

Maximization of Agricultural Productivity through Machine Learning and the Internet of Things

Erick NGINDU BEYA

Sciences Informatiques
Université Notre-Dame du kasayi, U.KA.
Kananga, République Démocratique du Congo
erickngindu@uka.ac.cd

Abstract—This article project explores the potential of Artificial Intelligence (AI) to transform the agricultural sector in developing countries. Faced with persistent challenges such as low yields, post-harvest losses, inefficient resource management, and the impacts of climate change, agriculture in these regions struggles to achieve optimal productivity and efficiency. The study proposes an in-depth analysis of various AI applications including machine learning, computer vision, and agricultural IoT to optimize decision-making, improve crop and livestock management, and enhance the resilience of farming systems. We will consider the design of a methodological framework for integrating AI solutions adapted to local contexts, taking into account infrastructure, data accessibility, and farmers' capabilities. The objective is to demonstrate how AI can not only significantly increase yields and reduce waste, but also foster more sustainable and profitable agriculture, thereby contributing to food security and sustainable economic development.

Keyword: Artificial Intelligence (AI), Machine Learning, Computer Vision, Agricultural IoT, Food Security, Sustainable Development.

Résumé— Cet article explore le potentiel de l'intelligence artificielle (IA) pour transformer le secteur agricole dans les pays en développement. Confrontée à des défis persistants tels que le faible rendement, les pertes post-récolte, la gestion inefficace des ressources et les impacts du changement climatique, l'agriculture dans ces régions peine à atteindre une productivité et une efficacité optimales. L'étude propose une analyse approfondie des diverses applications de l'IA incluant l'apprentissage automatique, la vision par ordinateur et l'IoT agricole pour optimiser la prise de décision, améliorer la gestion des cultures et du bétail, et renforcer la résilience des systèmes agricoles. Nous envisagerons la conception d'un cadre méthodologique pour l'intégration de solutions IA adaptées aux contextes locaux, en tenant compte des infrastructures, de l'accès aux données et des capacités des agriculteurs. L'objectif est de démontrer comment l'IA peut non seulement accroître significativement les rendements et réduire les gaspillages, mais aussi favoriser une agriculture plus durable et plus rentable, contribuant ainsi à la sécurité alimentaire et au développement économique durable.

Mot-clé

Intelligence Artificielle (IA), Efficacité, Apprentissage automatique, Vision par ordinateur, IoT agricole, Sécurité alimentaire, Développement durable.

1. Introduction

Le secteur agricole joue un rôle fondamental dans les pays en développement : il constitue le principal moteur de l'économie, la source de revenus pour une majorité de la population et le garant de la sécurité alimentaire (FAO, 2020). Selon le rapport de la Banque mondiale publié en 2024, cette contribution est souvent entravée par des défis persistants et multidimensionnels : faibles rendements, pertes post-récolte importantes, gestion inefficace des ressources en eau et des sols, exposition accrue aux maladies et ravageurs, ainsi que les impacts croissants du changement climatique. Ces contraintes limitent la productivité et l'efficacité des systèmes agricoles locaux, compromettant la résilience des communautés et un développement économique durable.

Dans ce contexte, l'intelligence artificielle (IA) émerge comme une technologie disruptive, offrant des perspectives prometteuses pour révolutionner les pratiques agricoles (L. Benos et al, 2021). Des applications variées – apprentissage

automatique pour la prédiction des rendements et la détection des maladies, vision par ordinateur pour le suivi des cultures et du bétail, et Internet des Objets (IoT) pour la surveillance en temps réel des conditions environnementales – montrent un potentiel considérable pour optimiser la prise de décision et automatiser des tâches complexes (A. Kamilaris et F.X. Prenafeta-Boldù, 2018)

La présente recherche vise à explorer en profondeur l'utilisation de l'intelligence artificielle pour améliorer la productivité et l'efficacité du secteur agricole dans les pays en développement. Elle analysera comment l'intégration de solutions basées sur l'IA peut augmenter significativement les rendements, réduire les gaspillages, et favoriser une agriculture plus durable, résiliente et rentable, contribuant ainsi à la sécurité alimentaire et au développement économique durable.

