



Classification des défauts électriques dans un réseau de métro

Une approche hybride : IA profonde + expertise physique

NASSIM EL ASSAD

Maîtrise en ingénierie

01
/ 10

Pourquoi c'est critique ?

Des millions de voyageurs chaque jour dépendent d'un réseau qui ne tolère aucune défaillance

24/7

Opération continue

Le métro ne s'arrête jamais — une panne signifie des voyageurs bloqués, des pertes économiques, et un risque de sécurité.

ms

Décisions en temps réel

Les relais de protection doivent distinguer un vrai défaut d'une accélération normale de train en quelques millisecondes.

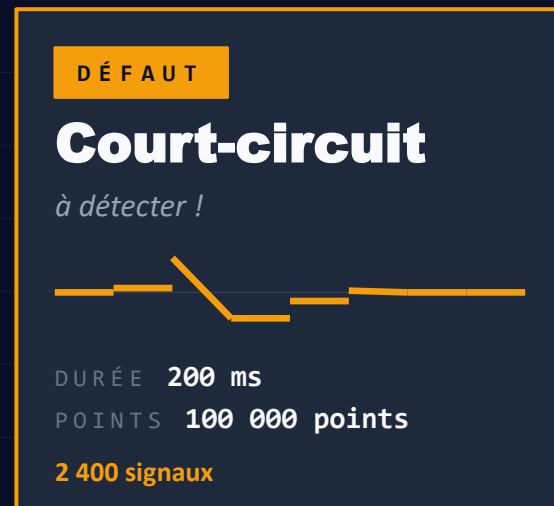

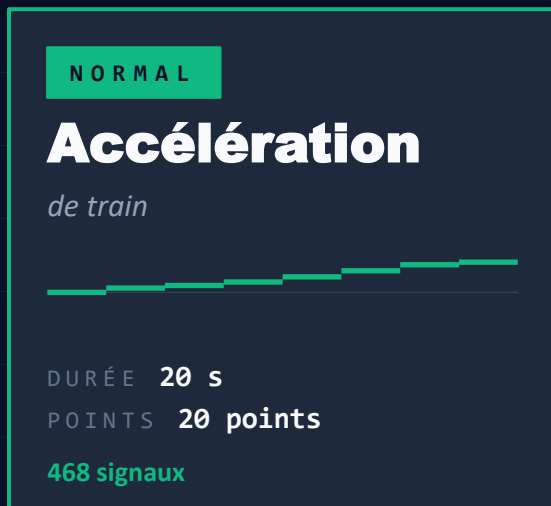
Faux

Les fausses alarmes coûtent cher

Un déclenchement à tort paralyse la ligne. Un défaut non détecté met en danger trains et infrastructure.

3 signaux, 3 échelles de temps

Le modèle doit reconnaître des phénomènes dont la durée varie sur 3 ordres de grandeur



Total : 3 068 signaux simulés

Un problème à deux visages

Deux difficultés combinées font échouer les approches classiques

01

Échelles de temps

3 ordres de grandeur séparent les classes

200 ms



défaut

2 s



énerg.

20 s



accél.

× 100 entre chaque étape →

02

Sous-classes de défauts

24 combinaisons à distinguer finement

$$2 \times 4 \times 3 = 24$$

types

distances

relais

Ce que la littérature propose

De méthodes classiques à l'apprentissage profond — panorama des approches existantes

CLASSIQUE

DWT + SVM

Décomposition en ondelettes + classification. Efficace mais nécessite un réglage manuel des features.

Reis 2004, Pires 2008, Shukran 2021

DEEP LEARNING

CNN + LSTM

Convolutions pour les motifs locaux, LSTM pour la temporalité. Référence dans le domaine.

Li 2024, Qian 2020, Tian 2020

SÉRIES TEMPORELLES

ResNet / InceptionTime

Architectures de pointe pour la classification de séries temporelles génériques.

