

Générer des données de patients synthétiques grâce au machine learning: accélérer les études en vie réelle (RWE)

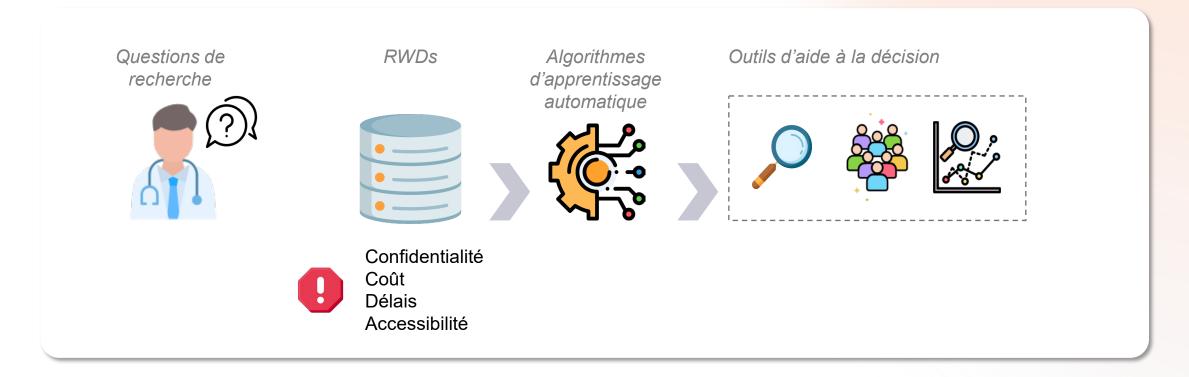
Margaux Törnqvist*, Louise Dry¹, Gaëtan Pinon¹, Antoine Movschin¹

¹Quinten Health – 8 rue Vernier, Paris – France

20 juin 2024

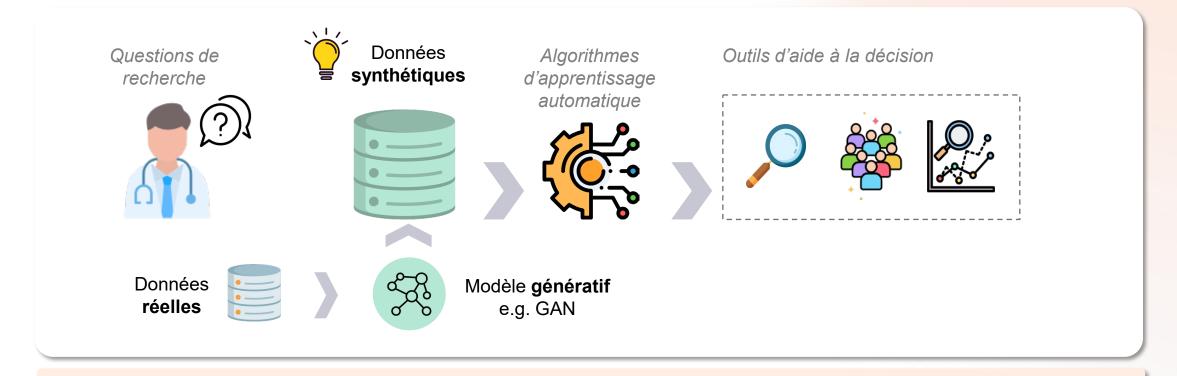
1

Une méthode de génération de données synthétiques de patients pour accélerer la recherche médicale





Une méthode de génération de données synthétiques de patients pour accélerer la recherche médicale

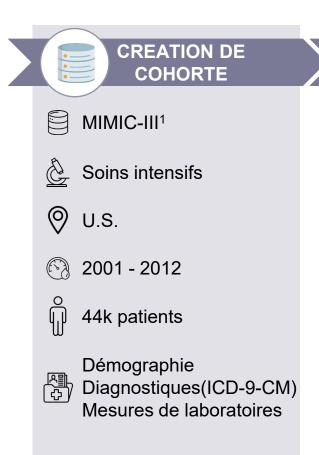




OBJECTIF: Evaluer la capacité des GANs à générer des données tabulaires synthétiques

