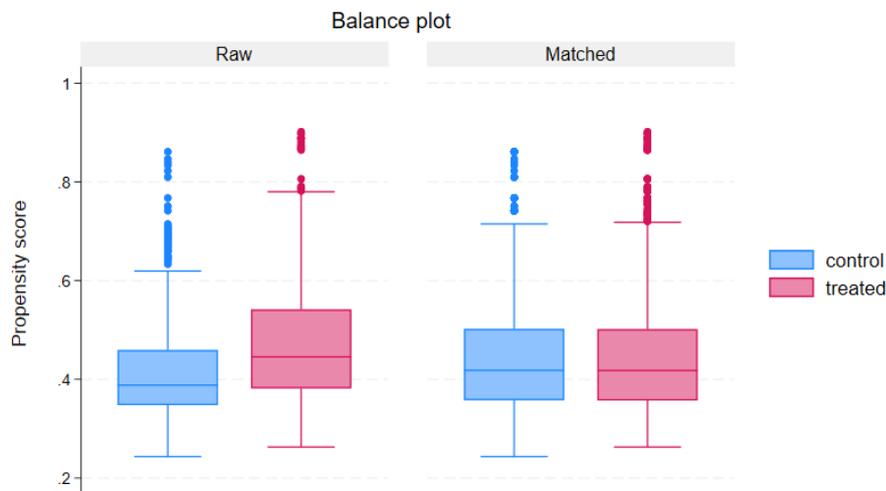
Figure 2 : Diagramme équilibré pour les données brutes et les données appariées



Source : auteurs

La figure 2 présente un diagramme d'équilibre et illustre l'efficacité de l'appariement des scores de propension dans l'évaluation de l'impact de la politique d'IA. Les deux diagrammes en boîte représentent la distribution du score de propension : "brut" (avant l'appariement) et "apparié" (après l'appariement). Idéalement, ces distributions devraient se chevaucher de manière significative, comme on le voit ici. L'appariement des scores de propension vise à créer des groupes comparables présentant des caractéristiques similaires (à l'exception de l'exposition à la politique d'IA) pour une comparaison équitable des résultats. La distribution "appariée" présentait une variabilité réduite par rapport à la distribution "brute", ce qui suggère que les différences de base entre le groupe traité (probablement exposé à la politique d'IA) et le groupe témoin ont été équilibrées avec succès. Cela renforce l'analyse en minimisant l'influence des variables confusionnelles sur les effets observés.

Figure 3 : L'équilibre de l'appariement par score de propension



Source : auteurs

4.1.2. Estimation du traitement moyen

Le tableau 2 explore les facteurs influençant l'adoption de l'intelligence artificielle (IA) pour la sécurité alimentaire à l'aide d'un modèle de régression Probit. Le tableau présente des variables indépendantes, telles que la participation à la population active, le PIB, le développement financier et les ressources renouvelables, susceptibles d'influencer l'adoption de l'IA. La colonne des coefficients montre que la participation à la main-d'œuvre réduit la probabilité d'utilisation de l'IA. Toutefois, les coefficients positifs significatifs pour le PIB et le développement financier indiquent que les pays dont le PIB et le développement financier sont élevés sont probablement enclins à adopter l'IA. La partie inférieure du tableau 2 ne montre rien d'autre que la différence dans l'évolution de l'insécurité alimentaire pour les groupes de traitement et de contrôle. Une analyse comparative des différences montre que l'utilisation de l'IA aurait un impact bénéfique sur la sécurité alimentaire en Afrique. L'adoption de l'IA dans l'agriculture réduit en moyenne l'insécurité alimentaire. Ce résultat s'explique de plusieurs manières. Tout d'abord, l'adoption de l'IA permet d'améliorer l'efficacité des pratiques agricoles en fournissant des analyses de sol plus précises, des prévisions météorologiques et des recommandations de cultures personnalisées. Cette optimisation de la productivité agricole permet d'augmenter les rendements, de limiter les pertes agricoles et de renforcer la sécurité alimentaire régionale. Finger (2023) a relevé plusieurs dimensions innovantes, telles que les technologies de géoréférencement et de localisation, qui permettent l'utilisation de systèmes de guidage et l'agriculture en circulation contrôlée, c'est-à-dire l'application très localisée d'opérations (par exemple, l'application d'intrants et la récolte). Cela permet de réduire les coûts privés et les externalités environnementales en évitant les applications redondantes d'intrants et en économisant du carburant (Gasso et al., 2013). Deuxièmement, l'IA permet d'optimiser l'utilisation de ressources telles que l'eau et les engrais en adaptant les pratiques agricoles aux conditions locales spécifiques. Cela contribue à une utilisation plus durable des terres agricoles et à la préservation des écosystèmes, ce qui permet de renforcer la sécurité alimentaire à long terme. La littérature (FAO, 2022 ; van Hilten et Wolfert, 2022) indique que dans la production animale, les technologies autonomes sont de plus en plus pertinentes, par exemple dans la production laitière et en particulier pour les systèmes de production en intérieur tels que les porcs et les volailles, de sorte que le travail manuel et la prise de décision humaine sont partiellement ou même totalement remplacés, transformant les fermes en "systèmes de gestion cyber-physiques". En outre, l'utilisation de technologies basées sur l'IA permet aux agriculteurs d'accéder plus facilement aux plateformes de marché en ligne afin d'extraire des informations commerciales cruciales et d'élargir leurs débouchés.

Tableau 2 : Estimation de l'effet moyen du traitement.

Régression Probit	Coefficient AI	Erreur std.	z	P>z	[Intervalle de confiance à 95 %]	
PMT	-0.0053861	0.0031778	-1.69	0.09	-.0116145	.0008423
lnPIB	0.0601307	0.0294703	2.04	0.041	.0023701	.1178914
DEVFIN	2.53775	0.5528633	4.59	0.000	1.454158	3.621343
RE	0.0018555	0.0020812	0.89	0.373	-.0022236	.0059346
_cons	-1.779752	0.6800486	-2.62	0.009		-3.559503

Variable	Échantillon	Traité	Contrôles	Différence	S.E.	T-stat
Alimentation	Inégalé	2.58604794	2.838106	-0.25205806	0.047120525	5.35
	ATT	2.61873472	2.72980895	-0.11107423	0.074198217	1.5
		<i>psmatch2</i> : Support commun		Total		
<i>psmatch2</i> : Affectation du traitement		Hors soutien	Sur le soutien			
	Non traité	0	506	506		
	Traité	14	396	410		
	Total	14	902	916		

Note : S.E. ne tient pas compte du fait que le score de propension est estimé.

