

Interpolation spatiale avec un réseau de neurones génératif comme alternative au krigeage

Herbert RAKOTONIRINA^{1,2} Paul HONEINE¹ Olivier ATTEIA³ Antonin VAN EXEM²

¹ Univ Rouen Normandie, INSA Rouen Normandie, Université Le Havre Normandie, Normandie Univ, LITIS UR 4108, F-76000 Rouen, France

²Tellux, 76650 Petit-Couronne, France

³Université de Bordeaux, EPOC (UMR 5805), CNRS,33607 Pessac, France

Résumé – En géosciences, les méthodes d’interpolation spatiale peuvent être divisées en géostatistiques, non-géostatistiques ou hybrides. Le krigeage est une méthode couramment utilisée en géostatistique, sous l’hypothèse d’une distribution normale des données. De plus, il peut être très gourmand en ressources lorsqu’il est utilisé pour réaliser une interpolation avec un volume de données conséquent. Les méthodes non-géostatistiques ont bénéficié des avancées récentes des Réseaux Antagonistes Génératifs (GAN), mais elles exigent une quantité importante de données étiquetées pour produire des résultats performants. Les approches hybrides sont limitées de part leurs dépendances aux contraintes associées aux approches géostatistiques. Dans cet article, nous proposons une nouvelle méthode d’interpolation spatiale non-géostatistique par apprentissage profond, en se basant sur une technique de reconstruction d’image sans entraînement au préalable, permettant ainsi de surmonter les limites des GAN. Notre méthode utilise des connexions résiduelles et un sur-échantillonnage bi-cubique dans le but d’adapter la technique de reconstruction d’image à notre application. Elle s’appuie sur un réseau de neurones convolutifs pour produire une carte à partir d’une carte de valeurs aléatoires, en réduisant la différence entre la carte générée et les valeurs observées. L’approche proposée est évaluée sur un jeu de données de modèle numérique de terrain selon deux méthodes d’échantillonnage différentes : régulière et aléatoire. Les résultats montrent des performances supérieures par rapport à l’état de l’art des méthodes d’interpolation.

Abstract – In Geoscience, spatial interpolation methods can be divided into geostatistical, non-geostatistical and hybrid. Kriging is a commonly used method in geostatistics, under the assumption of a normal distribution of the data. Moreover, it can be very resource intensive when dealing with a large volume of data. Non-geostatistical methods, on the other hand, have benefited from recent advances in Generative Adversarial Networks (GANs), but they require a large amount of labeled data to produce efficient results. Hybrid approaches are limited by their dependencies on the constraints associated with the geostatistical approaches. In this paper, we propose a new non-geostatistical spatial interpolation method using deep learning. This approach is based on image reconstruction techniques without prior training, thus overcoming the limits of GANs. Our method uses skip connections and bi-cubic upsampling in order to adapt the image reconstruction technique to our application. It relies on a convolutional neural network to produce a map from a map of random values, by reducing the difference between the generated map and the observed values. The proposed approach is assessed on a dataset of a digital elevation model using two different sampling methods: regular and random. The results show competitive performances compared to state-of-the-art interpolation methods.

1 Introduction

L’interpolation spatiale est une technique utilisée en géomatique, en cartographie et en traitement d’images pour estimer des valeurs à des emplacements où les observations réelles ne sont pas disponibles. Elle permet de créer une surface continue à partir d’un ensemble de données discrètes en interpolant les valeurs manquantes entre les points de données. L’interpolation spatiale est utilisée dans plusieurs domaines, notamment la géologie, la météorologie, la télédétection, l’océanographie, la modélisation environnementale et tant d’autres. Elle est également utilisée dans les systèmes d’information géographique pour créer des cartes et des modèles de surfaces continues à partir de données ponctuelles ou discrètes. Les applications des méthodes d’interpolation spatiale peuvent présenter des contraintes notamment quant à la qualité et la quantité des données, qui sont souvent incomplètes, inexactes ou manquantes. L’interpolation peut être aussi un processus intensif en termes de complexité de calcul pour des jeux de données volumineux.

Au fil des années, les méthodes d’interpolation spatiale ont connu une évolution importante et ont pu bénéficier des dernières avancées dans le domaine de l’apprentissage statistique. Ces méthodes peuvent être regroupées en trois catégories : géostatistiques, non-géostatistiques et hybrides [4].