Wang 2016, Fawaz 2020

ATTENTION

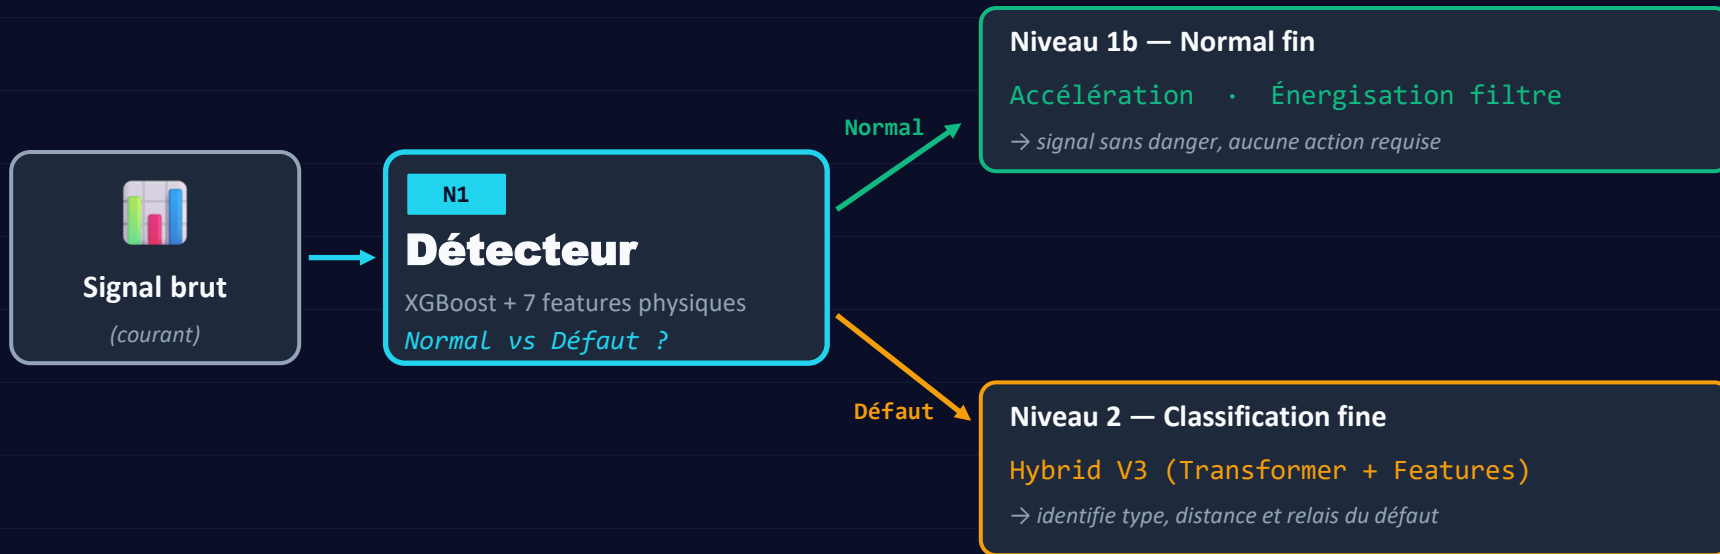
Transformers

L'attention capture les dépendances longues — puissant mais gourmand en données.

Vaswani 2017, Kumar 2024

Notre solution : cascade à 2 niveaux

Diviser pour mieux régner — d'abord détecter, ensuite classifier finement



Détecter l'anormal avec la physique

7 grandeurs physiques extraites du signal, un modèle léger — et une précision parfaite

LES 7 FEATURES PHYSIQUES

- 1 **Pic de courant** *valeur maximale*
- 2 **di/dt max** *pente d'attaque (A/s)*
- 3 **Crest factor** *rapport pic / RMS*
- 4 **RMS** *énergie du signal*
- 5 **Écart-type** *dispersion*
- 6 **Kurtosis** *queue de distribution*
- 7 **Skewness** *asymétrie*