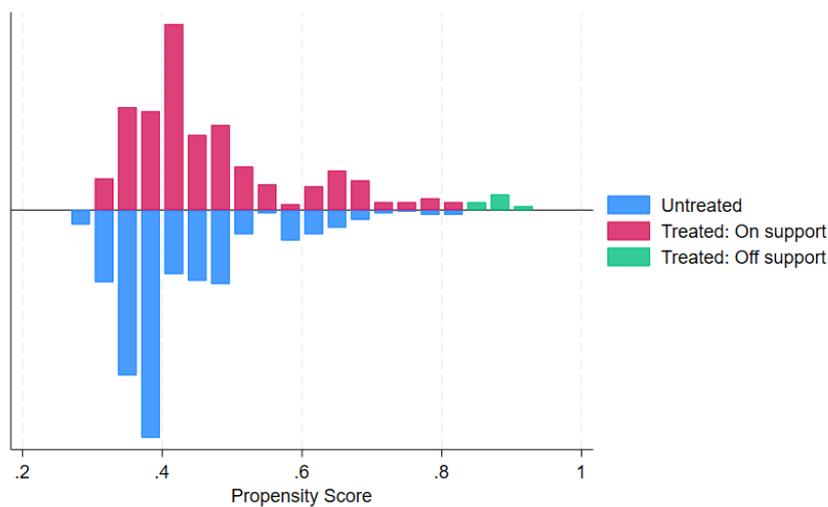
Notes : ***, ** et * sont significatifs aux niveaux de 1 %, 5 % et 10 %, respectivement.

Source : auteurs

4.1.3. Vérification du solde avant et après l'appariement

La figure 4 illustre le chevauchement entre les scores de propension des groupes de traitement et de contrôle dans le cadre d'une analyse d'appariement des scores de propension. L'axe X représente le score de propension (probabilité de recevoir le traitement) et l'axe Y représente la densité des observations pour chaque score (le nombre de personnes ayant ce score). Les deux lignes représentent la distribution des scores pour les deux groupes. Un facteur clé pour des données bien appariées est un chevauchement suffisant, ce que ce graphique indique en montrant une zone de densité considérable où les deux groupes ont des scores de propension similaires. Cela suggère que le groupe de contrôle comprend des individus comparables au groupe de traitement en ce qui concerne les facteurs influençant l'attribution du traitement. Ce chevauchement permet une comparaison plus équilibrée entre les groupes et contribue à réduire les biais dus à des différences préexistantes. Bien que le chevauchement semble suffisant, il est difficile de déterminer avec certitude son adéquation pour une analyse fiable à partir de cette seule image. En outre, la densité elle-même ne fournit pas d'informations sur l'équilibre entre toutes les variables observées, et une analyse plus approfondie pourrait être nécessaire pour une évaluation plus complète de l'équilibre entre les covariables. Dans l'ensemble, ce diagramme de support commun suggère un bon appariement des données basé sur un chevauchement suffisant des scores de propension, mais une évaluation plus détaillée de l'équilibre des covariables pourrait s'avérer nécessaire pour un jugement concluant.

Figure 4 : Diagrammes de support commun (traités et non traités)



Source : auteurs

Le tableau 3 résume les résultats de l'appariement des scores de propension, en soulignant qu'il a permis d'équilibrer les covariables entre les groupes traités et les groupes témoins. Avant l'appariement, les données brutes présentaient un échantillon déséquilibré avec 410 observations pour le groupe traité et 506 pour le groupe témoin. L'appariement des scores de propension a permis d'obtenir un échantillon équilibré de 916 observations dans chaque groupe (obtenu en dupliquant potentiellement les observations des données originales). En outre, le tableau démontre une amélioration significative de l'équilibre des covariables. Il montre que les différences standardisées (mesures de la disparité des moyennes des groupes) deviennent beaucoup plus faibles après l'appariement, et que les rapports de variance (mesures de la disparité de la variance des groupes) se rapprochent de l'unité. Cela suggère que les cinq covariables mesurées sont plus comparables entre les groupes traités et les groupes de contrôle. Dans l'ensemble, ce tableau renforce la validité de l'utilisation de l'appariement des scores de propension pour estimer l'effet causal du traitement, étant donné que l'équilibre des covariables réduit le biais dû aux différences préexistantes entre les groupes. Il est important de se rappeler que les seuils acceptables de différence standardisée peuvent varier en fonction du domaine et du nombre de covariables, et que l'analyse repose sur l'inclusion de toutes les covariables pertinentes pour éviter les biais.

Tableau 3 : Vérification de l'équilibre avant et après l'appariement

Variable	Inégalé		Moyenne		%réduit		test t		V(T)/V(C)
	Apparié	U	Traité	Contrôle	%bias	biais	t	p>t	
Score d'impédance	U		0.47901	0.42151	48.4		7.4	0.000	1.87*
	M		0.46488	0.46505	-0.1	99.7	-0.02	0.983	0.99

* si le rapport de variance se situe en dehors de [0,82 ; 1,21] pour U et de [0,82 ; 1,22] pour M

Équilibrer les indices

Échantillon	Biais			Biais				
	Ps R2	LR chi2	p>chi2	moyen	MedBias	B	R	%Var
Inégalé	0.042	53.39	0	48.4	48.4	48.4*	1.87	100
Apparié	0.000	0.000	0.983	0.1	0.1	0.1	0.99	0

* si B>25%, R en dehors de [0.5 ; 2]

Source : auteurs

4.1.4. Analyse de la sensibilité de nos résultats

Pour vérifier la sensibilité de nos résultats, nous effectuons le test des limites de Rosenbaum (2002). La logique de ce test de sensibilité est la suivante : nous supposons que nous avons obtenu de bons résultats d'appariement (ce qui est le cas). Si c'est le cas, nous avons réussi à rétablir une randomisation presque parfaite ex post (Rosenbaum, 2002) et définissons Gamma comme le rapport des PS des groupes traités et non traités qui est égal à une sou randomisation. Nous pouvons donc commencer par supposer que notre appariement a un Gamma égal à un. Ensuite, nous supposons l'existence d'un facteur de confusion inobservable qui génère une augmentation du ratio Gamma. Plus cette augmentation est importante, plus la déviation par rapport à la randomisation est grande. Par conséquent, le test simule des valeurs plus élevées de Gamma et explore dans quelle mesure la valeur p de ATT reste significative. Les résultats du tableau 4 montrent que la valeur p (voir la colonne "sig+") reste faible même lorsque Gamma augmente de manière significative, ce qui signifie que nos résultats d'appariement sont robustes. Nous concluons donc que nos résultats d'appariement sont robustes aux facteurs de confusion non observables.

Malgré la robustesse de nos résultats, nous pensons qu'il vaut la peine de les tester plus avant avec l'approche des différences hétérogènes (HDID), qui est robuste à la sélection non observable et ne tient pas compte de la disparité qui existe entre les pays.

Tableau 4 : Vérification de la sensibilité des résultats à la sélection d'éléments non observables

Limites de Rosenbaum pour le delta (N = 396 paires appariées)

