

# IDENTIFICATION DE RELATIONS SPATIALES PAR APPRENTISSAGE PROFOND SUR DES GRAPHE

par Azelle Courtial, Guillaume Touya

LASTIG, Univ Gustave Eiffel, ENSG, IGN,  
F-94160 Saint-Mandé, France,  
azelle.courtial@ign.fr, guillaume.touya@ign.fr

et Xiang Zhang

School of Resource and Environmental Sciences,  
Wuhan University, Wuhan 430079, China,  
xiang.zhang@whu.edu.cn

---

*L'identification des structures et relations spatiales est une tâche clé de la généralisation cartographique automatique. Dans cet article, nous explorons le potentiel des réseaux d'apprentissage profond par convolution sur des graphes (GCN) pour apprendre à identifier des relations spatiales à travers deux cas d'études : la détection d'alignement et la sélection du réseau routier. Nos résultats sont plutôt encourageants et mettent en lumière les enjeux liés à la construction et l'enrichissement d'une structure de graphe adaptée à la tâche dont on désire l'apprentissage.*

**Mot clés :** relation spatiale, généralisation cartographique, convolution sur les graphes.

*Structure and relation identification are key tasks for the automation of map generalisation. In this article, we explore the potential of graph convolutional networks (GCN) to learn spatial relation's identification, throw two examples: alignments detection and road selection. Our results are promising and highlight the issues of an adapted graph modelisation and enrichment.*

**Keywords :** Spatial relation, map generalisation, graph convolution.

## Introduction

Les cartes sont composées d'objets géographiques spatialement connectés. Les relations spatiales sont des informations clef pour l'utilisateur puisqu'elles supportent la description de position relative: la maison est à l'est du centre-ville, près de l'échangeur, à la fin du chemin. Par conséquent, la préservation de ces relations est primordiale durant la généralisation cartographique. Par exemple la typification de bâtiment est un opérateur de généralisation qui vise à réduire la quantité de bâtiments tout en préservant les relations entre et au sein des groupes de bâtiments homogènes (Regnauld, 2001). Les structures spatiales de route ou de bâtiment sont des arrangements remarquables dans la carte qui permettent l'inférence de concepts spatiaux de haut niveau (par exemple morphologie urbaine et occupation du sol). De telles structures peuvent être caractérisées par les relations spatiales (par exemple proximité, similarité et continuité d'éléments) et sont alors visuellement identifiables par un humain.

L'identification automatique de ces structures est importante pour l'automatisation de la généralisation cartographique (Christophe et Ruas,

2002). Cependant, il reste difficile de concevoir des algorithmes avec un niveau de performance similaire à celle d'un humain. Le but de ce papier est d'illustrer le potentiel des réseaux de convolutions sur les graphes (GCN) pour l'identification des structures et relations importantes pour la généralisation cartographique, à travers deux cas d'études : la détection de structure de bâtiment et la sélection de route. Ces deux tâches requièrent un certain degré de compréhension des relations spatiales entre les objets d'une carte. Par conséquent, notre expérimentation constitue une première étape dans l'exploration du potentiel des réseaux d'apprentissage profond pour apprendre les représentations de relation spatiale.

Les GCNs sont spécialisés dans l'analyse des nœuds et adjacence dans un graphe pour prédire une information à l'échelle du graphe ou du nœud. Ces réseaux ont déjà été employé pour la détection de blocs réguliers dans une zone urbaine (Yan *et al.*, 2019), et pour l'encodage de forme de bâtiment (Yan *et al.*, 2020). Les GCN utilisent comme entrée une description des attributs de chaque nœud, résumé dans une matrice d'attribut, avec la matrice d'adjacence du graphe. Pour chaque couche du

réseau, les attributs sont encodés par le produit matriciel de la précédente couche et de la matrice d'adjacence, par conséquent la valeur encodée d'un nœud dépend de ces attributs et de ses voisins.

## Détection des alignements

Dans notre premier cas d'étude, nous souhaitons prédire les relations entre bâtiments (appartient à un alignement droit, curviligne, ou à aucun alignement). En généralisation cartographique, les graphes de proximité sont souvent utilisés pour analyser les structures urbaines. Les graphes les plus souvent utilisés sont des variations de la triangulation de Delaunay (DT) présentée en figure 1. La triangulation de Delaunay donne un aperçu des proximités entre les bâtiments, mais tous les arcs de ce graphe ne sont pas nécessaires pour identifier les alignements.

Les graphes de proximité relative (RNG) connectent les nœuds qui sont au moins aussi proches les uns des autres que de tout autre point (Toussaint, 1980). Mais, comme montré (fig. 1), certains arcs d'alignement sont systématiquement ignorés par le RNG. Nous proposons donc une structure de proximité illustrée (fig. 1. c.) qui résout ce problème en ajoutant les arcs de la Triangulation de Delaunay qui sont suffisamment petits pour répondre au critère proposé par (Bader *et al.*, 2005).

