

# CHECKLIST WEHUBIT INTELLIGENCE ARTIFICIELLE

Quelles sont les conditions préalables à la mise en œuvre d'une innovation sociale numérique recourant à l'apprentissage automatique \* ?


© Makerere University

En 2021, Wehubit entamait une trajectoire d'échange et de partage des capacités autour de l'intelligence artificielle, en collaboration avec AI for Social Good Dagstuhl Seminar. Trois organisations ont été au bout de cette trajectoire : **D-tree International**, **TechnoServe** et **AirQo**.

**Que garder de leurs expériences ?** Après trois ateliers en ligne, le premier groupe de travail du KEN publie une **checklist sur les conditions préalables à la mise en œuvre d'une innovation numérique recourant à l'apprentissage automatique !**










\* **L'apprentissage automatique** est un sous-ensemble de l'intelligence artificielle et de l'informatique qui se concentre sur l'**utilisation de données** et **d'algorithmes** pour imiter la façon dont les humains apprennent, en améliorant progressivement sa précision. Grâce à l'utilisation de méthodes statistiques, les algorithmes sont formés pour effectuer des **classifications** ou des **prédictions**, et pour découvrir des **informations clés** dans les projets d'extraction de données.



## IA sur la bibliothèque en ligne Wehubit

Uniquement en Anglais.

La version numérique donnant accès aux différents liens est disponible sur le lien suivant : [www.wehubit.be/e-library](http://www.wehubit.be/e-library).

-  Artificial intelligence and the circular economy: AI as a tool to accelerate the transition
-  Artificial Intelligence in Global Health: Defining a Collective Path Forward
-  Ethics and Governance of AI for Health
-  Towards a research program Artificial intelligence and human development
-  Managing machine learning projects in international development a practical guide
-  The AI Ethics Playbook Implementing ethical principles into everyday business
-  Report from Dagstuhl Seminar

## PROJET 1 : CARTOGRAPHIE DES ZONES DE PRODUCTION ASSISTÉE PAR DRONES POUR UNE PRODUCTION DE NOIX DE CAJOU - CAJULAB

Le projet CajùLab a analysé les zones de production de noix de cajou à l'échelle nationale - en **identifiant les différentes zones** et en dressant un état des lieux de la filière anacarde - et au niveau des **plantations** - en identifiant l'**état sanitaire** des parcelles et les **pratiques de gestion foncière**. L'objectif était de fournir des informations sur la filière anacarde grâce à des données de qualité, et donc de **permettre aux décideur·euses politiques** et aux **services de formation d'adapter les ressources** et **les services aux petites exploitations**.


Le projet s'est appuyé sur des images par **drones** et **satellites**, analysées par une **structure d'apprentissage profond\***. Cette structure a utilisé à la fois des informations relatives à la texture - à quoi **ressemble l'anacardier** - et des informations temporelles - comment **l'anacardier évolue** pendant sa période de croissance - pour identifier les anacardières et les **pratiques agricoles/de gestion foncière** (exemples : anacardières d'autres espèces, densité des arbres).

 **BÉNIN**

 Par TechnoServe

 Du 06/2019 à 09/2021

 ODDs  

 349.238€

 **Pour en savoir plus**  
Découvrez leur fiche d'apprentissage

Ces données produites ont été valorisées et diffusées dans :

Un **tableau de bord de télédétection en ligne** conçu pour des décideur·euses politiques et des organismes de formation 

Un **Plan d'action relatif à la production climato-intelligente de noix de cajou** afin d'étendre les pratiques agricoles durables à 11.000 producteurs et productrices d'anacardes. 



\* **L'apprentissage profond** est un sous-ensemble de l'apprentissage automatique. L'apprentissage profond peut analyser **des images, des vidéos et des données non structurées** d'une manière que l'apprentissage automatique ne peut pas facilement faire.

## PROJET 2 : UTILISATION DE L'APPRENTISSAGE AUTOMATIQUE POUR PERSONNALISER ET AMÉLIORER LA SANTÉ PÉRINATALE À ZANZIBAR

Le projet avait pour objectif d'aider les **volontaires de la santé communautaire** (VSC) à **identifier les femmes enceintes présentant un risque élevé de complications périnatales**, afin de leur offrir des visites supplémentaires et ciblées à domicile pour discuter des **facteurs de risque** et **des stratégies d'atténuation**.