Malgré ce potentiel évident, l'adoption de ces technologies dans les systèmes agricoles des pays en développement reste limitée. **Comment l'intelligence artificielle peut-elle être efficacement mobilisée pour répondre aux défis structurels de l'agriculture, tout en tenant compte des contraintes locales liées aux infrastructures, aux compétences techniques et à l'accessibilité économique?**

Nous soutenons que l'intégration progressive de solutions d'IA adaptées à ces contextes permettrait une amélioration substantielle de la productivité agricole, une gestion plus efficace des ressources naturelles et une réduction des pertes, **à condition que ces technologies soient accessibles, accompagnées de formations appropriées et soutenues par des politiques publiques incitatives.**

Pour atteindre ces objectifs, notre étude adopte une approche qualitative et exploratoire, combinant :

1. Une **revue de la littérature** tirée de sources académiques et de rapports institutionnels (FAO, Banque mondiale, ONUDI), axée sur l'IA appliquée à l'agriculture.
2. **Études de cas concrets** illustrant l'usage de l'IA en agriculture dans des pays tels que l'Inde, le Kenya et le Rwanda, afin de comprendre les facteurs de succès, les obstacles rencontrés et les impacts observés.
3. Une **synthèse critique** visant à formuler des recommandations pertinentes pour les pays en développement, notamment ceux d'Afrique subsaharienne.

2. Le secteur agricole dans les pays en développement : état des lieux

Le secteur agricole constitue l'épine dorsale des économies nationales dans de nombreux pays en développement, particulièrement en Afrique subsaharienne. Sa compréhension approfondie est essentielle pour saisir les enjeux de développement durable et de bien-être des populations.

2.1. Rôle de l'agriculture dans l'économie locale

L'agriculture est bien plus qu'une simple activité de production alimentaire ; elle est le **principal pilier économique et social**. Elle emploie plus de la moitié de la population active dans la plupart de ces nations, fournissant des moyens de subsistance directs à des millions de ménages ruraux (FAO, 2020). Au-delà de l'emploi, le secteur est un **contributeur majeur au Produit Intérieur Brut (PIB)**, souvent représentant entre 20% et 40% de la richesse nationale, et joue un rôle crucial dans les exportations de matières premières (Banque Africaine de Développement, 2021). Son impact s'étend à la **sécurité alimentaire nationale**, assurant l'approvisionnement des marchés locaux et réduisant la dépendance aux importations. Par ailleurs, en stimulant le développement rural et en générant des revenus, l'agriculture est un **puissant levier pour la réduction de la pauvreté** et l'amélioration des conditions de vie des populations les plus vulnérables, contribuant ainsi à la stabilité sociale et à la cohésion communautaire (PNUD, 2019).

2.2. Défis structurels : productivité, climat, accès à la technologie

Malgré ce rôle central, l'agriculture dans les pays en développement est confrontée à une conjonction de défis structurels et conjoncturels qui entravent sévèrement son potentiel. La faible productivité demeure une préoccupation majeure ; les rendements des cultures et de l'élevage sont souvent significativement inférieurs aux moyennes mondiales en raison de l'utilisation prédominante de méthodes agricoles traditionnelles, de l'accès limité aux intrants modernes (semences améliorées, engrais adaptés, pesticides), et d'une mécanisation quasi inexistante (World Bank, 2022). À cela s'ajoutent

des pertes post-récolte considérables, estimées à 20-30% pour les céréales et jusqu'à 50% pour les fruits et légumes, dues à des infrastructures de stockage inadéquates, des chaînes d'approvisionnement inefficaces et des techniques de conservation rudimentaires (Inter-réseaux, 2023). Ces pertes représentent non seulement un gaspillage économique et environnemental, mais aussi une menace directe pour la sécurité alimentaire des populations.