Le krigeage reste la méthode la plus utilisée en géostatistique. Elle consiste à estimer les valeurs inconnues à partir des valeurs mesurées, en se basant sur une analyse variographique qui décrit la façon dont la variance entre les valeurs d’une variable change en fonction de la distance spatiale qui les sépare. L’étude récente [5] propose un réseau de neurones dense (DNN) pour ajuster le variogramme, permettant ainsi l’automatisation de l’analyse variographique. Dans [6], les auteurs ont proposé une nouvelle méthode d’interpolation empirique de krigeage bayésien tenant compte de la lithologie du sol. Cependant, bien que ces nouvelles méthodes de krigeage soient intéressantes, elles reposent sur l’hypothèse de distribution normale des données. De plus, pour une interpolation spatiale en 3D, les temps de calcul peuvent être considérables.

Les avancées récentes en approches non-géostatistique reposent essentiellement sur les réseaux antagonistes génératifs (GAN), qui ne nécessitent pas d'a priori sur la distribution des données et qui sont adaptés aux jeux de données à grande échelle. Par exemple, l'article [1] utilise un GAN avec des mécanismes d'attention pour identifier les zones d'intérêt et générer une carte plus précise, tandis que [13] utilise un GAN conditionné par les valeurs observées pour réaliser l'interpolation spatiale. Une autre solution [10] consiste à utiliser une forêt d'arbres décisionnels où la notion de corrélation spatiale est ajoutée à l'aide de co-variables supplémentaires définies par les emplacements les plus proches. Toutefois, ces approches exigent souvent des quantités considérables de données, ce qui peut être un obstacle dans les applications d'interpolation spatiale où les données sont très limitées. Les approches hybrides consistent à combiner les méthodes géostatistiques aux méthodes non-géostatistiques, comme dans [7], où les auteurs utilisent d'abord un réseau de neurones puis un krigeage pour réaliser l'interpolation spatiale. Toutefois, de telles méthodes ne parviennent pas à s'affranchir des contraintes liées au krigeage.

L'objectif de cet article est de présenter une nouvelle méthode d'interpolation spatiale basée sur un réseau de neurones générateur encodeur-décodeur. Cette méthode vise à répondre aux différentes exigences importantes pour l'interpolation spatiale, à savoir l'absence d'hypothèse sur la nature de la distribution, le nombre très limité de données observées et la capacité de calcul. Pour ce faire, nous nous inspirons des avancées récentes en matière d'apprentissage statistique pour la reconstruction d'image. En particulier l'architecture encodeur-décodeur proposée dans [12] permet de recréer des images à partir des pixels restants sans apprentissage en amont. Cependant bien que cette méthode donne de très bons résultats pour l'image *inpainting*, il faudrait l'adapter pour convenir aux contraintes de l'interpolation spatiale dans notre contexte. Pour ce faire, nous proposons deux modifications majeures : (i) nous ajoutons des connexions résiduelles (*skip connections* en anglais) entre les couches d'encodeur et de décodeur, ce qui permet au modèle de capturer les relations complexes entre les points observés à différentes résolutions ; (ii) nous utilisons la fonction bi-cubique à la place du plus proche voisin pour le sur-échantillonnage dans le décodeur où l'utilisation de cette fonction permet de se rapprocher du krigeage car elle considère une plus grande quantité d'informations lors du sur-échantillonnage, prenant en compte ainsi les variations locales des données. Nous démontrons la pertinence de la méthode proposée sur un jeu de données de modèle numérique de terrain [5] avec un nombre de données observées limité à 1%.

2 Formulation du problème

Le problème d'interpolation spatiale consiste à estimer les valeurs d'une variable continue (par exemple, la température, la pression, etc.) en tout point de l'espace, en utilisant des informations provenant de valeurs échantillonnées en certains endroits de l'espace. Plus précisément, étant donné un ensemble de n points d'échantillonnage $(x_i, y_i)_{i=1}^n$ où $x_i \in \mathbb{R}^d$ représente les coordonnées spatiales de l'échantillon i et $y_i \in \mathbb{R}$ représente la valeur de la variable continue à estimer à cet emplacement, le but de l'interpolation spatiale est de déterminer




FIGURE 1 : Représentation du processus d'apprentissage pour une interpolation spatiale.

une fonction $f_\theta : \mathbb{R}^d \rightarrow \mathbb{R}$ qui peut prédire les valeurs y dans les endroits non échantillonnés, et où θ désigne l'ensemble de ses paramètres. Cette fonction d'interpolation peut être obtenue à partir d'une variété de modèles tels que les polynômes, les splines, le krigeage ou encore l'apprentissage statistique.