Lors de l'identification d'une nouvelle femme enceinte dans la zone de desserte, le ou la VSC l'a inscrite - après avoir reçu son consentement - à **Jamii ni Afya, le programme national de santé communautaire de Zanzibar**, en utilisant une application pour smartphone. Le ou la VSC a recueilli des **données démographiques, des données sur les grossesses antérieures** et **les conditions de santé** et, sur la base de ces données, un modèle d'apprentissage automatique a estimé si la femme est **plus à risque de décès de son fœtus en cours de grossesse**. Les résultats du modèle ne sont pas communiqués au CHV ou à la femme enceinte en tant que tels. S'il estime un risque plus élevé, l'application programme des visites supplémentaires.

 **TANZANIE**

 Par D-tree International

 Du 12/2019 à 05/2022

 ODDs 

 349.887€

 **Pour en savoir plus**  
Découvrez leur fiche d'apprentissage

## PROJET 3 : MISE À L'ÉCHELLE D'UN SYSTÈME PARTICIPATIF ET CITOYEN DE MESURE ET D'ANALYSE DE LA POLLUTION ATMOSPHÉRIQUE POUR LA RÉSILIENCE URBAINE EN OUGANDA - AIRQO


Le projet AirQo vise à fournir un **accès rapide** et **hyperlocal** aux informations sur la qualité de l'air pour **les habitant-es** et **les décideur-euses politiques** dans les villes ougandaises, leur permettant ainsi de prendre des mesures pour **améliorer la qualité de l'air** dans leurs communautés. **80 capteurs conçus** et **fabriqués localement** à la Makerere University ont été déployés (ce réseau sera élargi à **150** appareils à la fin du projet) pour recueillir des données sur la pollution atmosphérique en temps quasi réel.



 **UGANDA**

 Par Makerere University

 Du 04/2021 à 03/2023



 ODDs

 342.000€

 **Pour en savoir plus**  
 Découvrez leur pages web  
ou leur app

Les données sont diffusées par le biais d'une **plateforme web** et d'une **application mobile** sur la qualité de l'air. AirQo intègre l'apprentissage automatique dans ses produits à des fins de :

**Prévisions spatio-temporelles** : l'apprentissage automatique est utilisé pour prévoir la qualité de l'air dans les 24 heures à venir afin d'éclairer les **décisions individuelles en vue de minimiser l'exposition**. Les prévisions sont disponibles pour tous les sites de surveillance actifs du réseau AirQo, mais l'apprentissage automatique est également utilisé pour **prédire/estimer** les niveaux de qualité de l'air dans des emplacements autour des villes, non dotés d'un système de surveillance de la qualité de l'air à des moments spécifiques. Ces prévisions sont utilisées pour générer des **cartes thermiques**.

**Étalonnage \* des données du capteur** : pour améliorer la **précision des données**. Les modèles d'apprentissage automatique sont utilisés pour calibrer les données des appareils de surveillance de la qualité de l'air à faible coût afin d'améliorer **leur précision et leur fiabilité**, et de faire en sorte que leurs relevés soient aussi proches que possible des **normes de référence internationales**. Le modèle d'étalonnage par apprentissage automatique est désormais un produit qui peut être utilisé par tout le monde pour étalonner les données des capteurs de faible puissance.  Découvrez comment AirQo utilise l'apprentissage automatique pour l'étalonnage dans son récent document de recherche. 

**Optimisation de l'emplacement des capteurs** : l'apprentissage automatique est utilisé pour l'emplacement optimal des capteurs.



\* **L'étalonnage** désigne le processus de comparaison et de correction des sorties de mesure d'un dispositif par rapport aux sorties d'un **dispositif de référence standard accepté au niveau international**. L'étalonnage des données accroît la précision et la fiabilité des résultats du modèle.



Cette checklist vise à informer et à soutenir les chef-fes de projet ou les équipes qui envisagent d'**introduire l'apprentissage automatique** pour appuyer (une partie de) s activités de leur organisation.

Elle énumère **9 questions importantes** qui ont été collectivement soulevées par les projets de Wehubit concernés, illustrées par **leurs propres leçons apprises** concernant trois aspects clés qui doivent être mis en place avant d'introduire l'IA : **organisations, données et utilisateur-rices finaux-ales et bénéficiaires ultimes**.