Parallèlement, la vulnérabilité au changement climatique s'accroît. Les agriculteurs sont en première ligne face à des phénomènes météorologiques extrêmes (sécheresses prolongées, inondations dévastatrices), à des variations imprévisibles des régimes de pluie et à la dégradation des sols, rendant la planification agricole incertaine et les récoltes précaires (IPCC, 2021). L'accès limité aux technologies modernes et à l'information fiable (prévisions météorologiques, prix des marchés, bonnes pratiques agricoles) constitue un autre frein majeur. L'absence de cadres politiques favorables, de financements accessibles et de services de vulgarisation agricole efficaces maintient une grande partie des petits exploitants dans une agriculture de subsistance, les empêchant d'adopter des innovations susceptibles d'améliorer leur résilience et leur rentabilité (AGRA, 2019).

2.3. Besoin d'innovation technologique

Face à ces contraintes multidimensionnelles, la simple perpétuation des méthodes actuelles ne suffit plus à garantir la durabilité et la croissance du secteur agricole dans les pays en développement. Il est devenu impératif d'opérer une **transformation profonde** reposant sur **l'intégration stratégique de l'innovation technologique**. L'adoption de technologies avancées est la clé pour pallier les déficits de productivité, atténuer les impacts climatiques, optimiser l'utilisation des ressources et réduire les pertes. Cela implique de repenser les systèmes agricoles pour les rendre plus résilients, plus efficaces et plus rentables. Dans ce contexte, l'émergence de l'intelligence artificielle offre des perspectives sans précédent pour fournir des outils d'aide à la décision précis, des capacités d'analyse de données inédites et des solutions d'automatisation adaptées, ouvrant la voie à une agriculture véritablement intelligente et durable.

3. L'intelligence artificielle : concepts et outils adaptés à l'agriculture

L'émergence de l'intelligence artificielle (IA) marque une rupture technologique majeure, offrant des perspectives sans précédent pour de nombreux secteurs, y compris l'agriculture. Comprendre ses fondements et ses applications spécifiques est crucial pour apprécier son potentiel de transformation.

3.1. Définition et principes de l'IA

L'**intelligence artificielle (IA)** peut être définie comme l'ensemble des théories et techniques visant à créer des machines capables de simuler des aptitudes cognitives humaines, telles que l'apprentissage, le raisonnement, la perception, la compréhension du langage et la résolution de problèmes (Russell & Norvig, 2010). Au-delà de la simple automatisation, l'IA cherche à doter les systèmes informatiques de la capacité à analyser des données complexes, à identifier des modèles, à prendre des décisions autonomes et à s'adapter à de nouvelles situations sans être explicitement programmés pour chaque scénario. Les principes fondamentaux de l'IA reposent sur des algorithmes avancés, la capacité à traiter de vastes quantités de données (Big Data) et l'apprentissage continu à partir de ces données. Dans le contexte agricole, l'IA permet ainsi de transformer des informations brutes en connaissances actionnables, ouvrant la voie à une agriculture de précision et à une gestion optimisée.

3.2. Types d'IA utilisés en agriculture

Plusieurs branches de l'IA trouvent des applications directes et transformatrices dans le domaine agricole :

- ✓ **Apprentissage Automatique (Machine Learning - ML)** : Il s'agit d'une sous-catégorie de l'IA qui permet aux systèmes d'apprendre à partir de données sans programmation explicite. En agriculture, le ML est utilisé pour des tâches telles que la prédiction des rendements en analysant les données historiques et météorologiques (Liakos et al., 2018), la détection précoce des maladies et ravageurs en identifiant des schémas dans les données de capteurs ou d'imagerie (Sharma et al., 2020), et l'optimisation des plans d'irrigation et de fertilisation en fonction des besoins spécifiques des cultures et des conditions du sol.