<i>Gamma</i>	<i>sig+</i>	<i>sig-</i>	<i>t-hat+ (en anglais)</i>	<i>t-hat-</i>	<i>CI+</i>	<i>CI-</i>
1	0.017898	0.017898	-0.10756	-0.10756	-0.2109	-0.00656
1.05	0.005858	0.046562	-0.12925	-0.08526	-0.23109	0.014158
1.1	0.001729	0.100356	-0.15072	-0.06504	-0.25195	0.035856
1.15	0.000466	0.184506	-0.17012	-0.04622	-0.27318	0.055028
1.2	0.000116	0.296751	-0.18984	-0.02674	-0.29362	0.072988
1.25	0.000027	0.42688	-0.20848	-0.00857	-0.31213	0.09251
1.3	5.80E-06	0.560146	-0.22442	0.007452	-0.3276	0.108588
1.35	1.20E-06	0.682387	-0.24121	0.025042	-0.34638	0.126731
1.4	2.30E-07	0.78402	-0.25758	0.040491	-0.36343	0.145363
1.45	4.20E-08	0.861395	-0.27378	0.055443	-0.38024	0.161091
1.5	7.50E-09	0.915821	-0.28926	0.069506	-0.3957	0.175223
1.55	1.30E-09	0.951465	-0.30481	0.08499	-0.41134	0.189973
1.6	2.10E-10	0.973347	-0.31761	0.098124	-0.42494	0.204101
1.65	3.30E-11	0.986014	-0.32953	0.110684	-0.43878	0.220642
1.7	5.10E-12	0.992966	-0.34412	0.124923	-0.45241	0.234368
1.75	7.70E-13	0.996599	-0.35746	0.138535	-0.46645	0.247042
1.8	1.10E-13	0.998415	-0.37096	0.152566	-0.47828	0.259634
1.85	1.60E-14	0.999286	-0.38302	0.163456	-0.4895	0.272863
1.9	2.30E-15	0.999689	-0.39458	0.174403	-0.50233	0.28626
1.95	3.30E-16	0.999868	-0.4068	0.185379	-0.51444	0.297983
2	0	0.999946	-0.4177	0.196038	-0.52638	0.308004

* γ - probabilité logarithmique d'une affectation différentielle due à des facteurs non observés

sig+	-	limite supérieure niveau de signification
sig-	-	limite inférieure niveau de signification
t-hat+ (en anglais)	-	borne supérieure Estimation ponctuelle de Hodges-Lehmann
t-hat-	-	borne inférieure Estimation ponctuelle de Hodges-Lehmann
CI+	-	limite supérieure de l'intervalle de confiance ($\alpha = 0,95$)
CI-	-	intervalle de confiance de la limite inférieure ($\alpha = .95$)

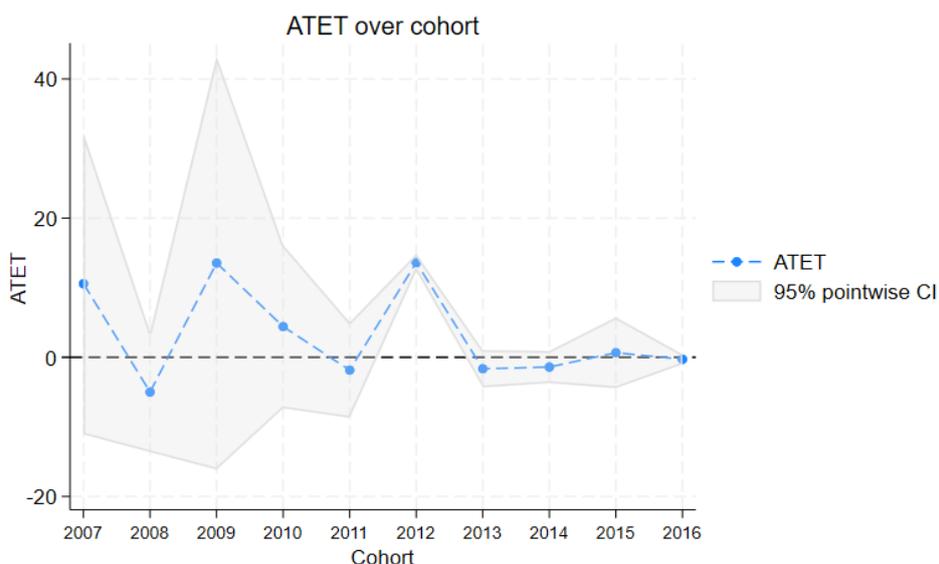
Source : auteurs

4.2. Analyse de robustesse

4.2.1. Résultats de la DID hétérogène

L'effet moyen d'une intervention sur un seul groupe (cohorte) au fil du temps est étudié dans la figure 5. L'axe X suit les périodes de temps, éventuellement des années, tandis que l'axe Y représente l'ATET mesuré en unités pertinentes pour le résultat. La ligne bleue représente l'ATET pour le groupe bénéficiant de l'intervention. L'élément clé réside dans la pente de la ligne bleue. Une pente ascendante indique un ATET positif, ce qui signifie que le résultat moyen dans le groupe traité s'est amélioré par rapport au résultat de base. Une ligne plate indique qu'il n'y a pas de changement significatif, et une pente vers le bas implique un ATET négatif, où le résultat moyen s'est détérioré après l'intervention. Les pentes croissantes en 2008, 2011, 2013 et 2014 montrent que l'IA a amélioré la sécurité alimentaire en Afrique, tandis que les pentes décroissantes en 2007, 2009, 2010, 2012 et 2016 indiquent la tendance inverse. La pente pour 2015 montre qu'il n'y a pas eu d'effet de l'IA sur la sécurité alimentaire en Afrique. Cependant, les résultats ne sont pas clairs quant à la cohorte la plus influencée par l'IA et ouvrent donc la voie à une analyse des cohortes afin de spécifier réellement quelles sont les cohortes les plus touchées.