## ORGANISATIONS

---

### 1. Mener une phase pilote avant la mise en œuvre réelle et tester une preuve de concept (Proof of Concept) ✓

La mise en œuvre d'une innovation numérique avec une composante d'apprentissage automatique nécessite une préparation minutieuse pour plusieurs raisons. Avant tout, il convient de prévoir une phase pilote, au cours de laquelle une **preuve de concept est testée dans l'environnement local**. L'intelligence artificielle étant encore relativement nouvelle dans le contexte de la coopération internationale et traitant de grandes quantités de données, **elle suscite encore des interrogations, voire de la méfiance**. Les projets doivent apporter la preuve du potentiel des outils d'apprentissage automatique pour induire un changement dans divers secteurs et montrer leur valeur ajoutée.

Selon le secteur et le projet, les preuves de concept peuvent avoir des dimensions et des objectifs différents – que devons-nous montrer ? Outre les objectifs généraux d'une preuve de concept, à savoir démontrer la viabilité et la faisabilité, la réalisation d'une phase pilote pour un projet d'intelligence artificielle permet d'instaurer la **confiance avec les parties prenantes**, notamment les gouvernements, et d'**obtenir leur adhésion d'entrée de jeu**.

Les phases pilotes permettent **aux projets de mieux évaluer les ressources nécessaires à une mise en œuvre réussie**, et **de mieux comprendre** préparer et traiter les données pour répondre aux besoins du modèle d'apprentissage automatique.

**D-tree** a développé un modèle d'apprentissage automatique basé sur des données représentant l'ensemble du pays. Il a cependant commencé par un petit projet pilote dans deux des onze districts de **Jamii ni Afya** afin de prouver que le modèle d'apprentissage automatique, en sus de l'intervention des agents de santé communautaire (ASC), était **efficace**.

La preuve de concept devait montrer que le modèle prédictif **pouvait fonctionner hors ligne sur un téléphone à ressources faibles ou moyennes** et pouvait être utilisé pour cibler une intervention en matière de santé. L'évaluation a montré que l'apprentissage automatique pouvait effectivement être utilisé avec succès, bien qu'il n'y ait pas de différence statistiquement significative dans l'utilisation du modèle combiné au **travail des ASC, comparé au travail des ASC seul-es**. Autrement dit, l'utilisation de l'apprentissage automatique n'a pas mené à une amélioration des soins.



## 2. Engager en interne du personnel capable de parler aussi bien le langage thématique que technique ✓

Lorsqu'il s'agit de trouver les compétences appropriées, la première étape consiste à identifier **les besoins et les lacunes en compétences à combler**. Pour être couronné de succès, le projet aura besoin d'une expertise thématique et technique, et d'un personnel capable de « parler les deux langues »; il s'agit généralement d'un·e ou de plusieurs **spécialistes des données** ou **ingénieur·es informaticien·nes**, qui guideront le projet et auront une vision globale.

La ou les personnes qui font le lien entre les questions thématiques et techniques, seront de préférence des membres du personnel interne. Ce personnel est chargé de s'assurer que le(s) modèle(s) d'apprentissage développé(s) **répond(ent) aux besoins du projet**; il peut entreprendre des **discussions techniques internes** et/ou **externes** pour orienter le projet et être un **point de contact commun** pour les diverses parties prenantes.

## 3. Assurer les compétences techniques, sur la base d'une stratégie à long terme ✓

La décision d'acquérir les compétences techniques nécessaires pour développer et gérer le(s) modèle(s) d'apprentissage automatique en interne ou d'obtenir ces compétences par le biais de partenariats doit être en lien avec la **stratégie à long terme de l'organisation**. Trois aspects principaux doivent être pris en compte (1) L'intention de l'organisation de **continuer à implémenter des projets dans un secteur spécifique** (2) La **sensibilité des données dans ce secteur** (3) La volonté d'investir et de continuer à travailler **avec des composants d'apprentissage automatique pour atteindre les objectifs de l'organisation**.

Si le projet/organisation décide d'aller **chercher des compétences en externe**, il est possible de nouer des partenariats avec des **universités internationales et/ou locales**, ce qu'ont fait les trois projets Wehubit. Travailler avec des universités offre plusieurs avantages :

Les universités recherchant des **possibilités de « tester » leur travail**, d'agir en tant que centre de connaissances et de publier, c'est donc une collaboration gagnant-gagnant.

Les données et le(s) outil(s) numérique(s) sont soit la propriété du projet, soit celle des universités elles-mêmes. Ceci garantit que les étudiant·es pourront continuer **à développer et à adapter l'outil à long terme**, favorisant l'**appropriation et la durabilité du(des) outil(s) numérique(s)**, ce qui n'est pas forcément le cas avec le secteur privé (voir Propriété des données infra).