- ✓ **Vision par Ordinateur (Computer Vision) :** Cette discipline permet aux ordinateurs d'interpréter et de comprendre des images et des vidéos. Dans l'agriculture, la vision par ordinateur, souvent associée à des drones ou des robots, est employée pour la surveillance de la santé des cultures (détection de stress hydrique, carences nutritionnelles), le comptage des fruits pour estimer la récolte, la cartographie des mauvaises herbes pour un désherbage ciblé (Patel et al., 2020) et le suivi du bétail (identification individuelle, détection de maladies ou de comportements anormaux).
- ✓ **Internet des Objets (IoT) et Capteurs :** Bien que n'étant pas une forme d'IA en soi, l'IoT est une technologie habilitante cruciale. Les capteurs connectés, déployés dans les champs ou sur les animaux, collectent en temps réel une multitude de données sur le sol (humidité, pH, nutriments), le climat (température, humidité, luminosité), l'état des cultures ou le comportement animal (Tsoulis et al., 2021). Ces données massives et continues sont ensuite transmises et analysées par des algorithmes d'IA, fournissant des informations précieuses pour la prise de décision en temps opportun et la mise en œuvre de pratiques d'agriculture de précision.
- ✓ **Robotique Agricole :** Alimentés par l'IA et la vision par ordinateur, les robots peuvent effectuer des tâches complexes et répétitives avec une grande précision, comme le semis, la pulvérisation ciblée, la récolte sélective ou la surveillance des cultures, réduisant ainsi la pénibilité du travail et l'utilisation excessive d'intrants.

3.3. Outils et plateformes existants

De nombreuses solutions basées sur l'IA sont déjà opérationnelles ou en phase de développement avancée, démontrant la faisabilité et les bénéfices de cette technologie dans des contextes variés, y compris potentiellement pour les pays en développement :

- ✓ **Plantix :** Cette application mobile utilise la **vision par ordinateur** et l'apprentissage automatique pour aider les agriculteurs à identifier les maladies, les ravageurs et les carences nutritives des plantes à partir de simples photos. Elle fournit ensuite des recommandations de traitement spécifiques, rendant l'expertise agronomique accessible même dans des zones reculées (Plantix, n.d.).
- ✓ **Zenvus :** Développée pour l'agriculture africaine, Zenvus combine des **capteurs IoT** de sol qui collectent des données sur l'humidité, la température et les nutriments, avec des algorithmes d'IA qui analysent ces données pour fournir aux agriculteurs des conseils personnalisés sur les cultures, les engrais et l'irrigation, optimisant ainsi les rendements et réduisant les coûts (Zenvus, n.d.).
- ✓ **Drones Agricoles :** Équipés de caméras multispectrales et thermiques, les drones collectent des images à haute résolution des champs. L'**IA analyse ces images** pour créer des cartes de santé des cultures, détecter les zones stressées, estimer les rendements et optimiser les épandages d'eau ou de pesticides (Boretti & Rosa, 2019). Cette technologie permet une agriculture de précision à grande échelle.
- ✓ D'autres solutions émergentes incluent des plateformes d'analyse de données satellitaires (ex: FarmLead pour les marchés de céréales), des systèmes de gestion intelligente de l'irrigation (ex: CropX), et des outils d'optimisation de la logistique agricole. Ces exemples illustrent le vaste éventail d'applications de l'IA, capables d'améliorer la productivité et l'efficacité à toutes les étapes de la chaîne de valeur agricole.

4. Collecte et traitement des données agricoles basés sur l'IoT

L'agriculture intelligente repose sur la capacité à **collecter, traiter et analyser de grandes quantités de données** provenant du terrain, en temps réel. L'Internet des Objets (IoT), par l'intermédiaire de capteurs connectés, permet de surveiller en continu divers paramètres environnementaux comme la température, l'humidité, la salinité du sol ou la présence de maladies dans les cultures. Ces dispositifs, souvent interconnectés via des réseaux sans fil ou cellulaires, sont aujourd'hui au cœur de l'agriculture de précision (Wolfert, Ge, Verdouw, & Bogaardt, 2017).