Figure 5 : Effet moyen du traitement (ATET) dans les différentes cohortes

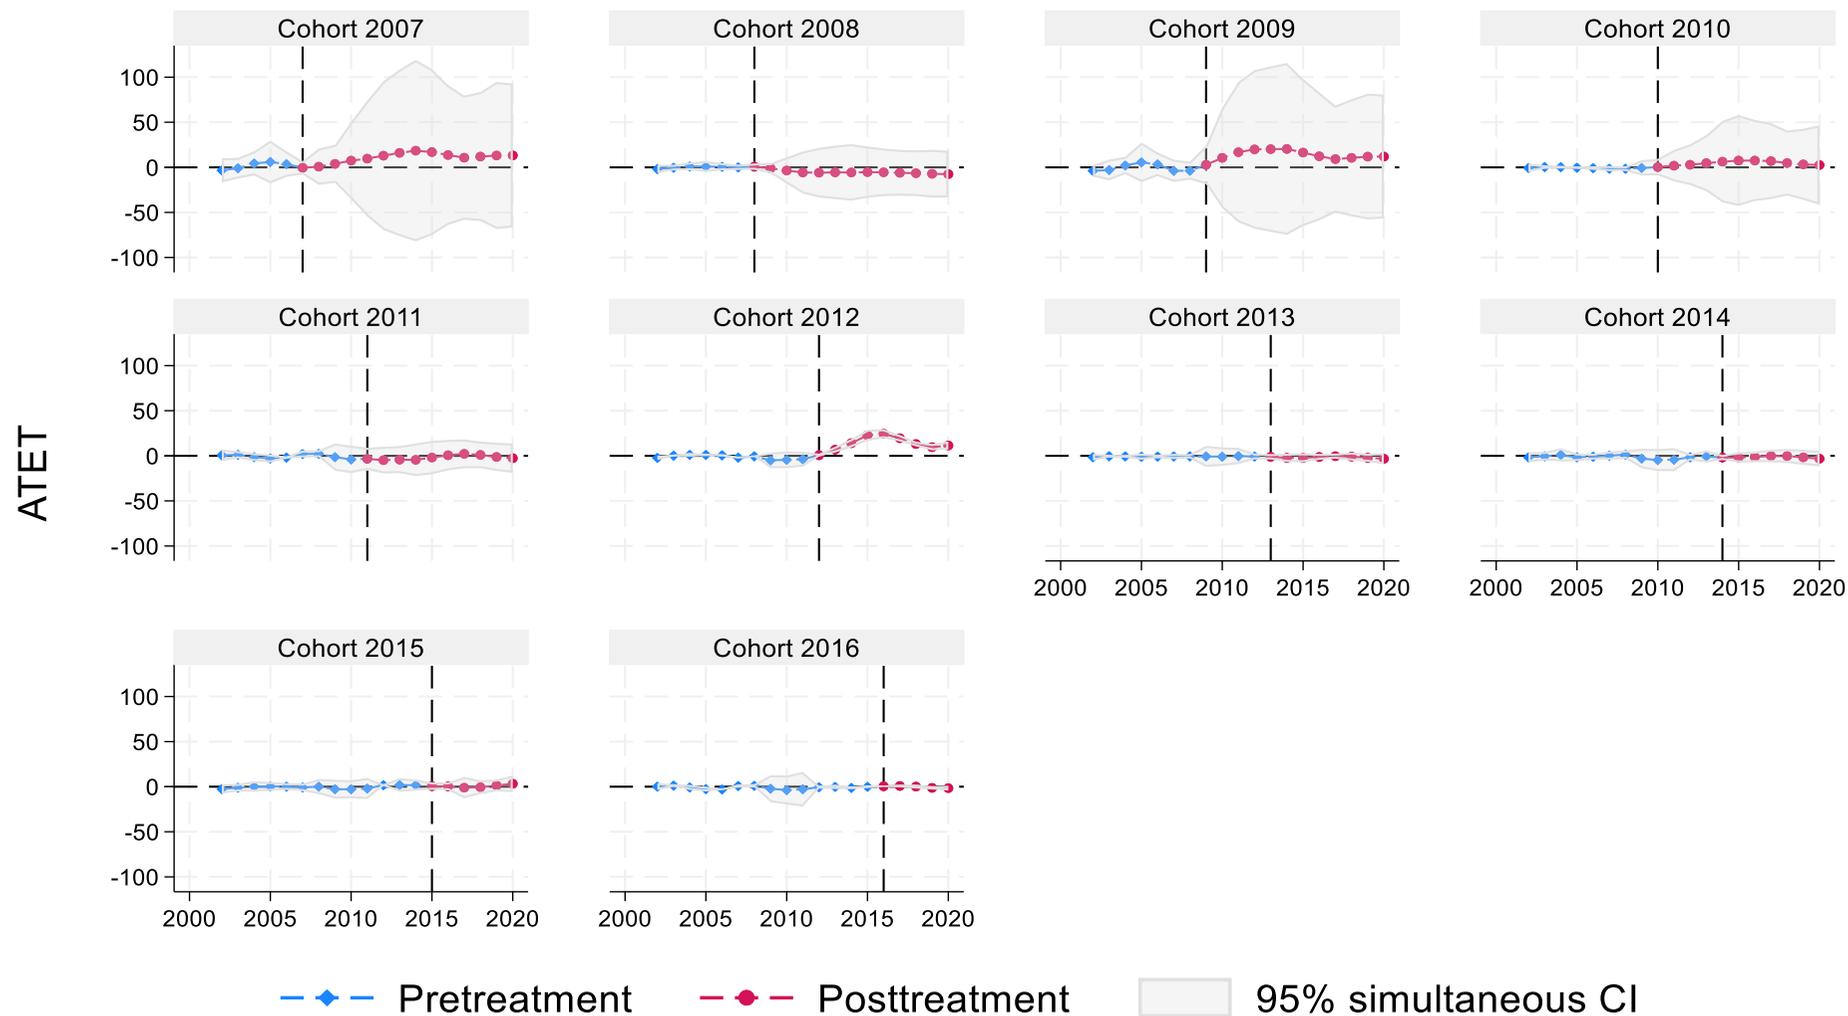


Source : auteurs

L'analyse de l'impact de l'IA sur l'insécurité alimentaire dans différents groupes (cohortes) en Afrique montre, à la figure 6, qu'il est important d'utiliser une approche hétérogène de différence dans les différences (DID). La première série de graphiques, représentant les

années 2007, 2009, 2010 et 2012, a exploré cette variation en comparant l'évolution de l'insécurité alimentaire pour chaque cohorte avant et après la mise en œuvre de l'IA et a révélé un impact contraire. Une diminution plus importante de l'insécurité alimentaire (distance verticale plus grande entre les points de données avant et après la mise en œuvre de l'IA) pour une cohorte spécifique suggère un effet positif plus important de l'IA sur ce groupe. C'est le cas pour 2008, 2013 et 2014. La deuxième série de graphiques ne montre aucune différence entre les scores avant et après l'IA dans ce groupe (2011, 2015 et 2016). Dans l'ensemble, ces analyses soulignent que l'IA peut avoir des effets variables sur différents groupes, ce qui permet de cibler les politiques et l'allocation des ressources afin de maximiser son impact positif sur la réduction de l'insécurité alimentaire en Afrique.

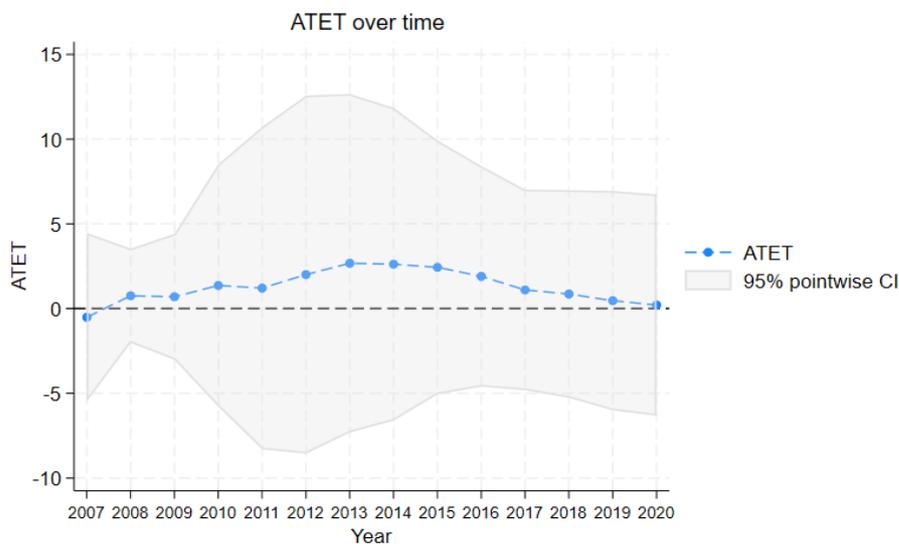
Figure 6 : Effet moyen du traitement (ATET) dans les différentes cohortes