Cela renforce les compétences locales et permet le **développement d'un écosystème numérique** en impliquant au fil du temps de nombreux·euses étudiant·es, créant ainsi dans le pays un **pool considérable de personnes** ayant des compétences en apprentissage automatique.



L'équipe d'**AirQo** est basée dans l'Université de Makerere – Kampala. L'ensemble du personnel technique, y compris l'unité de production des capteurs de qualité de l'air et les expert-es en intelligence artificielle, est du **personnel interne**, dont certain-es membres sont d'ancien-nés étudiant-es et stagiaires. Pour AirQo, avoir le personnel en interne permet une plus **grande flexibilité et adaptabilité** : l'équipe est **prête, informée et formée**, dès qu'il y a un changement à faire ou une maintenance à effectuer. Il s'avérerait de même plus onéreux pour le projet d'externaliser toutes les tâches de maintenance.

AirQo demeure une organisation **apprenante** qui s'appuie sur des échanges de connaissances externes.

- Elle tire parti du **réseau étudiantin** en les impliquant dans les réflexions (p. ex., organisation d'Hackathons) ou en les prenant comme stagiaires.
- Elle travaille avec des **acteurs externes** dans le cadre de partenariats et de mentorats formels ou informels, comme la société DeepMind de Google ou l'Université de Sheffield.
- Elle a recours à des **plateformes communautaires ouvertes d'apprentissage automatique**, telles que Zindi, qui permet d'exposer un problème et de discuter de la solution avec la communauté, **afin d'obtenir un feedback et de rassembler des connaissances**. En ce qui concerne son modèle prévisionnel, AirQo a développé un modèle en interne avant de mettre Zindi au défi. Après avoir évalué les trois meilleures solutions, elle les a intégrées au modèle.

**D-tree** s'est associée à **N/LAB**, un centre d'excellence en analyse comportementale de l'**Université de Nottingham**. N/LAB a créé le modèle d'apprentissage automatique et aidé D-tree à l'adapter en vue d'une utilisation dans l'application des ASC. Au cours du projet, D-tree a également renforcé ses capacités internes, mais considère toujours utile de faire appel à des partenaires externes comme N/LAB, en particulier pour les techniques d'apprentissage automatique de pointe qui nécessitent une **expertise très spécialisée**. Afin de pérenniser davantage les solutions d'apprentissage automatique à l'échelon local, y compris au-delà du travail de D-tree, cette dernière entame à présent des **partenariats avec des universités locales**.

**CajùLab** a noué des partenariats avec des universités afin de trouver les **compétences techniques requises**.

Le domaine de l'apprentissage automatique n'étant pas encore bien développé au Bénin, CajùLab s'est alliée à l'**Université du Minnesota** pour développer son algorithme.

Pour ce qui est du développement et de la maintenance du tableau de bord convivial, utilisé par les agent-es de l'État et les services de formation, CajùLab a entamé une collaboration avec l'**Université de Parakou et l'Institut de Mathématiques et de Sciences Physiques de Dangbo**.

Dans l'optique de s'associer à une université locale, CajùLab a soigneusement analysé le contexte local de la mise en œuvre et identifié des universités comptant un **département IT** dynamique, avec des professeur-es disposé-es à s'impliquer. Elle a formé les étudiant-es en informatique au développement et à la maintenance, ce qui a permis un transfert de compétences et une **appropriation locale** de l'outil numérique.



# DONNÉES

## 4. Vérifier que la législation locale fournit un cadre juridique régissant la gouvernance \* et la confidentialité des données ✓

Il est indispensable de s'assurer que le cadre juridique local du pays de mise en œuvre régisse **la gouvernance** et **la confidentialité des données**, tout particulièrement si l'on opère dans un **contexte fragile** et/ou **avec des données sensibles**. Le risque inhérent à la mise en œuvre d'un projet incluant une composante d'apprentissage automatique sans aucun cadre juridique est d'être **mis à l'arrêt par le gouvernement** par manque de confiance.

En l'absence de cadre juridique dans le pays de mise en œuvre, le projet peut s'efforcer de **créer un environnement favorable et d'instaurer la confiance**. Avant toute chose, il est important d'avoir une sorte d'**accord** avec des **acteurs étatiques** - clairement identifiés - et/ou le **gouvernement**, et de s'assurer qu'ils soutiennent le projet. Si la confiance est bien installée avec les partenaires étatiques, elle peut aussi en fin de compte permettre d'exercer un **plaidoyer en faveur d'un cadre juridique**.