Ensuite, le GCN est adapté pour une classification des nœuds, tandis que nous sommes intéressés par la classification des arcs de la structure de proximité. Nous proposons donc une transformation proche d'un graphe dual (fig. 1. d.) : pour chaque arc, nous créons un nœud que nous connectons à tous les nœuds qui sont connectés au même bâtiment dans la structure de proximité. Nous calculons aussi des caractéristiques pour chaque nœud qui décrivent la similarité des éléments : la longueur du lien de proximité, sa distance et orientation à la route la plus proche, la distance et le *facing ratio* (Wang et Burghardt, 2019) ainsi que leur différence de taille, d'orientation et d'élongation. Nous avons conduit notre expérimentation pour environ 10 000 bâtiments extraits d'OpenStreetMap dans des zones urbaines et suburbaines américaines ayant une organisation régulière. Le graphe d'entraînement est composé de 13 993 arcs annotés "non alignement", 2 976 annotés "alignement droit", et 2 010 arcs annotés "alignements curvilinéaires".

La figure 2 présente les annotations et résultats. Nos résultats ne sont pas encore satisfaisants : la prédiction des arcs n'appartenant pas à l'alignement est bonne, mais la classification manque de nombreux arcs qui ne sont pas alignés. La séparation entre alignement droit et curvilinéaire semble bien comprise. Finalement les segments alignés situés à l'extrémité d'une impasse sont toujours mal classifiés.

## Sélection du réseau routier

Notre deuxième expérience concerne la sélection des routes. L'objectif est de prédire pour chaque arc routier s'il doit être gardé ou éliminé de la représentation du réseau routier à l'échelle cible. Pour ce cas d'étude, chaque segment de route forme un nœud du graphe d'apprentissage et est décrit grâce à sa longueur, un attribut d'importance et des attributs liés à la forme du vecteur le représentant. Quand deux segments de route partagent une intersection, un arc est ajouté entre les nœuds correspondant dans le graphe. Pour cette expérience, notre jeu de données est composé de routes issues de cartes à 1:25000, nettes de leur généralisation au 1:50000 dans des aires urbaines, suburbaine et rurale. Le réseau routier contient 12 837 tronçons (55% qui doivent être gardés et 45% qui doivent être éliminés).

Les résultats sont présentés dans la figure 4 : La précision de la classification est autour de 69%, et le résultat est visuellement satisfaisant. La sélection dans les zones rurales, les centres-villes et la suppression des impasses fonctionne bien. Néanmoins, quelques déconnexions inattendues apparaissent dans des villages isolés.

## Conclusion

Pour conclure, notre expérience montre que les GCN sont intéressants pour apprendre la représentation de certaines relations spatiales et la généralisation cartographique. Mais des améliorations sont nécessaires pour chacune des expériences présentées ici, comme les choix des attributs utilisés, ou la quantité d'exemples d'entraînement. Par la suite, ces techniques pourraient être combinées avec des réseaux génératifs (Courtial *et al.*, 2021) pour généraliser plusieurs thèmes à la fois tout en préservant les structures.




Figure 1 : Différents graphes de proximité dans une situation simple de deux alignements parallèles perturbés par un bâtiment sans relation.



Figure 2 : Annotations (à gauche) et prédictions (à droite) pour la détection d'alignement par GCN.



Figure 3 : Annotations et prédictions de la probabilité d'être sélectionné dans le réseau routier généralisé.

## Bibliographie

- Bader M., Barrault M., Weibel R., 2005, « Building displacement over a ductile truss ». *International Journal of Geographical Information Science*, vol. 19, n° 8-9, p. 15-36, <https://doi.org/10.1080/13658810500161237>
- Christophe S., Ruas A., 2002, « Detecting Building Alignments for Generalisation Purposes. » dans: Richardson D.E., van Oosterom P. (éds), *Advances in Spatial Data Handling*. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/978-3-642-56094-1\\_31](https://doi.org/10.1007/978-3-642-56094-1_31)
- Courtial, A., Touya G., et Zhang X., 2021, « Generative adversarial networks to generalise urban areas in topographic maps. », *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLIII-B4-2021, p. 15-22. Copernicus GmbH. ISSN : 1682-1750
- Regnauld, N., 2001, « Contextual Building Typification in Automated Map », *Generalization Algorithmica*, vol. 30, p.312-333, <https://doi.org/10.1007/s00453-001-0008-8>
- Toussaint G., 1980, « The relative neighbourhood graph of a finite planar set », *Pattern Recognit.*, 10.1016/0031-3203(80)90066-7
- Wang X., Burghardt D., 2019, « A Mesh-Based Typification Method for Building Groups with Grid Patterns ». *ISPRS International Journal of Geo-Information* 8, n° 4, p. 168, <https://doi.org/10.3390/ijgi8040168>.
- Yan X., Ai T., Yang M., Yin H., 2019, « A graph convolutional neural network for classification of building patterns using spatial vector data », *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 150, p. 259-273, <https://doi.org/10.1016/j.isprsjprs.2019.02.010>.
- Yan X., Ai T., Yang M., Tong X., 2020, « Graph convolutional autoencoder model for the shape coding and cognition of buildings in maps ». *International Journal of Geographical Information Science*, p.1-23, <https://doi.org/10.1080/13658816.2020.1768260>.