RÉSULTAT TEST SET

100%

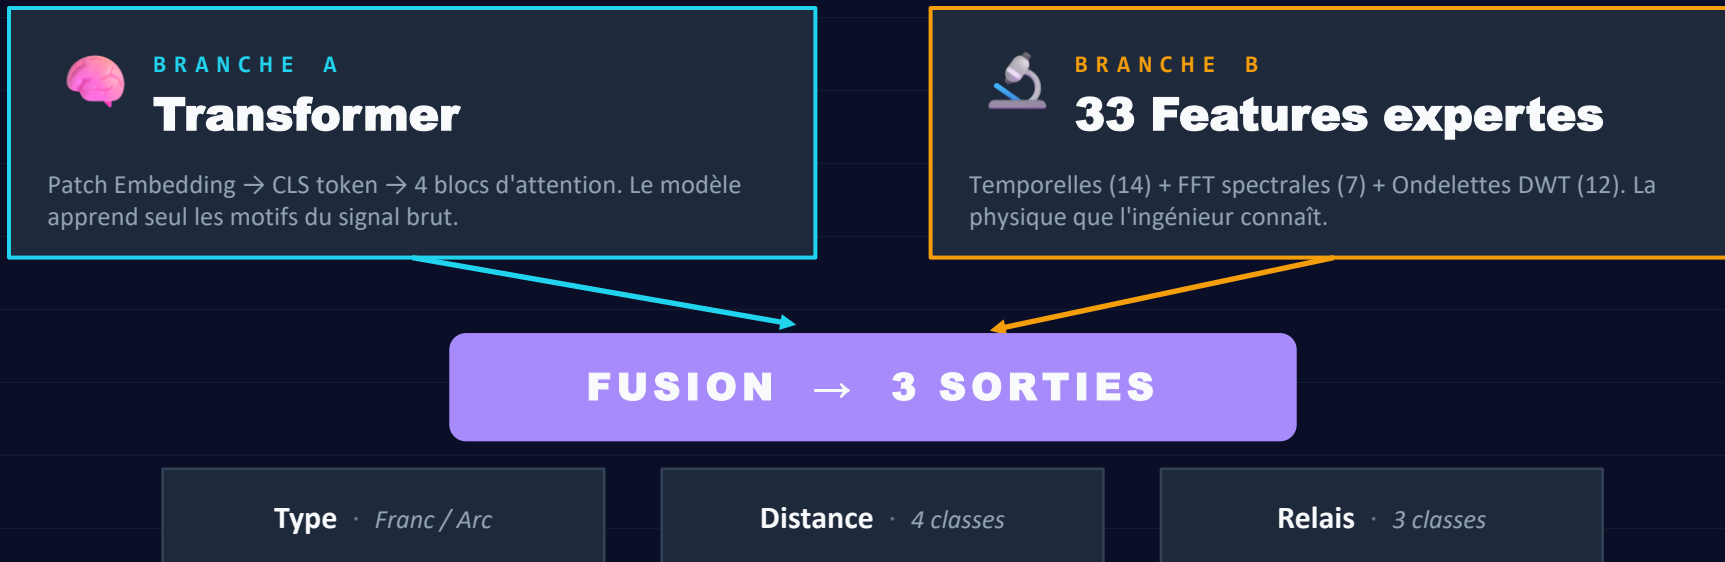
accuracy sur 3 classes

0 erreur · F1 = 1.0

XGBoost — 2 étages en cascade


Hybrid : IA + Physique

Deux cerveaux complémentaires qui collaborent pour classifier les 24 sous-classes



Hybrid V3 écrase la concurrence

Accuracy sur la tâche 24 sous-classes — test set de 360 signaux



HYBRID - DÉTAIL

Accuracy 24 classes **90.8%**

F1 Type (Franc/Arc) **0.944**

F1 Distance **0.964**

F1 Relais **1.000**

+25 points vs. le 2^e meilleur modèle — la combinaison IA + physique est le levier.

En résumé

01

Cascade intelligente

Détection à 100 % avec 7 features physiques, classification fine via Hybrid V3.

02

IA + Expertise physique

La fusion Transformer + features expertes surpasse tout modèle isolé (+25 pts).

03

Prêt à déployer

Application web Streamlit, modèles sauvegardés, pipeline complet automatisé.

Merci pour votre attention — questions ?