Source : auteurs

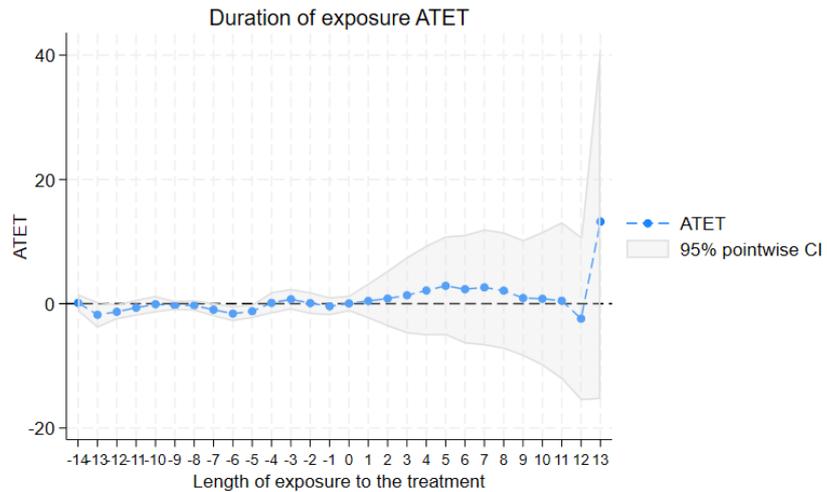
La figure 7 explore la manière dont l'influence de l'IA sur la sécurité alimentaire évolue dans le temps tout en tenant compte des variations au sein de la population étudiée. Une approche hétérogène de la différence des différences (DID) tient compte des différences préexistantes entre les sous-groupes définis par des facteurs tels que la participation à la population active, le PIB ou le développement financier. L'analyse clé se concentre sur la pente de la ligne ATET dans la période post-AI. Une pente plus forte vers le bas indique un impact positif plus important (de 2011 à 2019) de l'IA sur la sécurité alimentaire d'un sous-groupe. Inversement, une pente plus faible (de 2007 à 2013) ou une ligne plate (de 2019 à 2020) suggère un impact plus faible ou nul, et une pente ascendante peut indiquer un impact négatif. L'analyse des effets DID entre les sous-groupes montre quels segments bénéficient le plus, ce qui permet aux interventions ciblées de l'IA de maximiser leur impact positif sur la sécurité alimentaire de l'ensemble de la population, et c'est le cas pour le segment 2014-2019. Quoiqu'il en soit, l'analyse des cohortes ne tient pas compte de la variation temporelle, qui est un facteur important pour l'évaluation de l'impact.

Figure 7 : Effet moyen du traitement sur les personnes traitées (ATET) au fil du temps.



La figure 8 montre comment l'effet moyen du traitement (ATET) sur un groupe traité évolue en fonction de la durée d'exposition au traitement. La ligne elle-même illustre la tendance de l'ATET à mesure que la durée d'exposition augmente. Une pente ascendante suggère un effet positif plus important avec une exposition plus longue, tandis qu'une pente descendante peut indiquer une diminution de l'effet positif, voire un effet négatif, au fil du temps. Une ligne plate signifie que la durée d'exposition a un impact minimal sur l'ATET. Il est important de se rappeler que le traitement spécifique (ATET) et la mesure des résultats (axe Y) influencent l'interprétation. En outre, le graphique représente l'effet moyen sur le groupe traité et les réponses individuelles peuvent varier. Dans l'ensemble, ce graphique fournit des indications précieuses sur la relation potentielle entre la durée du traitement et l'efficacité du traitement pour le groupe traité.

Figure 8 : ATET en fonction de la durée d'exposition



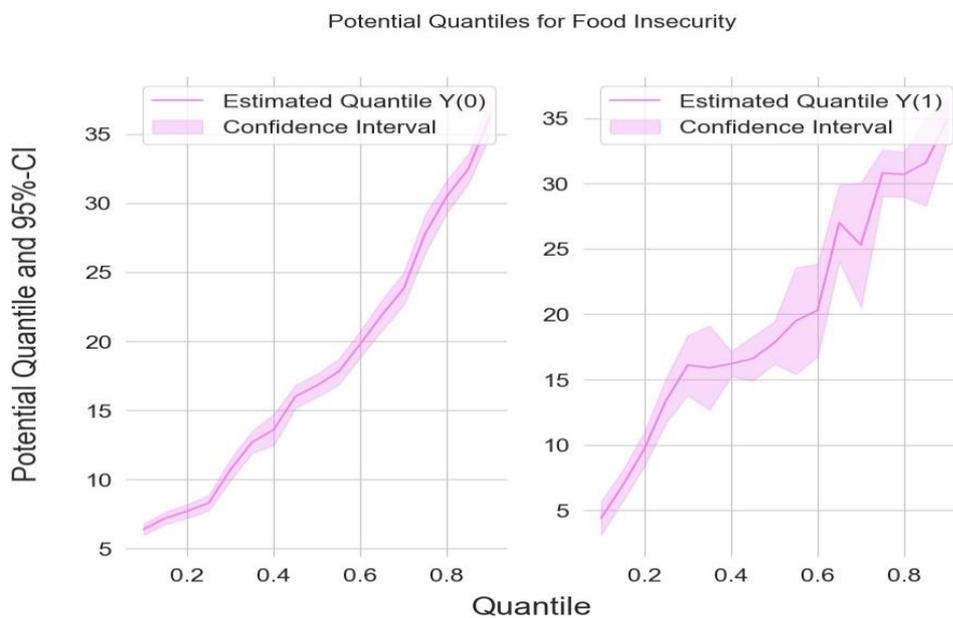
Source : auteurs

4.2.2. Analyse de l'effet de traitement par quantile

Dans la pratique, on s'intéresse souvent à l'effet non pas de toutes les variables explicatives mais, plus spécifiquement, de l'une d'entre elles. Dans cette étude, par exemple, nous nous intéressons à l'effet de l'utilisation de l'IA sur l'insécurité alimentaire en Afrique. L'objectif est d'évaluer l'effet causal de l'utilisation de l'IA, que l'on peut désigner par la variable binaire "T".

Pour fournir un cadre permettant d'aborder ces questions, nous pouvons utiliser le formalisme des méthodes issues de la littérature sur l'évaluation empirique des politiques publiques. Dans ce cadre, nous supposons que chaque pays a deux tendances "potentielles" dans l'évolution de l'insécurité alimentaire, Y0 (insécurité alimentaire attendue en l'absence d'utilisation de l'IA) et Y1 (insécurité alimentaire attendue avec l'utilisation de l'IA), comme le montre la figure 9. Cette figure montre que l'évolution de l'insécurité alimentaire varie avant et après l'utilisation de l'IA.

Figure 9 : Tendances potentielles de l'insécurité alimentaire.