Cependant, la simple acquisition de données ne suffit pas. Les flux de données recueillis doivent d'abord être **prétraités** : cela inclut le nettoyage (suppression des valeurs aberrantes ou manquantes), la transformation (normalisation ou

standardisation), puis le **stockage** dans des infrastructures adaptées (bases de données relationnelles ou NoSQL, cloud computing, etc.) (Kamilaris, Kartakoullis, & Prenafeta-Boldú, 2017).

Une fois les données structurées, elles peuvent être soumises à des techniques d'**analyse statistique ou de machine learning** pour produire de l'information utile. Cela comprend l'extraction d'indicateurs agricoles (stress hydrique, prévalence de maladies, besoins nutritionnels des cultures), l'identification de tendances, ou encore la détection d'anomalies (Misra, Agarwal, & Verma, 2020).

Enfin, les données traitées permettent la **création de modèles prédictifs**. Ces modèles, basés sur des algorithmes de régression, de classification ou d'apprentissage profond (deep learning), peuvent prédire le rendement, détecter les maladies avant qu'elles ne se propagent, ou optimiser l'irrigation selon les conditions météorologiques locales (Benos et al., 2021). L'entraînement de ces modèles nécessite des données historiques bien étiquetées, et leur performance est évaluée par des méthodes de validation croisée et des indicateurs comme l'exactitude, la précision ou le rappel.

4.1. Équipements IoT et capteurs dans les exploitations agricoles

L'utilisation de capteurs connectés constitue la première étape dans le déploiement d'un système d'agriculture intelligente. Ces équipements IoT (Internet of Things) sont capables de **collecter des données environnementales et biologiques** à intervalles réguliers, de façon autonome, tout en les transmettant à des serveurs ou plateformes d'analyse via des réseaux de communication (Wi-Fi, GSM, LoRaWAN, ZigBee, etc.).

Parmi les capteurs les plus couramment utilisés, on retrouve :

- **Capteurs de sol** : mesurent l'humidité, la température, le pH, la salinité, essentiels pour la gestion de l'irrigation et la fertilisation.
- **Capteurs climatiques** : température de l'air, humidité relative, vitesse du vent, rayonnement solaire, utiles pour anticiper les conditions météorologiques défavorables.
- **Caméras multispectrales ou thermiques** : installées sur drones ou tracteurs, elles permettent d'effectuer une surveillance visuelle de la croissance des cultures ou de détecter des maladies précoces.
- **Colliers ou balises GPS pour le bétail** : utilisés pour la géolocalisation, le suivi des comportements et la santé animale dans les élevages (Verdouw et al., 2016).

L'installation de ces dispositifs transforme les champs et les exploitations en véritables **environnements intelligents**, capables de s'auto-surveiller et de générer des données cruciales à haute fréquence (Kamilaris et Prenafeta-Boldú, 2018). Cette digitalisation permet de passer d'une gestion empirique à une **prise de décision fondée sur les données**, en temps réel.

Cependant, l'adoption de ces technologies dans les pays en développement reste limitée, en raison du **coût élevé des équipements**, de la **faible couverture réseau** dans les zones rurales et du **manque de compétences techniques** pour la maintenance et l'interprétation des données (Wolfert et al., 2017). Pour que ces outils soient accessibles, des solutions open source, à bas coût et adaptées au contexte local doivent être encouragées.