Un autre élément à l'appui d'un environnement favorable et de la confiance est la référence à des **cadres formels ou informels, des lois** et/ou **des bonnes pratiques**, qui peuvent émaner du niveau national, régional ou international. Ces références peuvent servir de base à l'élaboration d'un cadre interne (au niveau organisationnel) selon lequel les **données sont réglementées**.



\* **La gouvernance des données** a de nombreuses définitions et est considérée ici comme des **dispositions institutionnelles formelles ou informelles** régissant la **propriété des données; les procédures/protocoles de collecte, de stockage, d'accès et de partage des données** - ainsi que le **processus de décision et de contrôle de ces procédures** -; la confidentialité et la sécurité des données; la pratique consistant à s'assurer que les données peuvent être utilisées efficacement par les personnes qui peuvent en tirer de la valeur, tout en respectant à tout moment le **droit à la vie privée des individus et des communautés**.


En raison de la sensibilité des données sanitaires, un **partenariat avec le gouvernement** s'avère essentiel. Toutefois, **D-tree** a mis en œuvre le projet **Wehubit** en Tanzanie, où, au moment de sa mise en œuvre, il n'existait **aucun cadre juridique régissant les données**. Au cours du projet, elle a créé son propre cadre qui précisait la gouvernance des données ainsi que la manière de contrôler l'adhésion audit cadre et de **responsabiliser les parties prenantes**. D-tree a travaillé en étroite collaboration avec les partenaires gouvernementaux (c.-à-d. des responsables opérationnels jusqu'au Secrétaire Principal) afin de garantir la conformité du cadre à leurs attentes. Elle a en outre soumis une **proposition au National Ethics Review Board** (avec des partenaires du programme gouvernemental en tant que co-investigateurs).

**AirQo** s'appuie sur la loi ougandaise de **protection** et de **confidentialité des données** (Data Protection and Privacy Act) pour garantir la confidentialité des données. Il s'agit d'un outil de référence assurant la sécurité des données des parties prenantes. Par exemple, afin de préserver la vie privée des personnes et des institutions qui accueillent les dispositifs de surveillance, et de prévenir les risques d'utilisation abusive des dispositifs, les coordonnées réelles de l'emplacement des moniteurs de la qualité de l'air sont ajustées à distance de manière à ce que la **zone de surveillance soit connue sans révéler l'emplacement exact du moniteur**.



## 5. Définir des directives claires sur *qui fait quoi* en matière de propriété, d'utilisation et de confidentialité des données, qui peuvent être partagées et approuvées ✓

Outre un cadre juridique, il est important de nouer un accord clair avec le gouvernement et/ou d'autres parties prenantes sur la **propriété des données, leur utilisation et leur durabilité**. Ces aspects doivent être abordés et faire l'objet d'un **accord mutuel** avant le début du projet.


Un **accord clair** garantira une **utilisation responsable des données**, conformément au principe « ne pas nuire »  en particulier lorsqu'il s'agit de données personnelles et sensibles. Cet accord garantit par ailleurs la **transparence** aux utilisateur·rices et aux personnes auprès desquelles sont collectées les données.

*AirQo est propriétaire des données sur la qualité de l'air, mais elles sont disponibles gratuitement pour toute personne qui en fait la demande et y accède via la **plateforme** et qui accepte l'**accord d'utilisation des données**. En outre, tout le monde peut y accéder avec certaines des autres plateformes d'AirQo, comme l'application mobile, le site web et l'**API** (application programming interfaces). L'utilisateur·rice de ces données, dans le cadre de l'accord d'utilisation des données, est tenu·e de **créditer / référencer / attribuer** AirQo en tant que source primaire originale. AirQo a par ailleurs élaboré des protocoles d'accord avec ses partenaires et les parties prenantes du projet (PNUD, autorités de la capitale Kampala, ministères...), dans lesquels ils conviennent, entre autres, du **partage des informations** et **de la confidentialité des données**.*

*D-tree avait déjà la pleine propriété d'un **ensemble de données historiques**. Toutefois, elle n'a pas été en mesure, durant le cycle de vie des projets de Wehubit, de formaliser l'appropriation avec le gouvernement concernant l'ensemble de données actuelles (c.-à-d. les données du programme national de santé communautaire du gouvernement), comme il n'y avait **pas de cadre régissant le partage de données**. Cela a empêché la mise à jour du modèle pendant le projet.*