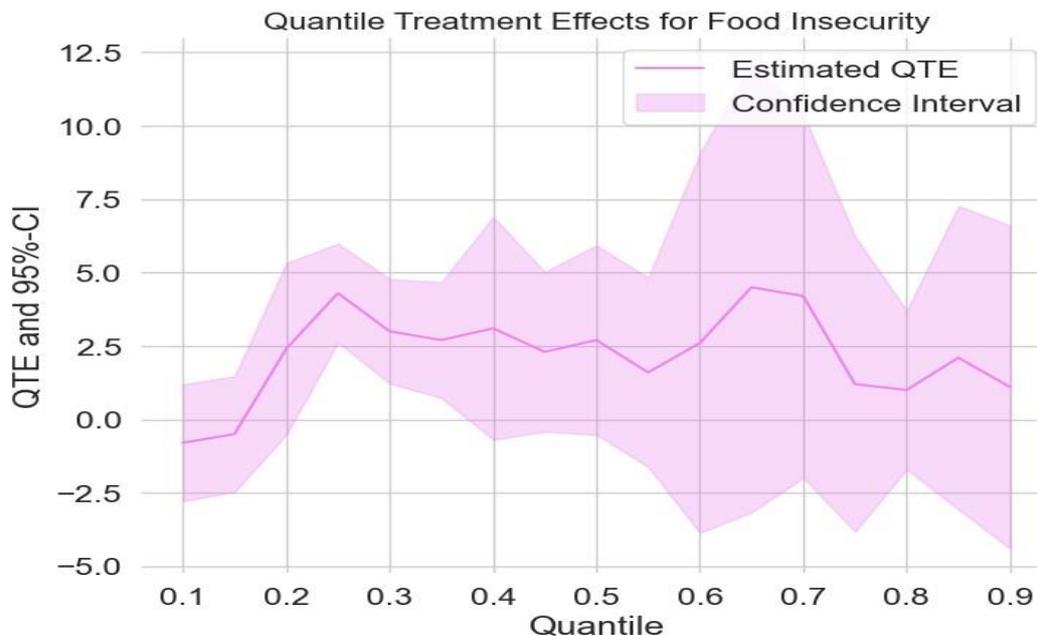


Source : auteurs

Ces changements potentiels dans l'insécurité alimentaire sont associés aux deux distributions $F(Y_0)$ et $F(Y_1)$. Nous pouvons alors définir le τ e quantile de l'effet de traitement (QTE) comme la distance horizontale entre les deux distributions (Doksum, 1974). En termes de présentation, nous disposons d'un ensemble de coefficients estimés pour chaque quantile d'intérêt. Les résultats sont donc plus lourds à présenter que pour une régression classique. Dans la littérature, ils sont présentés sous la forme d'un tableau regroupant l'ensemble des coefficients ou, peut-être plus parlant, sous la forme de graphiques. C'est la solution que nous avons choisie ici.

La figure 10 montre les estimations des coefficients pour les différents déciles, avec un intervalle de confiance de 95 % (zone rose). Le coefficient correspondant à la constante peut être considéré comme le décile pour les pays ayant des conditions de référence (dans ce cas, un pays n'utilisant pas l'IA). Il augmente avec le décile d'insécurité alimentaire. Il passe d'environ -1 pour le premier décile à 1,5 pour le neuvième décile. Le coefficient estimé par les moindres carrés ordinaires, qui correspond au niveau moyen d'insécurité alimentaire dans les pays avec des modalités de référence sans utilisation d'IA potentielle, est plus proche des premiers déciles (environ 0), ce qui indique clairement que l'effet de l'utilisation de l'IA sur l'insécurité alimentaire est asymétrique.

Figure 10 : Évolution de l'effet de l'IA par quantile d'insécurité alimentaire.



Source : auteurs

L'effet de traitement par quantile est plus général puisqu'il correspond à la différence entre les quantiles des distributions que l'on s'attendrait à observer dans les pays si l'utilisation de l'IA était généralisée à tous ou, au contraire, en son absence. Comme nous l'avons déjà noté, ces paramètres ne correspondent généralement pas à l'effet de l'utilisation de l'IA pour les pays qui se situent au τ ème quantile de la distribution de Y en l'absence d'utilisation de l'IA. En principe, ce paramètre ne permet donc pas de dire si ce sont les pays initialement les plus (dés)favorisés qui bénéficieraient de l'utilisation de l'IA que nous évaluons. Pour passer à cette interprétation, il faut à nouveau supposer l'invariance des rangs (les pays seraient "ordonnés" de la même manière dans la distribution de la variable d'intérêt Y en l'absence ou en présence

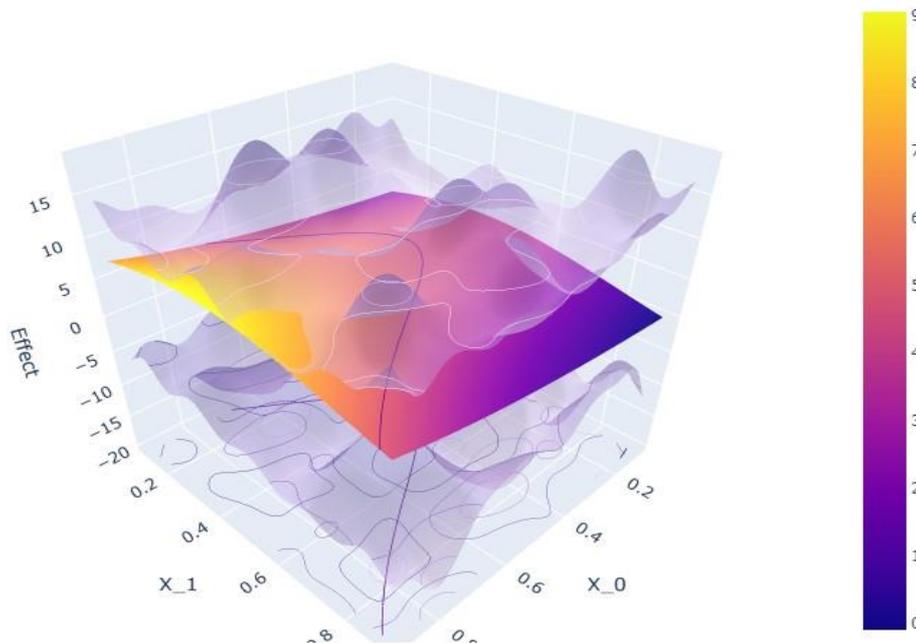
4.2.3. Traitement hétérogène

Il peut être difficile d'examiner l'impact d'un traitement dans le cadre d'études d'observation. Ces études sont vulnérables à la confusion par l'indication, au biais dans la détermination de l'exposition au traitement, aux inexactitudes dans l'évaluation des résultats et au manque d'informations pronostiques cruciales (dans les études utilisant des données existantes). Ces biais et erreurs de mesure peuvent créer une illusion d'hétérogénéité dans les effets du traitement (HTE) alors qu'il n'y a pas de biais ou, à l'inverse, masquer la véritable HTE. Pour déterminer si un résultat indique une véritable hétérogénéité, les chercheurs doivent évaluer soigneusement les ETS observés, car l'hétérogénéité dans les études d'observation peut résulter d'événements fortuits ou de biais. Pour ce faire, il est nécessaire d'évaluer les résultats fortuits en effectuant des tests d'interaction. Pour éviter les biais, il est essentiel de suivre des principes de conception d'étude solides et d'évaluer la distribution des covariables au sein des sous-groupes afin de déterminer le risque de confusion. Dans les études d'observation, de multiples facteurs peuvent contribuer à l'hétérogénéité, fournissant des explications possibles pour l'effet global (ATE) observé. Pour approfondir l'analyse et mieux adapter les plans de traitement, nous avons cherché à estimer l'effet moyen conditionnel du traitement (EMC) ou l'effet hétérogène du traitement. Cette approche permettra de mieux comprendre comment les effets du traitement diffèrent d'un pays à l'autre.

