

EXPLORATION DU POTENTIEL DE L'APPRENTISSAGE PROFOND POUR LA GÉNÉRALISATION CARTOGRAPHIQUE¹

par Azelle Courtial

Institut national de l'information géographique et forestière
73 avenue de Paris 94160 Saint-Mandé
azelle.courtial@ign.fr

Introduction

Depuis 20 ans, l'usage des cartes a évolué de façon importante, les cartes sont désormais majoritairement en ligne, multi-représentations, et multi-échelles. Les utilisateurs attendent un contenu spécifique à leurs besoins, à leurs appareils et interactif, où les informations sont accessibles de façon directe et lisible. Néanmoins, les cartes en ligne actuelles ne sont ni spécifiques aux besoins de l'utilisateur ni simples à naviguer. Par exemple, le saut de représentation entre les échelles d'une carte produit de la confusion pendant le zoom. D'autre part, la multiplication des sources de données a entraîné l'augmentation du besoin de synthèse, d'harmonisation et d'abstraction de l'information géographique sous forme d'une carte. Nous pensons que le développement de processus cartographiques qui limitent cette confusion, et répondent à ces nouveaux besoins est conditionné à de grandes avancées de la recherche en automatisation de la généralisation cartographique. Il s'agit du processus d'abstraction qui vise à adapter le niveau de détail de l'information géographique pour la rendre lisible sur une carte à une échelle plus petite (fig. 1).

La recherche sur l'automatisation de la généralisation cartographique a ralenti ces dernières années tandis que le besoin lui, n'a pas diminué. Nous pensons qu'elle pourrait bénéficier des avancées récentes en apprentissage profond qui rendent possible la résolution de tâches de plus en plus complexes, grâce à l'utilisation de nombreux exemples. L'usage de méthodes issues de l'apprentissage automatique pour la généralisation cartographique a déjà été expérimenté dans quelques cas d'étude isolés et limités (Feng, *et al.* 2019). Pourtant ces techniques sont prometteuses :

- nous disposons de jeux d'apprentissages importants grâce aux dynamiques open-data et l'ère du big data ;
- l'apprentissage profond permet d'apprendre de données brutes, Il est donc possible de passer l'étape d'extraction de variables, qui était jusqu'alors la principale limite à l'utilisation de l'apprentissage automatique en généralisation cartographique (Sester, 2000 ; Weibel et al., 1995);
- l'état de l'art en apprentissage profond montre une capacité accrue à résoudre des tâches similaires à la généralisation cartographique dans les domaines des sciences de l'information géographique et de la visualisation d'informations (Simo-Serra et al., 2017) ;

L'approche par apprentissage profond de la généralisation est encore expérimentale, et par ailleurs elle est à l'opposé des approches traditionnelles de la généralisation cartographique, où l'on formalisait d'abord des spécifications cartographiques puis on appliquait des opérations pour s'y conformer. En effet, un modèle d'apprentissage profond va plutôt apprendre à reproduire des cartes généralisées sans explicitement définir les spécifications de la carte ou les opérateurs employés, mais en déduisant ce à quoi devrait ressembler le résultat de la généralisation. Le premier objectif de cette thèse est donc de démontrer que l'approche est possible, puis nous proposons d'explorer *via* divers cas d'étude le potentiel et les questions de recherche soulevées par l'usage de l'apprentissage profond pour la généralisation cartographique. Notre exploration est construite à travers quatre cas d'études qui décrivent chacun un problème particulier de généralisation cartographique. Les trois premiers cas d'étude correspondent à des étapes classiques de processus

¹ Exploring the potential of deep learning for map generalization. Geography. Thèse dirigée par Guillaume Touya et soutenue à l'Université Gustave Eiffel le 18 janvier 2023.

de généralisation cartographique (généralisation graphique, détection de pattern, sélection d'entités) ; tandis que le dernier correspond à une approche plus globale pour la génération d'une carte généralisée qui combine plusieurs opérateurs de généralisation. La thèse est structurée autour des trois objectifs suivants : identifier le potentiel et les défis d'une telle approche ; expérimenter l'apprentissage de quelques tâches de généralisation cartographique importantes ; donner des indications pour les futures utilisations de l'apprentissage profond pour la généralisation cartographique.