*Le gouvernement béninois disposait d'un **cadre juridique applicable à la gouvernance des données** sur la base duquel **TechnoServe** a élaboré une politique interne relative à la confidentialité des données incorporant le **tableau de bord** et **des données d'utilisation plus spécifiques**. Il n'empêche que les données collectées au moyen d'une cartographie par drones et satellites - **comme le nom des propriétaires de plantations, leurs emplacements, leurs rendements** - ne sont pas encore incluses dans leur politique relative à la confidentialité des données.*

## 6. Assurer que l'ensemble de données soit inclusif et prendre en compte les biais potentiels ✓

Les projets doivent s'efforcer de disposer de la base de données **la plus représentative possible** au vu de la portée du projet et du principe « **Ne laisser personne de côté** » . En d'autres termes, les **groupes sous-représentés doivent avoir les mêmes chances d'être inclus** dans le projet et la base de données doit, dans la mesure du possible, permettre d'identifier ces groupes et de prendre des mesures factuelles pour améliorer leur situation. Si le projet ne peut pas avoir de **couverture complète** et même si les groupes sous-représentés ont été pris en compte, le risque de biais potentiel doit être envisagé et des **discussions régulières** entre les partenaires sur la façon de répondre à ces risques doivent être organisées dès le début du projet.





Un des défi résidait dans la prise en compte les personnes difficiles à atteindre afin d'être **le plus inclusif et représentatif possible**. Et même si **D-tree** était consciente des biais présents, il était difficile de les traiter. Ainsi, D-tree a collecté des données concernant des variables de substitution pour le statut socioéconomique (par exemple, le toit, le matériau du plancher), mais n'a pas encore été en mesure d'évaluer d'autres prédicteurs du comportement en matière de **recours aux soins qui répondent à certaines faiblesses des modèles de statut socioéconomique**.

Pour ses moniteurs de la qualité de l'air, **AirQo** a choisi des sites représentatifs qui reflètent les diverses variations de l'environnement physique, telles que la **répartition de la population** (p. ex., forte densité de population par rapport à faible densité de population, zones commerciales par rapport aux zones résidentielles), l'occupation des sols...

AirQo a fourni des informations **aux autorités locales et aux communautés** sur la localisation des moniteurs de la qualité de l'air afin de permettre aux diverses parties prenantes d'apprécier les lacunes et les solutions possibles. L'**engagement des parties prenantes** et les **discussions** sur les questions en jeu contribuent à créer une synergie et ouvrent la voie à de **nouvelles interactions** et à **une plus grande inclusion**. Lorsqu'il s'agit de déterminer et de décider où placer des moniteurs de qualité de l'air, AirQo collabore par exemple avec l'équipe de direction locale.

Pour élaborer son tableau de bord et décider des cultures à cartographier et à analyser, **CajùLab** a utilisé les **bases de données d'enregistrement des agriculteur-rices** et les **enquêtes de rendement annuelles de TechnoServe**. Il s'est avéré que le **pourcentage de femmes propriétaires de plantations d'anacardes était assez faible par rapport à celui d'hommes**. Les femmes ont en effet un accès limité à la terre et les bases de données d'enregistrement sont élaborées sur la base de la propriété foncière (et non de l'occupation du sol).

## 7. Assurer que les données soient précises, cohérentes et valables ✓

Pour que le modèle d'apprentissage automatique soit utile, les données recueillies doivent être de **grande qualité, utilisables, et répondre aux besoins dudit modèle**. Cela signifie :

Les données permettront au modèle d'atteindre un haut niveau de **précision**. Cela signifie que les mesures prises correspondent à **ce qui est censé être mesuré**.

Les données ne présentent pas de valeurs aberrantes; en d'autres termes, **elles se situent dans la fourchette de valeurs attendues**. Cette dernière est définie avant d'entamer les processus de collecte de données.

L'ensemble des données est suffisamment grand pour être représentatif. Pour pouvoir faire des prévisions valables, l'ensemble de données doit être suffisamment grand pour représenter tous les scénarios possibles à prévoir, avec **des caractéristiques et une qualité suffisantes**. Le modèle doit être capable de comparer les scénarios potentiels.

Les données proviennent d'une **source fiable**. Elles sont exhaustives et garantiront un haut niveau de précision. Les sources de données doivent être réutilisables et complémentaires.