3 Méthode proposée

Dans cette section, nous présentons la méthode proposée pour réaliser une interpolation spatiale avec un réseau de neurones profond, en présentant la méthode d'interpolation spatiale et en détaillant l'architecture proposée.

3.1 Interpolation par apprentissage profond

Dans cette approche, la fonction f_θ est un réseau de neurones profond générateur qui prend en entrée un champ aléatoire Z et qui renvoie le champ $\hat{X} \subset \mathbb{R}^d$ de même dimension d , tel que $f_\theta(Z) = \hat{X}$ où θ représente les paramètres du réseau de neurones. L'objectif est donc de capturer les relations dans l'espace entre les points de valeurs observées x_1, \dots, x_n dans le champ X pour prédire les valeurs manquantes. Pour ce faire, les paramètres du réseau de neurones sont optimisés selon

$$\theta_{opt} = \arg \min_{\theta} E(f_\theta(Z); X), \quad (1)$$

où θ_{opt} représente la valeur de θ qui minimise la fonction objectif E , $f_{\theta_{opt}}(Z)$ permet donc d'obtenir le champ \hat{X} représentant les valeurs observées et interpolées. Dans le cadre d'une interpolation, la fonction objectif E n'est calculée qu'à partir des valeurs observées. Un masque binaire $m \in \mathbb{R}^d$ est utilisé pour ne prendre en compte que les points observés dans le champ X . Ainsi, la fonction objectif est donnée par

$$E(\hat{X}; X) = \left\| (X - \hat{X}) \odot m \right\|^2. \quad (2)$$

Ici, l'opérateur \odot désigne la multiplication élément par élément (ou produit de Hadamard) entre la matrice des différences $(X - \hat{X})$ et le masque binaire m . La norme au carré de cette expression mesure l'erreur quadratique entre les valeurs observées et interpolées. Le processus d'apprentissage pour une interpolation est décrit par la Figure 1.




FIGURE 2 : L'architecture du réseau de neurones f pour réaliser une interpolation spatiale.

3.2 Architecture proposée

L'architecture que nous proposons est représentée par la figure 2, elle se divise en deux parties bien distinctes. La première partie est conçue pour réduire la dimension de Z en compressant les informations les plus importantes, jusqu'à l'obtention d'un vecteur de dimensions réduites. La seconde partie, quant à elle, se concentre sur l'augmentation de la dimension du vecteur compressé pour obtenir l'ensemble \hat{X} . Il est important de noter que le champ aléatoire Z et le champ \hat{X} ont la même dimension \mathbb{R}^d .

Dans la partie de réduction de dimension ou encodeur, nous utilisons un réseau de neurones convolutionnel. Les couches de convolution, chacune suivie par une fonction de normalisation de batch et de fonction Leaky Rectified Linear unit (Leaky ReLU), agissent comme un filtre avec un noyau qui se déplace sur l'ensemble du champ. Le transfert d'informations par le biais du noyau entre chaque couche de convolution est bien adapté à l'apprentissage de la configuration spatiale, comme récemment corroboré dans [3]. C'est en partie grâce à ce processus que le réseau de neurones est capable de récupérer les relations spatiales complexes entre les points observés.

La deuxième partie, appelée le décodeur, vise à augmenter la dimension jusqu'à l'obtention du champ \hat{X} . Le décodeur est également composé de couches de convolution, mais à la place des opérations de réduction, nous avons des couches d'upsampling ou de sur-échantillonnage. En outre, par rapport à la méthode d'inpainting proposée par [12], où ils affirment que l'ajout de connexions résiduelles (*skip connections*) est très préjudiciables à l'efficacité de l'approche et que la fonction d'optimale de sur-échantillonnage est la méthode de plus proche voisin. Dans l'architecture que nous proposons, nous utilisons (i) des connexions résiduelles dans le but de concaténer les caractéristiques à haute résolution provenant de l'encodeur avec celles du décodeur, (ii) et la fonction bi-cubique pour le sur-échantillonnage, comme décrit dans la suite.