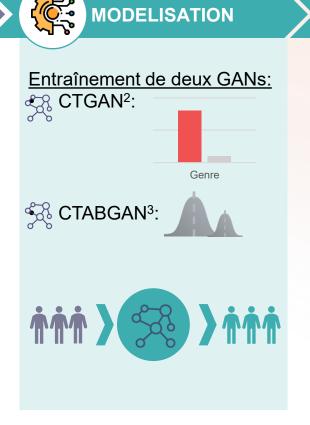


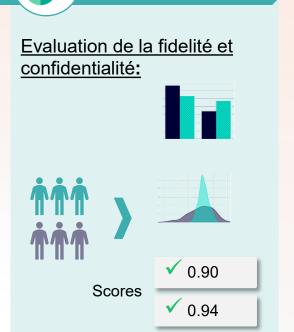
Méthode pour évaluer le machine learning dans la génération de données synthétiques de patients





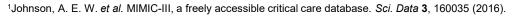
EXTRACTION DES





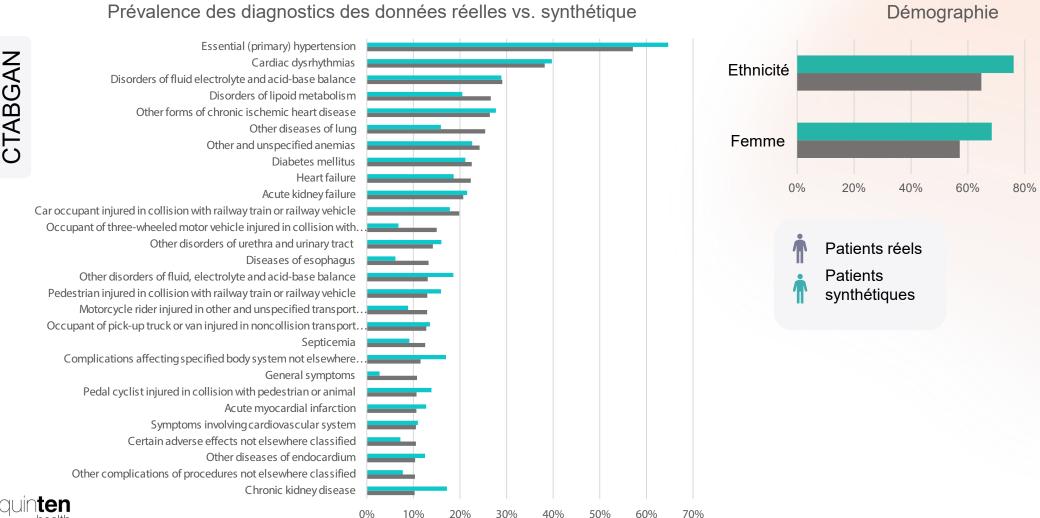
EVALUATION





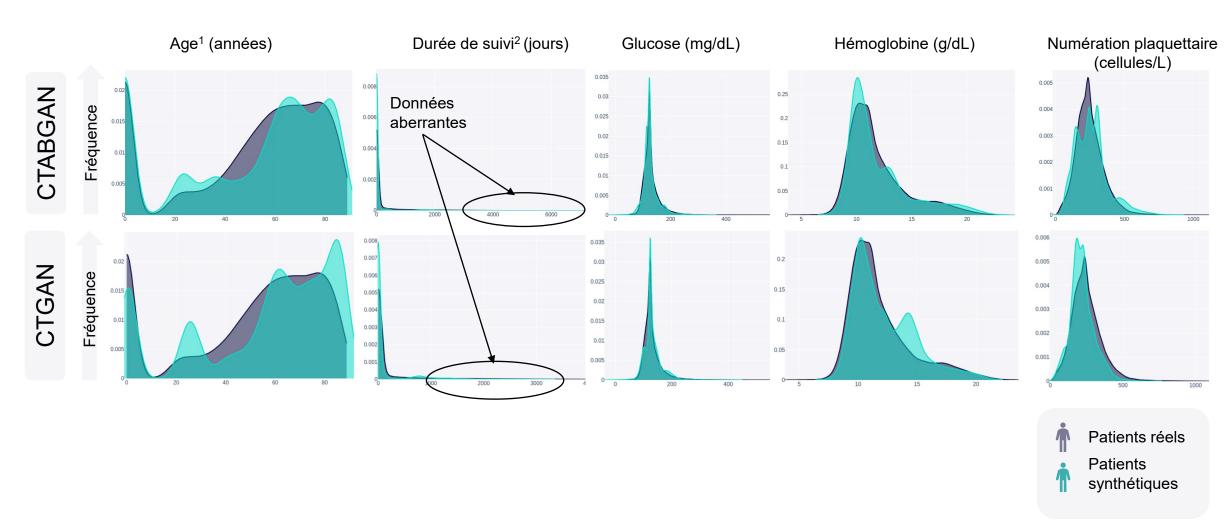
²Xu et al., Modeling Tabular data using Conditional GAN, arXiv:1907.00503 (2019).