Lors de l'exécution d'un modèle d'apprentissage automatique, la source des données à utiliser est importante pour **obtenir des données de qualité**. Pour sa **collecte de données par drone**, **CajùLab** a noué un partenariat avec une organisation baptisée AtlasGIS, qui a contribué à garantir des images qualitatives des plantations. Dans le cas de données sur les sols et les récoltes, CajùLab a, par le biais de l'équipe Suivi & Evaluation du projet BeninCaju, recueilli ces informations grâce à des **enquêtes annuelles dans toutes les zones d'intervention du projet**. Pour les données d'imagerie par satellites, CajùLab a choisi la constellation de microsattelites PlanetScope à haute résolution et à revisite rapide (moins d'un jour) comme **source de données**. La confidentialité des données est également l'un des aspects clés du projet CajùLab, car il traite les informations personnelles des producteurs et productrices d'anacardes dans les principales zones de production.

**D-tree** a abordé la qualité des données de trois manières différentes : (1) L'application des ACS est conçue avec des **contrôles du format des données et des règles de validation des données**; (2) Les valeurs aberrantes sont **surveillées** (p. ex., un nombre rapide ou élevé de visites sur un bref laps de temps); (3) Des **évaluations régulières de la qualité des données sont menées**, avec des contrôles ponctuels pour vérifier auprès des ménages s'ils ont effectivement reçu la visite d'un-e ASC et confirmer les informations collectées. En outre, un ensemble de données est soumis à un **nettoyage des données avant d'être utilisé comme entrée pour la modélisation de l'apprentissage automatique**.

Les données collectées passent par de **multiples étapes de validation et de nettoyage des données**, à partir du laboratoire où les dispositifs sont développés - à l'**Université de Makerere**. L'assurance qualité permet de s'assurer que les appareils répondent tous aux critères définis avant d'être **déployés sur le terrain**. Par la suite, les données brutes collectées passent par une série de contrôles de qualité avant d'être accessibles via la plateforme et d'être utilisées pour la **modélisation par apprentissage automatique**. Ces contrôles de la qualité des données comprennent des vérifications des valeurs aberrantes et hors limites, des vérifications de la corrélation entre deux capteurs, l'étalonnage pour s'assurer que l'ensemble des données est conforme aux normes de référence. En outre, l'équipe d'AirQo assure la **maintenance continue** des moniteurs de la qualité de l'air.

## UTILISATEUR-RICES FINAUX-ALES ET BÉNÉFICIAIRES ULTIMES

### 8. Définir clairement votre(vos) utilisateur-ric(e)s finaux-ale(s) ✓

Qui va utiliser les résultats obtenus? **Des chercheur-euses? Des décideur-euses politique-s? Des communautés? Et qui est la cible prioritaire?**

Différent-es utilisateur-rices finaux-ales requièrent **différentes façons de communiquer les résultats** produits par un modèle d'apprentissage automatique, si ceux-ci doivent être utilisés pour des activités ou des recherches ultérieures. Il est dès lors important de **définir clairement les utilisateur-rices finaux-ales**, car cela permet les éléments suivants.



- ▶ évaluer leurs **besoins**, notamment en termes de **maîtrise du numérique et des données**, et concevoir les outils en conséquence
- ▶ planifier leur éventuel **partage des capacités** pour qu'ils-elles puissent utiliser les informations produites
- ▶ les intégrer au projet et assurer une **meilleure adéquation entre les résultats du modèle d'apprentissage automatique et le développement de solutions appropriées**
- ▶ adapter le **langage utilisé** par le projet et développer différentes stratégies de communication
- ▶ instaurer la confiance et l'appropriation par une **communication appropriée à tous les**

Pour chaque projet, l'utilisateur-riche final·e prioritaire était différent·e des bénéficiaires ultimes. Cela implique qu'il y a eu différentes stratégies **sur la manière et le moment de présenter les résultats pour qu'ils soient exploitables et fiables.**

Ainsi par exemple, une prédiction basée sur l'apprentissage automatique et la recommandation qui en découle pourraient être présentées avec « **un niveau de confiance** » basé sur les attentes en matière de faux/vrais négatifs. Ou encore, la solution pourrait être conçue de manière à travailler sur la prédiction sans la mentionner, tout en éliminant/réduisant les effets néfastes.