Les connexions résiduelles entre les couches de convolutions sont une technique importante pour la construction de réseaux de neurones profonds. Elles permettent de résoudre certains des problèmes liés à l'entraînement des modèles. Dans notre cas d'étude, l'ajout des connexions résiduelles s'avère très bénéfique du fait de la limite des données observées. En effet, contrairement aux expérimentations réalisées dans [12] sur 50% de données observées, nous nous limitons à 1%. En raison de la non-linéarité introduite par les fonctions d'activation entre les couches de convolution, certaines informations

TABLE 1 : MAE et RMSE des différentes méthodes en fonction de la stratégie d'échantillonnage

	Région 1		Région 2		Région 3		Région 4		Moyenne		
	S1	S2	S1	S2	S1	S2	S1	S2	S1	S2	
MAE	OK [8]	6.16	7.20	10.57	13.32	7.01	7.88	5.40	7.27	7.29	8.92
	DNN-OK [5]	6.21	13.86	10.63	13.86	7.17	11.27	5.34	8.63	7.34	11.91
	DIP [12]	6.25	7.21	11.28	10.75	6.37	8.66	5.45	6.75	7.34	8.34
	Méthode proposée	5.96	6.91	10.48	10.10	5.86	8.41	5.19	6.29	6.87	7.93
RMSE	OK [8]	9.10	10.67	14.55	18.29	10.03	10.53	7.25	11.04	10.23	12.63
	DNN-OK [5]	9.21	54.28	14.73	19.62	10.41	25.05	7.34	15.89	10.42	28.71
	DIP [12]	8.62	11.23	16.05	15.01	8.83	12.69	8.15	9.82	10.41	12.19
	Méthode proposée	8.28	10.60	14.86	13.95	8.33	12.65	7.47	8.71	9.73	11.47

peuvent d'être perdues ou déformées au fur et à mesure de l'avancement dans le réseau. La connexion résiduelle permet donc de conserver ces informations complexes entre différentes échelles spatiales, comme récemment corroboré dans [11], ce qui permet d'avoir une carte interpolée plus précise avec des détails plus fins.

Les principales méthodes de sur-échantillonnage sont le plus proche voisin et la fonction bilinéaire. La première consiste à reproduire chaque pixel selon son plus proche voisin sans modification. La fonction bilinéaire calcule la valeur du nouveau pixel à partir des quatre points les plus proches. Nous proposons d'utiliser la fonction bi-cubique qui prend en compte les 16 pixels voisins dans l'image d'entrée pour estimer la valeur des nouveaux pixels. Pour ce faire, elle utilise une approximation polynomiale cubique pour calculer les nouvelles valeurs. La fonction d'interpolation bi-cubique est plus coûteuse en termes de temps de calcul que les autres fonctions d'interpolation. Dans notre cas d'étude, son utilisation dans l'étape de sur-échantillonnage nous permet d'obtenir une carte plus lisse et plus réaliste. En effet, contrairement aux autres méthodes d'interpolation, elle prend en compte une plus grande quantité d'information permettant ainsi de capturer les variations locales des données à l'instar du krigeage. Cette fonction permet donc de traiter les problématiques liées à la limitation des quantités de données observées.

Les expérimentations montrent l'apport des connexions résiduelles et de la fonction bi-cubique par rapport aux autres méthodes.

4 Expérimentations

Cette section a pour objectif d'évaluer les performances de notre modèle, en le comparant avec l'état de l'art de l'interpolation spatiale. Pour cela, nous utilisons un jeu de données de modèle numérique de terrain [5]. Ce jeu de données est composé de quatre régions de 100×100 pixels. La qualité de l'interpolation spatiale dépend fortement de la distribution des données observées. Ainsi, nous avons opté pour deux stratégies d'échantillonnage qui ne couvrent que 1% des données totales. La première stratégie, appelée S1, est composée de 100 points régulièrement répartis sur une grille, avec un espacement de 10 unités entre chaque point. La deuxième stratégie, S2, est composée de 100 points distribués aléatoirement sur l'ensemble des données. La méthode proposée est comparée au krigeage ordinaire (OK) en utilisant [8], à une nouvelle méthode de krigeage qui utilise un réseau de neurones dense pour ajuster automatiquement le variogramme (DNN-OK) [5] et à une architecture semblable à la partie inpainting de la méthode Deep Image Prior (DIP) [12]. Les résultats en termes d'er-




FIGURE 3 : Représentation des résultats de l'interpolation pour chaque méthode dans la Région 3 avec la stratégie d'échantillonnage S1. Les croix rouges de la première figure représentent les points observés.




FIGURE 4 : Comparaison des MAE entre la méthode DIP, la méthode DIP avec des connexions résiduelles DIP (skip), la méthode DIP avec une fonction de sur-échantillonnage en bicubic DIP (bicubic) et la méthode proposée.

leur absolue moyenne (MAE) et l'erreur quadratique moyenne (RMSE) entre la carte prédite et la carte réelle, présentés dans Table 1, montrent que la méthode proposée a des résultats compétitifs par rapport aux deux méthodes de krigeage. Il est aussi important de noter que la méthode proposée donne dans tous les cas de meilleurs résultats que l'approche DIP même si les résultats sont très proches comme le montre la figure 3. La figure 4 montre l'intérêt des modifications que nous proposons par rapport à l'approche DIP.

