

Détection automatique des essieux relevés via des approches Machine Learning (Projet SETO)

Dimitri DAUCHER
Allou SAME
(UGE)

Approche « machine learning » : position du problème

Données directes WIM
(plusieurs mois de données)



IMPROVED WIM DATA

$L \in [16m, 16m80]$ (exclure les portes-chars)
Utilisation de données vidéo de
surveillance du trafic pour améliorer la
labellisation
(5 jours de données)



Sous base de référence

~ 100 T2S2N

~ 1000 T2S3R (essieu relevé)



**Objectif : distinguer
T2S3R vs T2S2N**



Analyse

Variables
discriminantes

- Longueur totale L
- Distances entre essieux d_i
- Labellisation WIM
- *Charges par essieux*




= une unique silhouette
géométrique pour le
WIM

Approche machine learning : représentation 2D des données WIM

Projection des observations dans un plan 2D : (d_3, d_4)

Grande proximité des silhouettes T2S2N, T2S3R ...

Choix d'une méthode de classification NL adaptée




Approche machine learning : Détection des ER via une approche « Random Forest »

Méthode Random Forest :

Un arbre de décision est un modèle où des questions sur des variables mènent à des décisions (ici appartenance à la classe T2S3R)

Combiner les avis de plusieurs arbres (forêt) : classe majoritaire

preticted class \ real class	T2S3R	T2S2N and T2S2PC
T2S3R	True positives 92,5% (198)	False negatives 7,5% (16)
T2S2N and T2S2PC	False positives 10,6% (25)	True negatives 89,4% (211)



Approche machine learning : Détection des ER via une approche « MLP (Multi Layer Perceptron) »


MLP = modèle d'apprentissage auto fondé sur un réseau de neurones organisé en plusieurs couches (entrée, couches cachées, sortie).

Chaque neurone combine les infos qu'il reçoit à l'aide de coefficients pondérés, puis applique une transformation NL pour extraire des caractéristiques pertinentes des données.

En empilant ces transformations, le modèle est capable de représenter et d'approximer des relations complexes entre variables d'entrée et de sortie.


Les paramètres du réseau sont ajustés automatiquement à partir d'exemples, lors d'une phase d'apprentissage visant à minimiser l'erreur de prédiction.

predicted class real class	T2S3R	T2S2N and T2S2PC
T2S3R	True positives 96,4%	False negatives 3,6%
T2S2N and T2S2PC	False positives 7,5%	True negatives 92,5%



Approche machine learning : Détection des ER, Zones de confiance pour la méthode MLP

Zone de très grande confiance pour la détection des ER (15% de la population)



Zone de très grande confiance pour la détection des ER (>70% de la population)

Zone perfectible (<15% de la population)

- Chevauchement des caractéristiques des véhicules
- Limites des modèles
- Données observées insuffisantes

Conclusions et perspectives

- Les taux de bonne détection des méthodes (RF, MLP) sont $> 90\%$ à 95% .
- Ces méthodes ont été validées sur des ensembles de données réelles collectées sur l'A63 (Atlandes). Des travaux similaires seront menés sur des données plus riches issues de l'A61 (Sud de Toulouse)
- Une meilleure connaissance « physique » pourrait permettre d'améliorer les méthodes (infrastructure, dynamique PL, ...)
- Généralisation possible à d'autres silhouettes
- Ce problème reste important de la fiabilisation des systèmes de pesage en marche (EPM)

Merci pour votre attention !

Dimitri DAUCHER, Université Gustave Eiffel
dimitri.daucher@univ-eiffel.fr

Allou SAME, Université Gustave Eiffel
allou.same@univ-eiffel.fr