



HAL
open science

Metamodèle de la propagation d'ondes sismiques 3D par opérateur neuronal de Fourier (FNO) amélioré avec un transfert d'apprentissage.

Fanny Lehmann, Filippo Gatti, Michaël Bertin, Didier Clouteau

► To cite this version:

Fanny Lehmann, Filippo Gatti, Michaël Bertin, Didier Clouteau. Metamodèle de la propagation d'ondes sismiques 3D par opérateur neuronal de Fourier (FNO) amélioré avec un transfert d'apprentissage.. 16ème Colloque National en Calcul des Structures, Association Calcul des Structures et Modélisation (CSMA), May 2024, Presqu'île de Giens, France. 10.57745/LAI6YU . hal-04531803

HAL Id: hal-04531803

<https://hal.science/hal-04531803>

Submitted on 4 Apr 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Metamodèle de la propagation d'ondes sismiques 3D par opérateur neuronal de Fourier (FNO) amélioré avec un transfert d'apprentissage

F. Lehmann^{1,2}, F. Gatti², M. Bertin¹, D. Clouteau²

¹ CEA/DAM/DIF, Arpajon, France

² Université Paris-Saclay, CentraleSupélec, ENS Paris-Saclay, CNRS, Laboratoire de Mécanique Paris-Saclay, UMR 9026, France

Résumé — L'estimation de l'aléa sismique dans la zone d'une installation nucléaire doit prendre en compte un grand nombre d'incertitudes, et en particulier notre connaissance limitée de la géologie. Or, on sait que certaines caractéristiques géologiques peuvent créer des effets de site qui amplifient considérablement les mouvements du sol. En combinant la précision des simulations basées sur la physique et l'expressivité des réseaux neuronaux profonds, il devient possible de quantifier l'influence des hétérogénéités géologiques sur le mouvement du sol en surface.

Ce travail démontre l'utilisation d'un opérateur neuronal de Fourier factorisé (F-FNO, Factorized Fourier Neural Operator) qui apprend la relation entre des géologies hétérogènes 3D et les mouvements du sol générés par la propagation d'ondes sismiques à travers ces géologies. Le F-FNO a été entraîné sur la base de données HEMEW-3D composée de 30 000 simulations du mouvement du sol à travers des géologies génériques. Ensuite, une base de données plus petite a été construite spécifiquement pour la région du séisme du Teil (Ardèche, France, 2019). Le F-FNO est alors spécialisé sur cette base de données avec seulement 250 exemples. L'apprentissage par transfert a amélioré l'erreur de prédiction de 22 %.

Selon les critères d'adéquation (GOF, Goodness-Of-Fit), 91 % des prédictions ont un GOF excellent pour la phase (et 62 % pour l'enveloppe). Les mesures d'intensité du mouvement du sol sont, en moyenne, légèrement sous-estimées par le F-FNO. Cependant, le fait de prédire le mouvement du sol pour un ensemble de géologies hétérogènes donne accès à des intervalles de confiance. Dans ce cas, la borne supérieure prédite par le F-FNO est toujours supérieure au mouvement du sol simulé habituellement avec une seule géologie homogène. Ces résultats suggèrent donc que les opérateurs neuronaux sont un outil efficace pour quantifier la variabilité de mouvements du sol qu'une installation nucléaire peut subir.

Mots clés — Opérateurs neuronaux, F-FNO, SEM3D, Propagation sismique, Metamodèle

1 Introduction

Le séisme du Teil (M_w 4.9, 2019) est l'un des séismes majeurs en France métropolitaine au cours de la dernière décennie [1]. Il est survenu dans la vallée du Rhône, une zone industrielle dense avec une sismicité faible à modérée. Cela a ravivé l'intérêt pour les analyses d'aléa sismique dans cette région, et en particulier pour les installations nucléaires. Les analyses d'aléa sismique évaluent l'intensité des mouvements du sol en surface, en fonction de la sismicité régionale et du contexte géologique. Cependant, les caractéristiques géologiques sont généralement mal caractérisées, ce qui entraîne de grandes incertitudes dans la variabilité des mouvements du sol qui peuvent impacter l'installation nucléaire [2].

Pour quantifier l'influence des incertitudes géologiques, l'approche Monte-Carlo consiste à effectuer des milliers d'analyses avec des géologies différentes. Cette méthode devient irréalisable si les analyses sont très exigeantes en temps de calcul, ce qui est le cas lorsque l'on essaie d'atteindre des fréquences élevées et une résolution verticale élevée. Les simulations tridimensionnelles (3D) qui utilisent des méthodes numériques traditionnelles présentent un intérêt particulier : elles fournissent la réponse sismique générée par la source, à la surface libre, où le mouvement du sol est synthétisé par des capteurs virtuels.

