

# Apprendre à combiner l'information géographique pour générer une carte généralisée

Azelle Courtial\*, Guillaume Touya\*

\* Univ. Gustav Eiffel, ENSG, IGN, Champs-sur-Marne  
prenom.nom@ign.fr,

## 1 Introduction

L'apprentissage profond est de plus en plus utilisé pour générer de l'information géographique et notamment des cartes, afin d'accélérer les processus de production (Courtial et al., 2020). Le problème de génération de cartes est souvent traité comme un problème de traduction d'image à image. Mais contrairement à la méthode traditionnelle qui repose sur des couches de données vectorielles stockées dans des bases de données géographiques, l'image ne transmet qu'une vue limitée des informations géographiques nécessaires à la construction d'une carte. L'ensemble des informations nécessaires à ces processus sont : la forme et la localisation des objets, mais aussi des caractéristiques implicites telles que leur importance, rôle dans le paysage, relations spatiales, ... Lorsque nous nous intéressons à la génération de cartes à partir d'images, nous devons nous assurer que ces informations soient accessibles dans les exemples d'apprentissage. C'est pourquoi, nous nous intéressons aux modalités de représentation et de combinaison de l'information géographique pour améliorer la génération de cartes par apprentissage profond. Nous proposons deux méthodes pour ajouter de l'information dans nos images initiales : séparer notre image par thème cartographique, et utiliser de l'information supplémentaire et des mécanismes de combinaison.

## 2 Création du jeu d'apprentissage

On propose d'abord de comparer deux méthodes de création du jeu d'apprentissage depuis une base de données vectorielle. D'une part, la représentation symbolisée est construite par symbolisation des données initiales et cible, puis rasterisation puis découpage de l'espace d'étude en images (Courtial et al., 2020). D'autre part la représentation par thème qui limiterait les problèmes de superposition entre objets de types différents. Elle consiste à utiliser une pile d'images, chaque image de la pile représentant un type d'objet de la base de données initiale. L'apprentissage des relations entre objets de types différents (par exemple : la rivière longe une route) est facilitée, car les deux éléments sont toujours représentés même en cas de colocalisation. Dans nos expérimentations comparant les deux approches, le mode de représentation n'impacte pas la qualité de la prédiction dans la plupart des situations. Mais pour les cas où l'information est dense et la superposition entre symboles est importante dans l'image initiale, la représentation par thème limite les effacements d'information liés à ces superpositions.

Génération de carte par combinaison d'information.




FIG. 1 – Comparaison des images de cartes générées par un GAN à partir de l'empilement ou de la fusion d'une image de carte et de l'information additionnelle de probabilité de sélection.

### 3 Ajout d'informations additionnelles

Nous proposons également d'inclure des informations additionnelles pouvant être représentées sous la forme d'un tenseur. Nous avons comparé deux méthodes de combinaison pour ajouter la probabilité de chaque route d'apparaître sur la carte (calculée par ailleurs), et représentée sous forme d'une image en niveau de gris : (1) une combinaison de l'information géographique par simple empilement d'images dans un unique tenseur ; (2) la fusion d'information via un FuseNet (Hazırbas et al., 2016). La Figure 1 montre nos résultats pour des cartes générées avec un GAN (réseau de neurones génératif) avec empilement des couches, ou avec un FuseNet comme générateur du GAN, cette dernière méthode donnant les meilleurs résultats. On observe que les deux réseaux apprennent à effacer des routes pour éviter la superposition entre symboles de routes et de bâtiments. Mais le réseau procédant par empilement ne semble pas tirer profit de la carte de probabilités. Au contraire, le réseau ayant un générateur en forme de FuseNet ne sur-sélectionne pas le réseau routier et préserve davantage la structure générale.

### Références

- Courtial, A., A. El Ayedi, G. Touya, et X. Zhang (2020). Exploring the Potential of Deep Learning Segmentation for Mountain Roads Generalisation. *ISPRS International Journal of Geo-Information* 9(5), 338.
- Hazırbas, C., L. Ma, C. Domokos, et D. Cremers (2016). FuseNet : Incorporating Depth into Semantic Segmentation via Fusion-Based CNN Architecture. In *Computer Vision – ACCV*.

### Summary

Deep learning allows the generation of maps from images. However, images only convey a limited view of the vector geographic information. We explore the methods to combine and represent cartographic information as tensors to improve map generation using deep learning.