Les effets du traitement sont rarement parfaitement homogènes au sein d'un panel, comme le supposent les méthodes précédentes. Par exemple, l'utilisation de l'IA peut fonctionner de manière similaire à une technologie existante dans les pays de notre panel, mais peut être extrêmement bénéfique pour un sous-groupe de pays présentant des caractéristiques spécifiques. Il peut donc être difficile d'appliquer l'effet moyen d'un traitement pour répondre à des questions sur les résultats individuels. Les effets de l'utilisation de l'IA sur l'insécurité alimentaire dépendent des caractéristiques du pays (covariables), telles que le niveau de développement du pays (revenu par habitant), le dynamisme de la main-d'œuvre nationale (taux d'activité), la facilité d'accès au crédit dans le pays (développement financier) et la durabilité de son économie (consommation d'énergie renouvelable), entre autres. Il est donc naturel de déduire que les effets de l'IA sur l'insécurité alimentaire ne sont généralement pas homogènes d'un pays à l'autre, comme le suggère le tableau 1.

En ce qui concerne l'effet de traitement hétérogène, les pays ont montré une hétérogénéité significative en réponse à l'utilisation de l'IA, certains pays bénéficiant davantage, d'autres moins et d'autres encore ne bénéficiant pas du tout de l'utilisation de l'IA (figure 11). Par conséquent, l'effet de traitement moyen est d'une valeur limitée pour informer les individus, et une analyse de l'effet de traitement hétérogène est nécessaire pour comprendre comment les effets de traitement varient d'un pays à l'autre. La figure 11 montre que l'effet de l'adoption de l'IA sur l'insécurité alimentaire n'est pas uniforme dans notre panel. Certains pays bénéficient davantage de l'utilisation de l'IA, d'autres en bénéficient moins et d'autres encore n'en bénéficient pas du tout. La figure 11 illustre la distribution des effets réels de l'adoption de l'IA sur l'insécurité alimentaire définie par le modèle en fonction des covariables. L'effet réel de l'adoption de l'IA est indiqué par le carré multicolore de la figure 11. La figure montre que l'effet de l'IA varie de l'absence d'effet (couleur foncée) à un effet maximal (couleur jaune). Ce résultat confirme la non-uniformité des effets de l'adoption de l'IA au sein de notre panel. On observe donc une transition non linéaire entre l'effet de traitement le plus élevé et l'effet de traitement le plus faible.

Figure 11 : Effets hétérogènes du traitement



Source : auteurs

Le tableau 5 fournit des estimations des effets de traitement moyens conditionnels (CATE) en anglais « *Conditional Average Treatment Effects* » de l'IA sur l'insécurité alimentaire dans différents sous-groupes de pays. Les CATE représentent l'effet moyen de l'IA sur l'insécurité alimentaire pour un sous-groupe spécifique, tous les autres facteurs étant maintenus constants. Chaque ligne du tableau correspond à un sous-groupe spécifique, défini par les valeurs des variables de contrôle. La colonne "*point_estimate*" indique le CATE estimé pour ce sous-groupe. Par exemple, dans la première ligne, l'estimation ponctuelle de 0,025 indique que pour les pays ayant un PIBhab de 1, un PFR de 0, un DF de 0 et une consommation d'énergie renouvelable de 0, l'augmentation moyenne de l'insécurité alimentaire due à l'adoption de l'IA est de 0,025 unité.

En outre, le tableau 5 révèle l'hétérogénéité de l'effet de l'IA sur l'insécurité alimentaire. Les CATE varient d'un sous-groupe à l'autre, ce qui suggère que l'impact de l'IA sur l'insécurité alimentaire n'est pas uniforme d'un pays à l'autre. Les variables de contrôle telles que le PIBhab, la PMT, l'FD et la consommation d'énergie renouvelable contribuent probablement à l'hétérogénéité observée. L'IA peut avoir des effets différents sur l'insécurité alimentaire dans les pays où le PIBhab, la PMT, la FD et la consommation d'énergie renouvelable sont plus élevés. Le tableau fournit donc des indications précieuses sur les effets hétérogènes de l'IA sur l'insécurité alimentaire. L'hétérogénéité observée suggère que l'impact de l'IA varie selon les différents sous-groupes de pays, et des recherches supplémentaires sont nécessaires pour comprendre pleinement les mécanismes sous-jacents impliqués.

Tableau 5 : Estimation de l'effet conditionnel du traitement.

<i>Résultats des coefficients</i>						
	<i>estimation_du_point</i>	<i>Erreur std.</i>	<i>z-stat</i>	<i>Valeur p</i>	<i>ci_inférieur</i>	<i>ci_upper</i>
PIBhab	0.025	0.006	4.401	0.0	0.014	0.036
PMT	0.012	0.0001	1.592	0.111	-0.01	0.030
DevFin	426.663	0.0	127320.743	0.0	426.663	426.664
RE	-0.822	0.603	-1.364	0.173	-2.004	0.359
<i>Résultats de l'interception CATE²</i>						
	<i>estimation_du_point</i>	<i>Erreur std.</i>	<i>z-stat</i>	<i>Valeur p</i>	<i>ci_inférieur</i>	<i>ci_upper</i>
<i>cate_intercept</i>	-131.365	0.006	-20597.237	0.0	-131.377	-131.352

Source: auteurs

L'arbre de décision de la figure 13 représente une approche non paramétrique de l'estimation des effets de traitement hétérogènes de l'intelligence artificielle sur l'insécurité alimentaire dans les pays africains. Il divise les données en sous-groupes sur la base des valeurs des variables de contrôle (PIBhab, PMT, FD et consommation d'énergie renouvelable) et estime l'effet de traitement moyen (ATE) pour chaque sous-groupe. Le nœud racine représente l'ensemble de l'échantillon de pays. La valeur CATE au nœud racine (1,299) indique l'effet moyen de l'IA sur l'insécurité alimentaire dans l'ensemble des pays. L'arbre est divisé en fonction des valeurs des variables de contrôle. Chaque branche représente un sous-groupe défini par des valeurs spécifiques des variables de contrôle. Les nœuds des feuilles représentent les sous-groupes finaux, et les valeurs CATE aux nœuds des feuilles représentent les effets de traitement estimés pour ces sous-groupes spécifiques. Un CATE positif indique que l'adoption de l'IA est associée à une augmentation de l'insécurité alimentaire dans ce sous-groupe. Inversement, un CATE négatif indique que l'adoption de l'IA est associée à une diminution de l'insécurité alimentaire dans ce sous-groupe.