Un nouveau paradigme pour la généralisation

Dans cette partie nous interrogeons comment l'apprentissage peut constituer un nouveau paradigme pour la généralisation. Les défis de la généralisation par apprentissage sont les suivants :

- la représentation image est l'approche principale en apprentissage profond, mais l'utilisation d'images pour la généralisation cartographique est moins efficace, car elle implique une perte d'information par rapport aux bases de données géographiques vectorielles ;
- les modèles d'apprentissage profond sont complexes à paramétrer et nécessiteront probablement d'être adaptés pour traiter des informations cartographiques ;
- l'apprentissage profond donne des résultats sans explication qui peuvent être considérés comme non fiables ou difficiles à intégrer dans un processus semi-automatique ;
- l'entraînement de modèles d'apprentissage profond demande des ressources importantes qui peuvent être difficilement accessibles aux chercheurs en cartographie, ou avoir un coût économique ou environnemental trop important.

Ensuite, nous identifions comment des opérations de généralisation cartographique peuvent être formulées en une tâche qu'un modèle d'apprentissage peut résoudre (fig. 2). En particulier, nous relevons qu'une grande partie des tâches de généralisation cartographique peuvent être exprimées comme un problème de classification, segmentation ou régression sur des images ou des graphes. Notons que la combinaison de plusieurs approches semble plus prometteuse encore. Par exemple pour la simplification d'une forme, une approche image est possible, ou bien une approche qui combine sélection et régression sur les nœuds d'un graphe pour prédire les nouvelles positions des sommets.

L'apprentissage profond peut-il apprendre la généralisation cartographique ?

Cette partie a pour objectif d'expérimenter le potentiel de l'apprentissage de quelques tâches de généralisation cartographique importantes. Dans un premier temps nous testons la détection d'alignement de bâtiments et la sélection du réseau routier avec une approche par graphe. Ces expériences montrent des résultats perfectibles mais révèlent une capacité à faire des prédictions cohérentes avec les relations spatiales que nous (humains) observons dans les données (fig. 3.c). Ensuite nous proposons d'éprouver la capacité des modèles d'apprentissage basés sur des images à apprendre la généralisation graphique des entités cartographiques via le cas d'étude des routes de montagne pour un saut d'échelle important. Cette expérience compare plusieurs approches (par segmentation et avec un GAN) et révèle que les modèles sont capables de reproduire le lissage des lignes, l'élargissement de virages serrés, et la caricature, pour la plupart des situations testées (voir figure 3.a). Dans cette expérience la préservation de la structure du réseau routier (et en particulier éviter la création de boucle et les déconnexions) est un enjeu majeur et les modèles génératifs sont plus prometteurs sur ce point. Enfin, nous démontrons que les réseaux adverses génératifs (GAN) sont capables de générer des images ressemblant à des cartes à une échelle donnée. Nous générons des images de cartes généralisées à partir de cartes détaillées comportant : des bâtiments, les réseaux routier et hydrographique. Nos résultats reproduisent la simplification, l'agrandissement et la typification de bâtiments, mais la représentation en tuiles est limitante pour les tâches nécessitant plus de contexte comme la sélection du réseau routier et le grisage des centres-villes (fig. 3.b).

Le futur de la généralisation cartographique par apprentissage

Les résultats de nos expériences nous laissent penser que l'utilisation de l'apprentissage profond pour la généralisation cartographique pourrait être un tournant dans l'automatisation de la généralisation cartographique. Mais pour cela, les modèles doivent être insérés et comparés avec les processus traditionnels de généralisation cartographique. Dans la troisième partie de la thèse nous discutons donc : 1) capacité de transfert des modèles d'apprentissage profond proposé, 2) leur intégration, d'une part dans un processus de généralisation traditionnel

