

# Classification de panneaux de signalisation routière

Maurice, Camille, [c.maurice@geo-sat.com](mailto:c.maurice@geo-sat.com), GEOSAT, Pessac (Orateur)

Soubiès, Gabriel, [g.soubies@geo-sat.com](mailto:g.soubies@geo-sat.com), Geosat, Pessac

Ferrero, Cédrik, [c.ferrero@geo-sat.com](mailto:c.ferrero@geo-sat.com), Geosat, Pessac

Thématique : Thème 6 : Intelligence Artificielle

*Résumé : Pour certifier un niveau de sécurité aux véhicules autonomes, législateurs et constructeurs peuvent compléter les données capteurs par une carte Haute Définition de l'environnement. La signalisation routière est l'une des composantes de cette carte. Nous présentons ici une approche de classification de panneaux via une approche d'apprentissage profond ainsi que des techniques de régularisation pour adresser les spécificités de cette problématique.*

Mots clés : apprentissage, *deep-learning*, *classification*, *autonomous driving*,

## 1. Introduction

Pour la création de la carte Haute Définition, des acquisitions d'images panoramiques sont effectuées sur le territoire. Le problème de classification de panneaux de signalisation routière peut s'exprimer ainsi : trouver quel type de panneau est représenté par une image vignette. Il existe en France plus de 600 types de panneaux différents, il s'agit d'un problème de classification avec un très grand nombre de classes.

Les différentes classes de panneaux ne sont pas aussi fréquentes les unes que les autres, par exemple les panneaux « voie interdite aux charrettes à bras » sont bien moins fréquents que les panneaux « stop ». Les données des différentes classes sont dites déséquilibrées.

Bien que les panneaux répondent à une norme, il existe au sein d'une même classe de panneau des variations dues aux conditions climatiques, aux altérations humaines ou au vieillissement des panneaux. Des panneaux au sein de deux classes différentes peuvent également se ressembler.

Le grand nombre de classes, leur déséquilibre, les grandes variations intra-classe et les faibles variations inter-classes constituent les principales caractéristiques de cette problématique.

## 2. Méthodologie

Pour répondre à la problématique par des techniques d'apprentissage supervisé il est nécessaire de constituer un jeu de données. Nous avons créé un jeu de données séparé entre un jeu d'entraînement pour l'apprentissage supervisé et un jeu de validation pour évaluer les performances de la solution.

Ensuite il y a également une phase d'augmentation des données. Des pré-traitements sont appliqués sur les images pour notamment prendre en compte les effets de distorsions propres à nos données d'acquisition.

Le réseau de neurones entraîné suit l'architecture globale de EfficientNet[1], certaines modifications ont été apportées pour mieux répondre à notre problème. La tête du réseau intègre maintenant une couche de régularisation supplémentaire afin de prévenir le sur-apprentissage[2]. Un choix particulier a également été opéré pour la fonction de coût à optimiser lors de l'entraînement.

### 3. Originalité / perspective



Figure 1 : Exemples de classes de panneaux avec 100% de précision et de rappel

L'originalité de nos travaux se trouve à plusieurs niveaux : les images d'entrée, le jeu de données et au niveau de l'architecture du réseau.

Les données d'entrées issues d'images panoramiques sont assez peu courantes dans la littérature. Nous présentons des résultats sur un minimum de 116 classes ce qui est plus important par exemple que les 80 classes du jeu de données MSCOCO[3].

Grâce à notre création de jeu de données et aux deux modifications opérées sur la tête du réseau nous obtenons un résultat en justesse (*accuracy*) de 95% et un score F1 de 0,90. Les résultats montrent notamment une robustesse aux altérations humaines ainsi qu'une capacité de généralisation grâce à des tests sur un jeu de données allemand[4].

D'autres travaux sont en cours pour étendre la reconnaissance de toutes les classes à partir de *0-shot learning* ou encore des techniques de *clustering* par apprentissage profond.

### Références

[1] Tan, Mingxing, and Quoc Le. "Efficientnet: Rethinking model scaling for convolutional neural networks." *International Conference on Machine Learning*, 2019.

[2] Srivastava, Nitish, et al. "Dropout: a simple way to prevent neural networks from overfitting." *The journal of machine learning research* 15.1, 2014

[3] Lin, Tsung-Yi, et al. "Microsoft coco: Common objects in context." *ECCV*. Springer, 2014.

[4] Houben, Sebastian, et al. "Detection of traffic signs in real-world images: The German Traffic Sign Detection Benchmark." *IJCNN*. IEEE, 2013.