4.2. Prétraitement et gestion des données agricoles

Une fois les données collectées à partir des capteurs IoT, elles doivent être **prétraitées** avant toute analyse ou utilisation dans des modèles prédictifs. Le prétraitement des données constitue une étape cruciale, car les données agricoles sont souvent **incomplètes, bruitées, redondantes ou incohérentes** en raison des conditions environnementales, des défaillances techniques des capteurs ou des interruptions de transmission (Kamilaris, Kartakoullis, & Prenafeta-Boldú, 2017).

Le processus de prétraitement comprend plusieurs opérations essentielles :

- **Nettoyage des données** : consiste à éliminer ou corriger les valeurs aberrantes, supprimer les doublons, combler les valeurs manquantes (par interpolation ou estimation).
- **Transformation des données** : implique la normalisation ou la standardisation des mesures pour les rendre comparables entre capteurs ou zones agricoles.
- **Filtrage temporel ou spatial** : permet de lisser les séries temporelles ou de rééchantillonner les données spatiales en fonction des besoins de l'analyse.

Une fois nettoyées, les données doivent être **stockées dans des systèmes robustes et accessibles**, adaptés au volume et à la complexité des flux. Selon le cas, on utilise des bases de données relationnelles (SQL) pour les données structurées, ou des bases NoSQL (comme MongoDB ou InfluxDB) pour les données temporelles, géospatiales ou semi-structurées (Zhang, Wang, & Wang, 2021). Le **cloud computing** offre également des infrastructures de stockage et de traitement distribuées, permettant d'analyser à grande échelle des données hétérogènes et de réduire les coûts locaux (Wolfert et al., 2017).

Dans le contexte des pays en développement, la gestion des données pose plusieurs défis : **infrastructures numériques limitées, coûts élevés de connectivité, manque de spécialistes des données et faible interopérabilité des systèmes**. Une gouvernance adaptée des données agricoles est donc indispensable, incluant des normes ouvertes, la protection des données des agriculteurs, et des plateformes de mutualisation régionales (FAO, 2022).

4.3. Analyse de données et génération de connaissances

Une fois les données agricoles collectées et prétraitées, elles peuvent être soumises à des **analyses statistiques et computationnelles** dans le but de produire des informations utiles à la prise de décision. L'objectif principal de cette phase est de **transformer les données brutes en connaissances exploitables**, capables d'orienter les pratiques agricoles de manière plus efficace et durable (Wang et al., 2020).

Les techniques utilisées varient selon les objectifs visés, mais on distingue généralement :

- **L'analyse descriptive** : permet de résumer les données à l'aide de statistiques simples (moyennes, écarts-types, tendances saisonnières). Elle est utile pour comprendre les conditions générales d'une parcelle, d'une culture ou d'un troupeau.
- **L'analyse diagnostique** : vise à comprendre les causes des événements observés (ex. : pourquoi un champ présente un faible rendement ou une maladie).
- **L'analyse prédictive** : repose sur des modèles d'apprentissage automatique pour anticiper des situations futures, comme l'apparition d'un stress hydrique, le rendement d'une culture ou la prolifération d'un ravageur (Liakos et al., 2018).
- **L'analyse prescriptive** : va plus loin en proposant des recommandations optimales (quantité d'engrais à appliquer, planification de l'irrigation, etc.).

Parmi les outils mobilisés, on retrouve les algorithmes de **régression linéaire ou logistique**, les **arbres de décision**, les **forêts aléatoires (Random Forest)**, les **machines à vecteurs de support (SVM)**, ou encore les **réseaux de neurones profonds** (deep learning), en particulier pour l'analyse d'images agricoles issues de drones ou de capteurs multispectraux (Kamilaris & Prenafeta-Boldú, 2018).

L'analyse de données contribue aussi à **l'identification d'indicateurs agronomiques** tels que les besoins nutritionnels, les taux de croissance, l'indice de végétation (NDVI), les zones à haut risque sanitaire, etc. Ces indicateurs peuvent ensuite être visualisés sous forme de cartes, graphiques ou tableaux de bord pour faciliter la décision à l'échelle de la parcelle, de l'exploitation ou du territoire (Tsouros, Bibi, & Sarigiannidis, 2019).