La représentation des domaines géologiques en 3D est cruciale pour s'assurer que les effets de site sont correctement pris en compte dans les analyses d'aléa sismique. Les effets de site incluent des bassins sédimentaires ou des caractéristiques topographiques qui peuvent amplifier considérablement les

ondes sismiques et entraîner des dommages extrêmes. Pour modéliser les effets de site, des simulations numériques en 3D sont nécessaires [3], mais elles nécessitent des temps de calcul importants. En effet, les simulations 3D à haute fréquence (jusqu'à 10 Hz) demandent généralement plusieurs dizaines de milliers d'heures équivalent CPU (Computational Processing Unit) [4-6].

Il est donc nécessaire d'élaborer des méta-modèles suffisamment précis pour représenter des domaines géologiques en 3D et dont le coût de calcul permet une quantification avancée de l'incertitude. Il existe déjà plusieurs méthodes pour obtenir les caractéristiques des mouvements du sol, mais elles restent limitées. Les équations de prédiction du mouvement du sol (GMPE, Ground Motion Prediction Equation) ou les modèles de mouvement du sol (GMM, Ground Motion Model) prédisent les mesures d'intensité du mouvement du sol, telles que l'accélération maximale du sol (PGA, Peak Ground Acceleration), en apprenant la relation entre les paramètres du séisme (par exemple, la profondeur, la magnitude), les conditions géologiques à la position du capteur (par exemple, $V_{S,30}$, la vitesse moyenne des ondes de cisaillement dans les 30 premiers mètres), et les caractéristiques des sismogrammes. Leur applicabilité dépend du nombre de séismes enregistrés dans des contextes similaires au site nucléaire étudié. Pour pallier à ce problème, les modèles de régression par processus gaussien [7], les méthodes de chaos polynomial [8], ou la décomposition orthogonale [9], entre autres, utilisent des simulations numériques pour créer des bases de données synthétiques. Cependant, elles ne modélisent que des domaines géologiques 1D ou 2D et ne prédisent généralement que certaines caractéristiques du mouvement du sol, et non l'ensemble de la série temporelle.

Grâce aux progrès récents de l'intelligence artificielle (IA), la prédiction des mouvements du sol en fonction du temps et de l'espace est désormais possible [10, 11]. Les réseaux neuronaux convolutifs et les réseaux neuronaux physiquement informés (PINN, Physics-Informed Neural Networks [12]) se sont révélés très efficaces pour résoudre l'équation des ondes 2D [13, 14]. Toutefois, ces modèles doivent être réapprenus à partir de zéro chaque fois que la configuration (par exemple, le domaine géologique) change. Les opérateurs neuronaux offrent de nouvelles perspectives à l'IA en concevant des modèles d'apprentissage profond qui sont entraînés pour toute une famille de configurations [15, 16]. En effet, les opérateurs neuronaux apprennent la correspondance entre un espace fonctionnel de configurations géologiques et l'espace fonctionnel des mouvements du sol, dépendant du temps et de l'espace.

Parmi les nombreux opérateurs de neurones, l'opérateur neuronal de Fourier (FNO, Fourier Neural Operator, [17]) a donné des résultats prometteurs, et l'une de ses variantes a été appliquée avec succès pour prédire la propagation des ondes sismiques en 3D [18]. Bien que les géologies soient intrinsèquement tridimensionnelles, les prédictions des opérateurs neuronaux dépendent également de trois coordonnées : deux coordonnées spatiales pour décrire la position du capteur à la surface du domaine, et la coordonnée temporelle. Le traitement des entrées et sorties 3D amène plusieurs défis aux opérateurs neuronaux, en termes de mémoire, de complexité du modèle et de gestion des données [19]. Les variables 3D sont rarement traitées par les opérateurs neuronaux, et ce travail fait figure de pionnier dans ce domaine.

Cette étude utilise une méthode récente d'opérateur neuronal de Fourier factorisé (F-FNO, Factorized Fourier Neural Operator, [20]) pour prédire le mouvement du sol sur une base de données géologique spécifique au séisme du Teil (Section 2). En raison du coût d'acquisition des données et du temps d'entraînement du modèle, l'apprentissage par transfert est utilisé pour bénéficier d'un entraînement préalable du F-FNO sur une base de données générique. Ensuite, les prédictions des champs d'ondes sont évaluées à l'aide de métriques physiques et l'influence des incertitudes géologiques est quantifiée (Section ??).