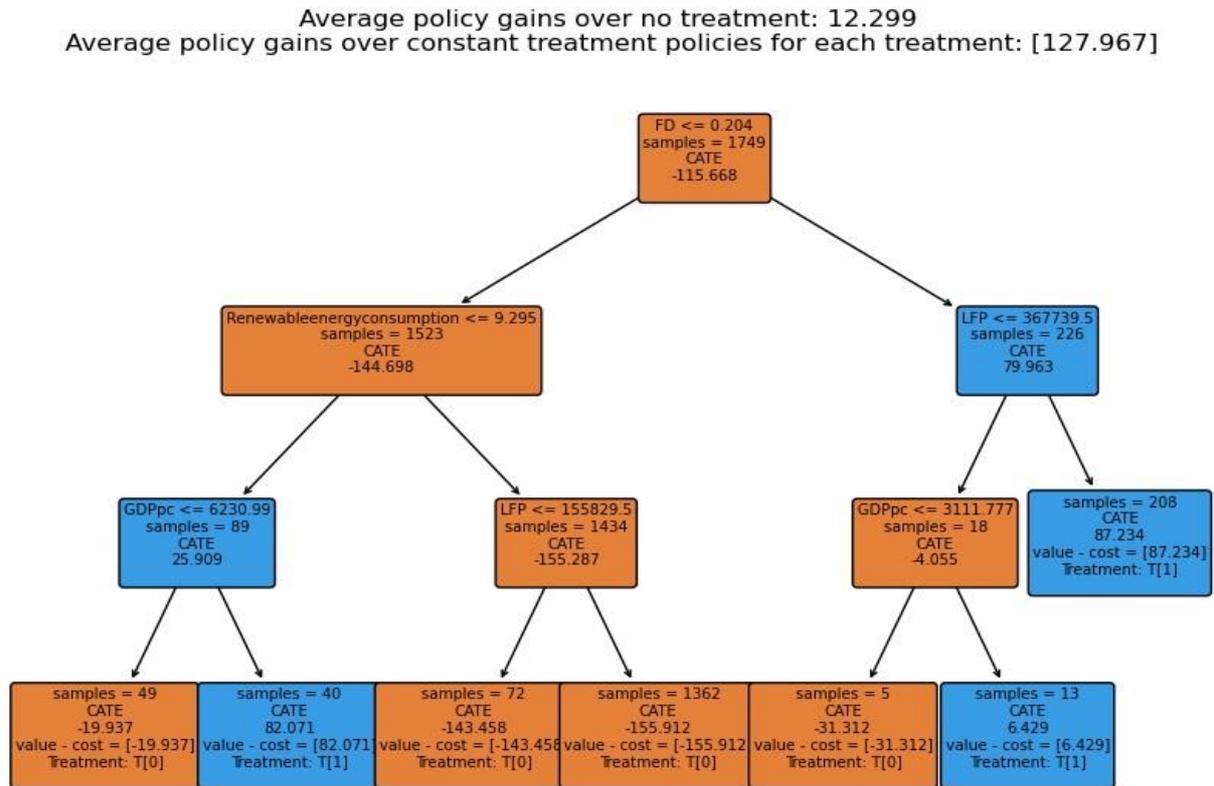
Par exemple, si le PIBhab est inférieur ou égal à 6 230,99, le CATE est de -115,668. Cela suggère que pour les pays ayant un PIBhab faible, l'adoption de l'IA est associée à une réduction de l'insécurité alimentaire de 115,668 unités en moyenne. De même, si le PIBhab est supérieur à 6 230,99 et que la PFR est inférieure ou égale à 155 829,5, le CATE est de 87,234. Cela suggère que pour les pays ayant un PIBhab élevé et une faible PFR, l'adoption de l'IA est associée à une augmentation de l'insécurité alimentaire de 87,234 unités en moyenne.

L'arbre de décision met en évidence l'hétérogénéité de l'effet de l'IA sur l'insécurité alimentaire. Les CATE varient d'un sous-groupe à l'autre, ce qui suggère que l'impact de l'IA n'est pas uniforme dans les pays africains. Les variables de contrôle telles que le PIBhab, la PMT, le FD et la consommation d'énergie renouvelable contribuent probablement à

² Conditional Average Treatment Effects

l'hétérogénéité observée. Les pays présentant des niveaux différents de ces facteurs peuvent connaître des effets différents de l'IA sur l'insécurité alimentaire. L'arbre de décision est un outil utile pour explorer les effets hétérogènes de l'IA sur l'insécurité alimentaire en Afrique. L'hétérogénéité observée suggère que l'impact de l'IA varie selon les différents sous-groupes de pays, et des recherches supplémentaires sont nécessaires pour comprendre pleinement les mécanismes sous-jacents impliqués.

Figure 13 : Arbres de décision



Source : auteurs

5. Conclusion

5.1. Principales conclusions

Au terme de ce travail, l'objectif était d'évaluer l'impact de l'adoption de l'IA sur l'insécurité alimentaire en Afrique. Les résultats obtenus à partir de l'appariement des scores de propension, qui est une méthode non paramétrique d'évaluation de l'impact, ont montré qu'en moyenne, l'adoption de l'IA réduit significativement l'insécurité alimentaire en Afrique. En d'autres termes, l'application de l'IA dans les secteurs agricole et alimentaire contribue à accroître l'efficacité, la productivité et la résilience des systèmes alimentaires. Ces avancées prometteuses offrent des opportunités cruciales pour atténuer les défis persistants associés

à la sécurité alimentaire dans la région. Les résultats obtenus dans cet article se sont avérés solides grâce à plusieurs analyses de robustesse et à des spécifications supplémentaires. Néanmoins, pour maximiser les avantages de l'IA dans la lutte contre l'insécurité alimentaire, des politiques économiques stratégiques sont essentielles. Nous suggérons que les gouvernements africains et les parties prenantes qui s'engagent à atteindre la faim zéro investissent dans l'infrastructure technologique afin d'encourager l'investissement dans les technologies d'IA, de les rendre accessibles aux petits exploitants agricoles et d'encourager leur adoption à grande échelle. En outre, il est impératif de développer des programmes de formation et de soutien pour permettre aux agriculteurs et aux acteurs du secteur alimentaire d'utiliser efficacement les outils technologiques liés à l'IA. Enfin, les partenariats entre les acteurs africains, les organisations internationales et les centres de recherche doivent être renforcés afin d'échanger les meilleures pratiques et de promouvoir le partage des technologies et des connaissances.

5.2. Limites et perspectives

Malgré l'ambition de cet article, certaines lacunes théoriques ou empiriques subsistent et pourraient être étudiées dans le cadre d'une extension de ce travail. Il pourrait notamment s'agir d'utiliser une mesure quantitative de l'IA afin de déterminer la sensibilité potentielle des résultats.

Tableau A2 : Description des variables

Variables	Code	Description
Insécurité alimentaire	Alimentation	Prévalence de la sous-alimentation (% de la population totale) Codifié comme "1" pour les pays qui ont adopté l'utilisation de la haute technologie et "0" dans le cas contraire.
Intelligence artificielle	IA	
Participation au marché du travail	PMT	Taux d'activité des 15-24 ans, total (%) (estimation modélisée du BIT)
PIB par habitant	PIBhab	PIB par habitant (en dollars constants de 2015)
Développement financier	DEVFIN	Crédit domestique au secteur privé par les banques (% du PIB)
Énergies renouvelables	RE	Consommation d'énergie renouvelable (% de la consommation totale d'énergie finale)

Source : auteurs

RÉFÉRENCES BIBLIOGRAPHIQUES :

1. Tilman, D., Balzer, C., Hill, J., Befort, B. L., 2011. «Global food demand and the sustainable intensification of agriculture ». *Proceedings of the National Academy of Sciences* 108: p. 20260-20264.
2. FAO, 2022, «The State of Food and Agriculture 2022: leveraging agricultural automation for transforming agrifood systems ». Rome, Italy: Food and Agriculture Organisation (FAO).
3. Gouel, C. and Guimbard, H., 2019, « Nutrition transition and the structure of global food demand ». *American Journal of Agricultural Economics* 101: p. 383-403.

4. Issa, H., Jabbouri, R., & Palmer, M. 2022, « An artificial intelligence (AI)-readiness and adoption framework for AgriTech firms », *Technological Forecasting and Social Change*, 182, p. 121-874.
5. Van Hilten, M. and Wolfert, S., 2022, « 5G in agri-food-a review on current status, opportunities and challenges », *Computers and Electronics in Agriculture* 201: p.107-291.