Cependant, pour que cette transformation de données en connaissances soit efficace, il est crucial que les outils soient **compréhensibles et accessibles** aux agriculteurs, même ceux ayant un faible niveau de technicité. D'où l'intérêt de

développer des **interfaces conviviales** et des systèmes d'aide à la décision intégrés dans des applications mobiles, adaptées aux réalités du terrain dans les pays en développement.

4.4. Mise en place d'un modèle d'apprentissage automatique pour la prédiction de rendement du maïs

Dans le cadre de cette recherche, nous avons mis en œuvre un modèle d'apprentissage automatique visant à prédire le rendement du maïs, culture de base dans de nombreux pays en développement, en nous appuyant sur des données ouvertes fournies par la FAO (2023). Cette expérimentation permet de démontrer la faisabilité d'une approche intelligente pour maximiser la productivité agricole à l'aide du Machine Learning.

4.4.1. Objectif du modèle


L'objectif principal est de prédire les rendements de maïs (en tonnes par hectare) à partir de variables explicatives telles que les précipitations annuelles, la température moyenne, la surface cultivée, les apports d'engrais, et l'irrigation. Ces variables constituent des facteurs clés influençant directement les performances agricoles.

4.4.2. Collecte des données

Les données utilisées proviennent de la plateforme FAOSTAT (FAO, 2023), qui met à disposition des informations statistiques sur la production agricole mondiale. Nous avons sélectionné des séries temporelles concernant :

- les rendements de maïs,
- les surfaces cultivées,
- les apports d'engrais,
- les pratiques d'irrigation,
- et les indicateurs climatiques (température, précipitations).

L'analyse a porté sur les données de la République Démocratique du Congo (RDC), avec possibilité d'élargir à d'autres pays.



Site FAOSTAT

4.4.3. Prétraitement des données

Les données ont été nettoyées afin de supprimer les valeurs manquantes et les doublons. Une normalisation Min-Max a été appliquée pour homogénéiser les échelles des variables. Des visualisations graphiques ont permis de détecter des corrélations et d'éventuelles anomalies.

Aperçu après nettoyage :

	Yield	CultLand	CropCultLand	Acre	1appDaysUrea	2appDaysUrea	MineralFertAppMethod.1	Harv_hand_rent
59	300	22	22	0.227273	15.0	30.0	0	600.0
257	240	15	15	0.181818	15.0	30.0	0	600.0
467	110	2	2	0.090909	15.0	30.0	0	300.0
1148	120	2	2	0.090909	15.0	30.0	0	300.0
1483	400	30	10	0.227273	30.0	18.0	0	2.0

[5 rows x 9 columns]

Active Windows
Activez les paramètres pour activer Windows.

4.4.4. Choix et entraînement du modèle

Nous avons opté pour un modèle de régression linéaire multiple, simple à interpréter et efficace dans ce contexte. Les étapes réalisées sont :

- la séparation des données en jeu d'apprentissage (70 %) et de test (30 %),
- l'entraînement du modèle sur les données connues,
- et la prédiction des rendements sur les données de test.

L'entraînement a été réalisé en Python avec la bibliothèque scikit-learn. Le modèle a été évalué avec des métriques telles que le coefficient de détermination (R^2) et l'erreur quadratique moyenne (RMSE).

```
Dimensions des jeux de données :
X_train : (13, 34)
X_test  : (4, 34)
y_train : (13,)
y_test  : (4,)
```

4.4.5. Résultats et interprétation

Les prédictions montrent une bonne correspondance avec les rendements réels observés. La température et l'irrigation apparaissent comme des facteurs prédictifs dominants. L'analyse révèle également les marges d'optimisation possible selon les conditions climatiques.