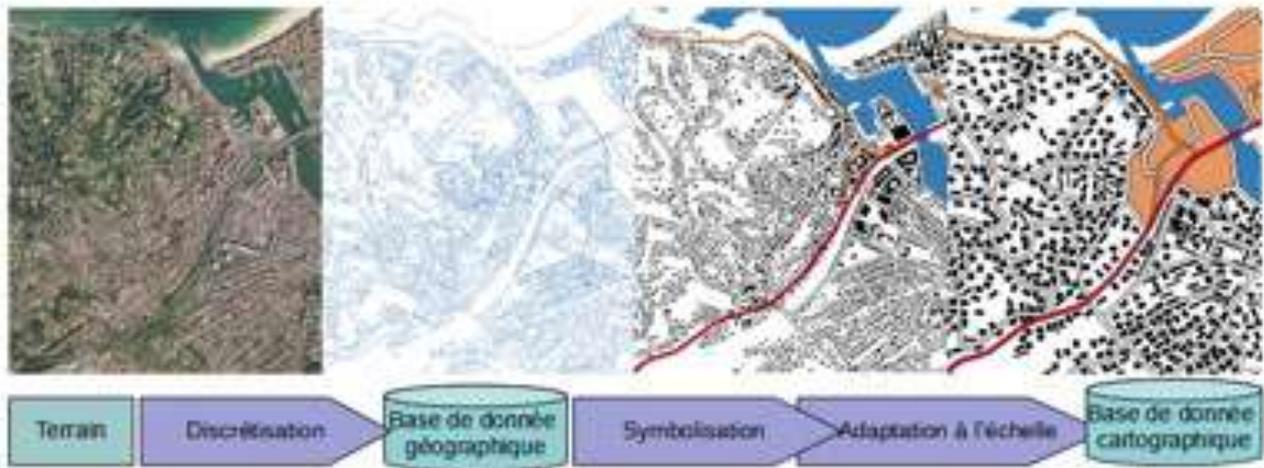


Figure 1 : Le rôle de la généralisation dans la production cartographique

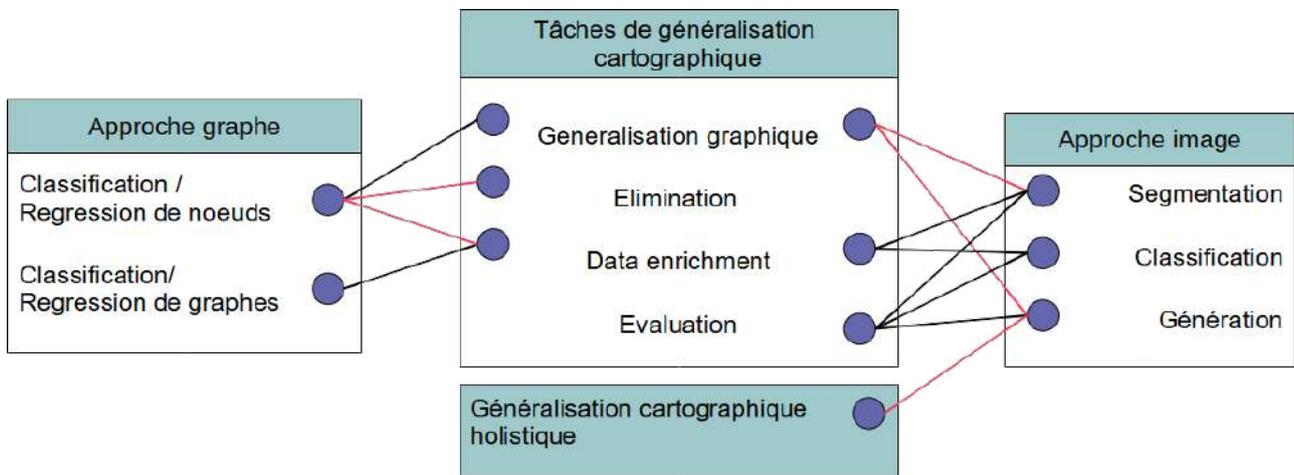


Figure 2 : Résumé des approches graphe et images pour résoudre des tâche de généralisation cartographique (les liens en rose représentent les approches abordées dans la thèse).