5 Conclusion

Dans cet article, nous avons présenté une nouvelle approche d'interpolation spatiale par apprentissage profond en adaptant l'architecture d'une méthode de reconstruction d'image sans apprentissage en amont. Cette méthode utilise des réseaux de convolution pour capturer la configuration spatiale et les liens entre les points observés. Nous avons montré dans les expériences la pertinence des modifications de l'architecture que nous avons proposé pour réaliser une interpolation spatiale. Les résultats montrent que la méthode proposée donne des résultats compétitifs par rapport aux autres méthodes d'interpolation spatiale. En outre, la flexibilité de cette méthode permet de réaliser une interpolation spatiale en 3D en adaptant l'architecture des réseaux de convolution. Ces résultats ouvrent de nouvelles perspectives pour l'utilisation de l'apprentissage profond dans les problèmes d'interpolation spatiale.

6 Remerciements

Nous tenons à remercier l'ADEME (Agence de transition écologique) et l'entreprise Tellux pour le financement de ce travail de recherche.

Références

- [1] Yujia GAO, Liang LIU, Chi ZHANG, Xiao WANG et Huadong MA : SI-AGAN : Spatial interpolation with attentional generative adversarial networks for environment monitoring. *Frontiers in Artificial Intelligence and Applications*, 325:8, 2020.
- [2] Ian GOODFELLOW, Jean POUGET-ABADIE, Mehdi MIRZA, Bing XU, David WARDE-FARLEY, Sherjil OZAIR, Aaron COURVILLE et Yoshua BENGIO : Generative adversarial networks. *Communications of the ACM*, 63(11):139–144, 2020.
- [3] Honggeun JO et Michael J PYRCZ : Automatic semivariogram modeling by convolutional neural network. *Mathematical Geosciences*, 54(1):177–205, 2022.
- [4] Jin LI et Andrew D HEAP : Spatial interpolation methods applied in the environmental sciences : A review. *Environmental Modelling & Software*, 53:173–189, 2014.
- [5] Yang LI, Zhong BAORONG, Xu XIAOHONG et Liang ZIJUN : Application of a semivariogram based on a deep neural network to ordinary kriging interpolation of elevation data. *Plos one*, 17(4):e0266942, 2022.
- [6] Ziyang LI, Huan TAO, Dan ZHAO et Hengkai LI : Three-dimensional empirical bayesian kriging for soil pahas interpolation considering the vertical soil lithology. *Catena*, 212:106098, 2022.
- [7] Guan-Yu LIN, Yi-Ming LEE, Chuen-Jinn TSAI et Chia-Ying LIN : Spatial-temporal characterization of air pollutants using a hybrid deep learning/kriging model incorporated with a weather normalization technique. *Atmospheric Environment*, 289:119304, 2022.
- [8] Mirko MÄLICKÉ, Egil MÖLLER, Helge David SCHNEIDER et Sebastian MÜLLER : mmaelicke/scikit-gstat : A scipy flavoured geostatistical variogram analysis toolbox, 2021.
- [9] Sebastian MÜLLER, Lennart SCHÜLER, Alraune ZECH et Falk HESSE : Gstools v1.3 : a toolbox for geostatistical modelling in python. *Geoscientific Model Development*, 15(7):3161–3182, 2022.
- [10] Aleksandar SEKULIĆ, Milan KILIBARDA, Gerard HEUVELINK, Mladen NIKOLIĆ et Branislav BAJAT : Random forest spatial interpolation. *Remote Sensing*, 12(10):1687, 2020.
- [11] Quang Nhat TRAN et Shih-Hsuan YANG : Video frame interpolation via down-up scale generative adversarial networks. *Computer Vision and Image Understanding*, 220:103434, 2022.
- [12] Dmitry ULYANOV, Andrea VEDALDI et Victor LEMPITSKY : Deep image prior. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 9446–9454, 2018.
- [13] Di ZHU, Ximeng CHENG, Fan ZHANG, Xin YAO, Yong GAO et Yu LIU : Spatial interpolation using conditional generative adversarial neural networks. *International Journal of Geographical Information Science*, 34(4):735–758, 2020.