Des prévalences de caractéristiques cliniques relativement fidèles aux données d'origine



100%

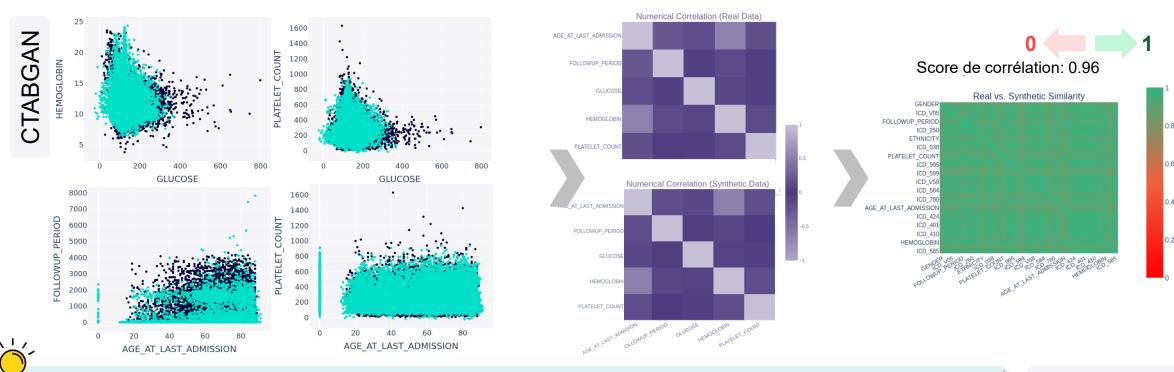
Des distributions continues fidèles aux données d'origine



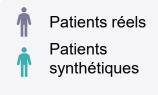


¹Age à la dernière admission aux urgences

Des corrélations préservées entre l'ensemble des variables

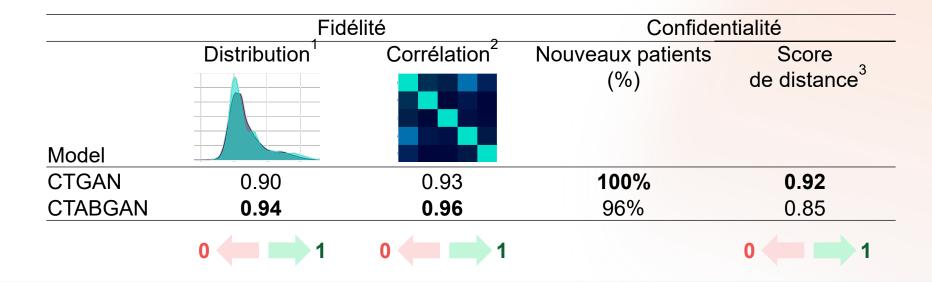


- CTABGAN préserve les correlations entre variables continues mais aussi discrètes
- MAIS génère des points aberrants pour les patients nouveaux nés

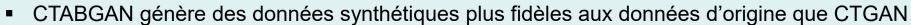




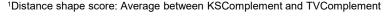
Génération de données réalistes préservant la confidentialité, un équilibre







MAIS CTGAN préserve mieux la confidentialité des données



²Distribution correlation score: Average between contingency and correlation similarity



Discussion

Méthode

DES RESULTATS ENCOURAGEANTS

- Les GANs produisent des données synthétiques fidèles à la réalité et préservant la confidentialité
- MAIS des ressources computationnelles et données importantes, difficulté de convergence

UNE EVALUATION DEPENDANTE DE L'USAGE DES DONNEES

- Un niveau et quantité de preuve dépendant du critère de jugement
- Un compromis entre fidelité et confidentialité

POUR ALLER PLUS LOIN

- Evaluation sur d'autres bases de données de santé, de taille et nature différentes
- Métrique d'utilité adaptée à la question de recherche
- Comparaison à d'autres approches: Large Language Models



Thank you

Merci pour votre attention

Des questions ?

8, rue vernier 75017 Paris - France +33 1 45 74 33 05

www.quinten-health.com