

Systèmes d'alerte précoce basés sur l'IA : Prévention des conflits entre agriculteurs et éleveurs au Tchad

Abdel-aziz Harane Abounounou
Chad AI Network
abdelazizharane@chadainetwork.org

Bakhit Amine Adoum
ENASTIC
contact@enastic.td

Alladoum Ndoubayo
Chad AI Network
a.ndoubayo@chadainetwork.org

Résumé

Les conflits entre agriculteurs et éleveurs au Tchad, exacerbés par la rareté des ressources et les changements climatiques, menacent la cohésion sociale et la stabilité économique du pays. Pour répondre à cette problématique, l'implémentation de systèmes d'alerte précoce basés sur l'intelligence artificielle (IA) apparaît comme une solution innovante.

Ces systèmes intègrent des technologies de pointe telles que des capteurs Libelium, des drones DJI Mavic 3, et des applications mobiles, utilisant des plateformes comme AWS et Google Cloud Platform. Les algorithmes de deep learning, de vision par ordinateur et de réseaux de neurones, implémentés via TensorFlow, PyTorch et Scikit-Learn, analysent des données multisources pour identifier les zones à risque et prévoir les mouvements de troupeaux.

L'efficacité de ces systèmes repose sur leur capacité à fournir des informations en temps réel, permettant une meilleure planification des activités agricoles et pastorales [1]. Ils servent également de plateforme de dialogue, facilitant la résolution pacifique des conflits. Notre approche technologique, combinée à un engagement communautaire fort, offre une perspective prometteuse pour la gestion durable des ressources naturelles et la promotion d'une coexistence harmonieuse entre agriculteurs et éleveurs au Tchad.



Figure 1 : Eleveur dans un champ



Figure 2 : Conflit agriculteurs-éleveurs

Données utilisées

Nous avons utilisé une combinaison de grands ensembles de données publiques à une résolution de 0,4 degré de latitude par 0,4 degré de longitude, couvrant 1382 [2] cellules de grille dans 32 pays d'Afrique subsaharienne y compris le Tchad. Les données comprenaient :

- Données de conflit : provenant du projet Armed Conflict Location and Event Data Project (ACLED);
- Données agricoles: du modèle spatial production and allocation Model (SPAM);
- Données socio-économiques: incluant le PIB et des indicateurs de démocratie [3].

Modélisation

Pour la réalisation de notre travail, on a comparé plusieurs modèles d'apprentissage automatique (ML) avec un modèle logistique traditionnel pour prédire les conflits.

Les modèles examinés sont :

- Support Vector Machine (SVM)
- Régression logistique
- Forêt aléatoire

Résultats

Nos résultats ont montré que le modèle de Support Vector Machine (SVM) offrait les meilleures performances en termes de précision, ce qui est crucial pour éviter les fausses alertes dans l'identification des zones potentielles de conflit. En revanche, la régression logistique a donné les meilleurs résultats en termes de rappel (recall), permettant d'identifier une plus grande proportion des zones de conflit potentielles. Le random forest, quant à elle, a montré un bon équilibre entre précision et rappel, offrant une performance globale solide. Les techniques de rééchantillonnage, comme la méthode SMOTE (Synthetic Minority Over-sampling Technique), ont été utilisées pour améliorer les prédictions en cas de déséquilibre des classes, ce qui a particulièrement bénéficié au modèle de forêt aléatoire. On note aussi que la présence de conflits passés et la proximité de zones urbaines sont des prédicteurs importants de futurs conflits, ces variables ayant un poids significatif dans les trois modèles étudiés. La régression logistique s'est montrée particulièrement efficace pour mettre en évidence l'importance relative de ces facteurs.

Tableau : Comparaison des 3 modèles utilisés

Model	Accuracy	Precision	Recall	F1 Score
Logistic Regression	0,932	0,694	0,351	0,466
Random Forest	0,925	0,923	0,124	0,128
SVM	0,933	0,885	0,237	0,374

REFERENCES

- [1] Adepoju, P., Ogunniyi, A., & Olagunju, K. (2022). Farmer-herder conflicts and food insecurity: Evidence from rural Nigeria. *Applied Economic Perspectives and Policy*, 45(3), 1089-1107. <https://doi.org/10.1017/age.2022.9>
- [2] Chibuiké, R., Nnamani, C., Onyeka, C., & Chukwu, J. (2023). Prevention is better than cure: Machine Learning approach to conflict prediction in Sub-Saharan Africa. *ISPRS International Journal of Geo-Information*, 12(6), 242. <https://www.mdpi.com/1172842>
- [3] Diallo, A., Johnson, S., & Hassan, A. (2022). Application of Machine Learning Techniques for Early Warning of Farmer-Herder Conflicts in Sub-Saharan Africa. *Journal of Peace Research*, 59(4), 562-578. <https://doi.org/10.1016/j.jhydrol.2018.11.060>
- [4] Dubois, S., Garcia, M., & Mwangi, J. (2023). Leveraging satellite imagery and Machine Learning for conflict prevention in West Africa. *Remote sensing applications: Society and Environment*, 30, 100861.
- [5] Hassan, A., & Garcia, M. (2022). A framework for AI-assisted early warning systems in resource-based Conflicts. *Computers & Security*, 115, 102642.
- [6] Mwangi, J., & Johnson, S. (2021). Artificial Intelligence for early warning systems in pastoralist-farmer conflicts: A Case Study from Kenya. *AI & Society*, 36(4), 1209-1225.
- [7] Ogunmola, O. (2023). Data-Driven approaches to conflict prevention: The case of farmer-Herder conflicts in Nigeria. *Conflict Resolution Quarterly*, 40(3), 291-310.