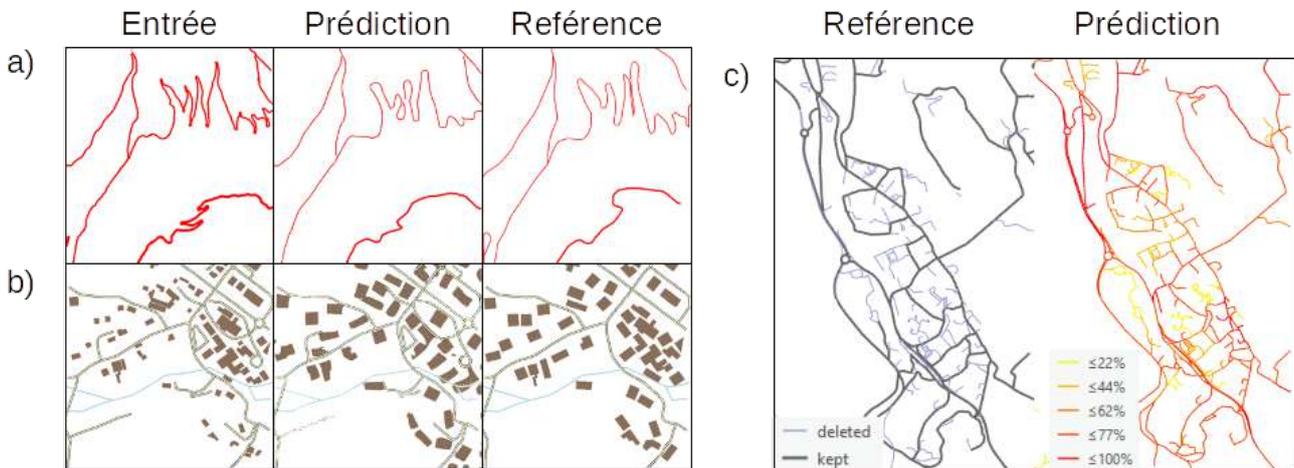


Figure 3 : Illustration des résultats des trois principaux cas d'études a) généralisation graphique de routes de montagnes ; b) génération de carte généralisée ; c) sélection du réseau routier.

(comme indicateur pour l'enrichissement des données géographiques ou comme opérateur de généralisation) et d'autre part dans un processus constitué entièrement de modèles d'apprentissage, 3) leur évaluation.

En particulier, pour l'évaluation nous comparons trois approches :

- l'adaptation des contraintes de généralisation cartographique pour une mesure basée sur des tuiles, permet une évaluation automatique des différents aspects de la généralisation, mais toutes les contraintes ne semblent pas adaptables.
- La reconstruction d'une base de données vectorielle permet d'appliquer les méthodes traditionnelles d'évaluation de la généralisation cartographique, mais demande un temps de calcul important et peut altérer la qualité des prédictions.
- Le test utilisateur est le seul moyen de s'assurer que la prédiction correspond à ce qui est attendu par l'utilisateur, néanmoins, il ne permet pas l'évaluation automatique.

Conclusion

L'objectif de notre thèse était d'explorer le potentiel de l'apprentissage profond pour la généralisation cartographique. Les résultats de nos expériences

révèlent la capacité des modèles d'apprentissage profond à apprendre à interpréter, abstraire et représenter l'information géographique depuis des images ou des graphes. Nos résultats sont suffisamment performants pour un usage comme indicateur (c'est-à-dire pour l'enrichissement de l'information géographique avant la généralisation), mais la qualité et les difficultés d'évaluation/intégration des modèles qui visent à apprendre un ou plusieurs opérateurs ne sont pour l'instant pas suffisantes pour remplacer ou compléter les opérateurs traditionnels dans un processus de généralisation. Nous pensons que pour rendre possibles de tels usages, l'amélioration des architectures et jeux d'apprentissage est nécessaire et en particulier pour une meilleure utilisation du contexte spatial. Aussi, notre thèse s'inscrit dans l'objectif global de la géo-intelligence artificielle, qui est de concevoir un programme capable de comprendre la question d'un utilisateur relative à l'information géographique, et de regrouper, analyser et présenter les données requises pour répondre à la question de l'utilisateur dans une forme adaptée (Janowicz *et al.*, 2020, p. 631). En effet, la carte est bien souvent le mode de communication de la solution la plus souhaitable pour communiquer une information géographique à un utilisateur humain, et requiert l'automatisation et l'adaptabilité des processus de généralisation. L'usage de l'apprentissage profond pourrait débloquer la recherche d'un modèle capable de générer de telles cartes.

Bibliographie

Feng, Y., Thiemann, F., et Sester, M. (2019). « Learning cartographic building generalization with deep convolutional neural networks ». *International Journal of Geo-Information*.

Janowicz, K., Gao, S., McKenzie, G., *et al.* (2020), "GeoAI: spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond", *International Journal of Geographical Information Science*, 34(4), 625-636. <https://doi.org/10.1080/13658816.2019.1684500>

Sester, M. (2000), "Knowledge acquisition for the automatic interpretation of spatial data", *International Journal of Geographical Information Science*, 14(1), 1-24. <https://doi.org/10.1080/136588100240930>

Simo-Serra, E., Iizuka, S., et Ishikawa, H. (2017). Mastering Sketching: Adversarial Augmentation for Structured Prediction. ArXiv:1703.08966 [Cs], 37(1). <https://doi.org/10.1145/3132703>

Touya, G., Zhang, X., et Lokhat, I. (2019). « Is deep learning the new agent for map generalization ? » *International Journal of Cartography*, 5, 142-157. <https://doi.org/10.1080/23729333.2019.1613071>

Weibel, R., Keller, S., et Reichenbacher, T. (1995), "Overcoming the knowledge acquisition bottleneck in map generalization: The role of interactive systems and computational intelligence", *Spatial Information Theory A Theoretical Basis for GIS* (Vol. 988, p. 139-156). Springer. https://doi.org/10.1007/3-540-60392-1_10