Nous avons bien lancé nos codes et obtenu les métriques d'évaluation pour deux modèles différents : Régression Linéaire

```
=== Évaluation du modèle : Régression Linéaire ===
MAE : 41.578368164484885
RMSE: 42.27676950054622
R²   : 0.9795266295601109

=== Évaluation du modèle : Random Forest ===
MAE : 117.30000000000001
RMSE: 200.00913729127478
R²   : 0.5417679839633447
PS C:\Users\LENOVO>
```

et Random Forest. Voici l'interprétation des résultats que nous avons dans la Figure 4.4.5.1 :

- **Régression Linéaire**

- **MAE (Mean Absolute Error) : 41.57**

→ En moyenne, ton modèle se trompe d'environ **41 unités** (dans l'échelle de ta variable cible).

- **RMSE (Root Mean Squared Error) : 42.27**

→ L'erreur quadratique moyenne est très proche du MAE, ce qui veut dire qu'il n'y a pas de grosses erreurs extrêmes.

- **R² (Coefficient de détermination) : 0.9795 ≈ 98 %**

→ C'est **excellent** : ton modèle explique environ **98 % de la variance** des données.

Conclusion : La régression linéaire est très performante sur le jeu de données.

➤ **Random Forest**

- **MAE : 117.3**

→ En moyenne, le modèle se trompe de 117 unités, donc **3 fois plus que la régression linéaire**.

- **RMSE : 200.0**

→ Les erreurs sont assez grandes et dispersées.

- **R² : 0.54 (≈ 54 %)**

→ Le modèle n'explique que la moitié de la variance, ce qui est beaucoup moins bon.

Conclusion : La Random Forest est nettement moins adaptée à ces données.

➤ **Interprétation globale**

- Le dataset semble **fortement linéaire** → la régression linéaire s'en sort très bien.
- La Random Forest, qui est plus flexible, n'arrive pas à capter une structure meilleure que la régression linéaire. Elle peut même **sur-apprendre ou mal généraliser** selon la taille et la nature de ces données.

Ici nous avons montré qu'un **modèle de Machine Learning simple (régression linéaire)** peut être **très efficace** pour prédire la productivité agricole.

En le reliant ainsi, l'IA (Machine Learning) et l'IoT (collecte automatisée de données) nous proposons une approche d'**optimisation de la productivité agricole**.

4.4.6. Limites du modèle

Le modèle est limité par la qualité des données et l'absence de données IoT en temps réel. De plus, la régression linéaire ne capture pas toujours les interactions non linéaires complexes. Une perspective future serait l'utilisation de modèles plus avancés comme les réseaux de neurones ou les forêts aléatoires.

Conclusion

Pour tout dire, l'agriculture se trouve aujourd'hui à un tournant décisif dans le pays en développement : entre des défis structurels persistants (changement climatique, faible productivité, pertes post-récolte, manque de ressources) et des opportunités technologiques inédites offertes par l'IA et l'IoT (Internet des Objets). Les résultats de notre étude confirment que des modèles d'apprentissage automatique, même simples comme la régression linéaire, peuvent fournir des prédictions fiables des rendements agricoles, ouvrant la voie à une meilleure planification et une gestion optimisée des ressources.

Ces performances démontrent que l'Intelligence Artificielle peut constituer un levier puissant pour maximiser la productivité agricole, à condition que son adoption soit accompagnée d'une intégration progressive et adaptée aux réalités locales : accessibilité des technologies, formation des acteurs ruraux, infrastructures numériques et politiques publiques incitatives.

Ainsi, l'association entre Machine Learning et IoT ne doit pas être considérée comme un luxe réservé aux pays industrialisés, mais comme une **opportunité stratégique pour renforcer la sécurité alimentaire, accroître la résilience des communautés rurales et stimuler un développement économique durable** dans les pays en développement, notamment en Afrique subsaharienne.

Authors



Erick NGINDU Beya, Assistant à la Faculté d'informatique, UKA.