*Les producteur·rices d'anacardes ne sont pas les utilisateur·rices de l'innovation sociale numérique, mais bien les **bénéficiaires ultimes**. Le tableau de bord - les résultats produits - a été utilisé par les **technicien·nes du ministère de l'Agriculture** pour prendre des décisions fondées sur des informations et par les prestataires de formation et les coopératives pour personnaliser leur soutien aux agriculteur·rices. **TechnoServe** s'attend également à ce que les **chercheur·euses et les étudiant·es de l'Université d'Abomey-Calavi utilisent les tableaux de bord comme source de données pour leurs recherches sur l'anacarde au Bénin.***

*L'identification de ces utilisateur·rices a permis de développer une plateforme axée sur les besoins (quel type d'information est nécessaire pour quoi faire?) et de partager les capacités sur les aspects numériques et techniques.*

*Les utilisateur·rices finaux·ales de **D-tree** comprennent les ASC, leurs superviseur·euses et les décideur·euses au niveau du district et au niveau central du ministère de la Santé. Les ASC et leurs superviseur·euses utilisent les applications numériques, tandis que le Ministère **utilisent les données produites**. Utilisateur·rices finaux·ales prioritaires, les ASC bénéficient d'une formation initiale, de cours de remise à niveau ainsi que d'un **appui permanent de mentors et superviseur·euses pairs**. Les ASC n'étant pas des professionnel·les de la santé, l'application les aide dès lors à prendre des décisions et à fournir une réponse standardisées aux **femmes enceintes**.*

*Les principaux·ales utilisateur·rices finaux·ales d'**AirQo** comprennent des décideur·euses et des leaders locaux·ales directement impliqués·es dans la politique. Il·elles utilisent les plateformes pour **guider l'élaboration de politiques**.*

*Les bénéficiaires ultimes (communautés, citoyen·nes) sont également impliqués·es dans certaines activités du projet, à savoir la formulation du problème dans **le contexte, la collecte de données, l'évaluation et le déploiement**.*

## 9. L'intelligence artificielle/l'apprentissage automatique est adapté(e) au problème identifié et les effets négatifs involontaires sont limités ou inexistantes ✓

Si l'apprentissage automatique offre un potentiel important, il se peut qu'un grand ensemble de données et un objectif valable ne suffisent pas pour développer un modèle adapté malgré qu'ils **respectent les principes « Ne pas nuire »** et **« Ne laisser personne de côté »**. Les outils d'apprentissage automatique doivent être évalués minutieusement selon le domaine de recherche et les **problématiques à traiter**, en répondant aux questions suivantes :

- ▶ Sera-t-il possible d'avoir une **grande précision** ? (nombre de vrais positifs et négatifs divisé par la taille de la population)
- ▶ Est-ce que ce sera **précis** ? (vrais positifs divisés par les positifs prévus)
- ▶ La **sensibilité - ou la mémorisation** seront-elles suffisantes ? (vrais positifs qui sont correctement identifiés)

Et donc, la valeur ajoutée l'emporte-t-elle sur les risques et les biais potentiels, notamment en ce qui concerne les **bénéficiaires ultimes** ? L'output de l'algorithme sera-t-il exploitable, p. ex., pourra-t-il induire une intervention efficace ?

L'output de **D-tree** du modèle d'apprentissage automatique est simplement «risque plus élevé estimé» ou «pas de risque plus élevé estimé». Le principal défi à relever par le projet était **le nombre élevé de faux positifs**. Le modèle était en effet calibré pour un faible nombre de faux négatifs, afin de ne pas passer à côté des **femmes réellement confrontées au décès infantile périnatal**. Le nombre de faux positifs a par conséquent augmenté.

Afin de ne pas soumettre ces femmes à des effets secondaires négatifs (p. ex., s'angoisser inutilement à propos du décès potentiel de leur enfant), **l'output du modèle (c.-à-d. la prédiction des risques) n'est pas communiqué aux ASC ou à la femme enceinte.**

En outre, une évaluation manuelle des risques a été effectuée, au cours de laquelle le ou l'ASC passe en revue une liste de conditions de santé pertinentes ainsi que d'autres questions. Cette évaluation manuelle a été incluse de sorte à se **prémunir contre tout biais ou un modèle d'apprentissage automatique autrement peu performant.**

**AirQo** fournit toujours des quantifications de l'incertitude et des niveaux de confiance lorsqu'il **communique les résultats des modèles d'apprentissage automatique**. En outre, lors du partage des résultats avec les utilisateur·rices finaux·ales ou les bénéficiaires ultimes, AirQo communique des informations neutres. Ainsi, au lieu de souligner que tel ou tel endroit est le plus pollué, il fera référence aux **niveaux recommandés par l'Organisation mondiale de la Santé.**

Cette fiche d'apprentissage a été produite dans le cadre du Réseau d'échange de connaissances de Wehubit avec la collaboration de Heiko Hornung, D-tree, Richard Sserunjogi, AirQo, Martin Boton, Seth Ogoe Ayim, TechnoServe et le soutien du Royal Tropical Institute (KIT)