2 Méthodes

2.1 La base de données d'entraînement HEMEW-3D

La base de données HEMEW-3D contient 30 000 géologies avec leurs champs d'ondes de vitesse associés¹. Chaque géologie est un domaine cubique de taille 9.6 km × 9.6 km × 9.6 km représentant la vitesse des ondes de cisaillement (ondes S) entre 1071 m/s et 4500 m/s. Ce jeu de données se veut aussi générique que possible pour permettre diverses applications. Par conséquent, les géologies ne sont liées à aucun contexte géologique connu. Au lieu de cela, chaque géologie contient des couches horizontales d'épaisseur aléatoire, et des hétérogénéités sont ajoutées dans chaque couche pour créer des

1. <https://entrepot.recherche.data.gouv.fr/dataset.xhtml?persistentId=doi:10.57745/LAI6YU>

valeurs de vitesse variables (Figure 1a). Il est important de noter que les géologies présentent de grandes hétérogénéités (le coefficient de variation moyen des hétérogénéités étant de 20%).

Un champ d’ondes de vitesse est associé à chaque géologie. Il a été créé par la propagation d’ondes sismiques provenant de la source du séisme du Teil, décrite comme un tenseur de moment de direction 48° , de pendage 45° , et d’inclinaison 88° , et de moment sismique $M_0 = 2.47e16$ N.m, [21]. Cependant, dans la base de données HEMEW-3D, la source est située plus profondément (-7.8 km) que la source réelle du séisme du Teil afin de permettre une propagation plus longue des ondes sismiques à l’intérieur du domaine. Le champ d’ondes de vitesse à trois composantes est synthétisé sur une grille de 16×16 capteurs virtuels situés à la surface du domaine, entre 1 s et 7.4 s avec un intervalle d’échantillonnage de 0.02 s. Les simulations de la propagation des ondes ont été réalisées avec le simulateur de tremblement de terre SEM3D² [6]. Les simulations numériques sont valables jusqu’à une fréquence de 5 Hz, la pollution numérique apparaissant à des fréquences plus élevées. Bien que les domaines géologiques soient intrinsèquement tridimensionnels (fonction des coordonnées spatiales x , y et z), il est important de noter que les champs d’ondes de vitesse du mouvement du sol dépendent également de trois variables : l’espace x et y , et le temps t .

2.2 Opérateur neuronal de Fourier factorisé (F-FNO)

Le principe de base du FNO consiste à considérer les opérateurs de convolution comme une multiplication des coefficients de Fourier [17]. Chaque couche de Fourier ℓ décompose ses entrées v_ℓ à l’aide de la transformée de Fourier rapide (FFT, \mathcal{F}) et multiplie les coefficients de Fourier obtenus par la FFT des poids de la couche R_ℓ :

$$v_{\ell+1} = \sigma(\mathcal{F}^{-1}(R_\ell \cdot \mathcal{F}(v_\ell)) + W_\ell v_\ell)$$

Le calcul est effectué efficacement en apprenant les poids dans l’espace de Fourier. On conserve les 16 premiers modes de Fourier dans les première et deuxième dimensions, et 32 modes dans la troisième dimension (à l’exception de la première couche qui a 16 modes).

Le F-FNO transforme les couches de Fourier en couches de Fourier factorisées en remplaçant la FFT 3D par la somme de trois FFT 1D sur chaque dimension, ce qui réduit considérablement le nombre de paramètres. TRAN et al. [20] a montré que l’erreur du F-FNO diminue lorsque le nombre de couches de F-Fourier augmente, ce qui n’est pas le cas pour le FNO original. Dans cette étude, le F-FNO est composé de 20 couches de Fourier factorisées, précédées d’un sous-réseau qui enrichit les entrées géologiques (de 1 canal à 16 canaux) par l’intermédiaire de deux couches denses. A la sortie du F-FNO, trois sous-réseaux projettent les variables à 16 canaux sur des variables physiques à 1 canal correspondant à la vitesse de surface. Chaque sous-réseau de projection est spécialisé pour l’une des trois composantes du champ d’ondes (Est-Ouest, Nord-Sud, Vertical) et comprend deux couches denses.

La base de données HEMEW-3D a été divisée en 27 000 données d’entraînement et 3 000 données de validation. L’optimiseur Adam a été utilisé avec un taux d’apprentissage de $6 \cdot 10^{-4}$ divisé par deux sur les plateaux, un *batch* de 16 et l’erreur absolue relative (rMAE, *relative Mean Absolute Error*) comme fonction de perte. Le F-FNO a été entraîné pendant 350 époques, ce qui a pris 24 heures sur 4 GPUs Nvidia A100.

2.3 La base de données du Teil pour l’apprentissage par transfert

Étant donné les temps de calcul nécessaires pour simuler une base de données comme HEMEW-3D (1.6 million d’heures équivalent CPU), il n’est pas souhaitable de construire de nouvelles grandes bases de données lorsque l’on souhaite étudier une région cible. Avec l’apprentissage par transfert, on bénéficie d’un modèle pré-entraîné que l’on spécialise avec un entraînement une base de données plus petite et adaptée à la région visée [22].

Des hétérogénéités ont été ajoutées à la *géologie de référence* pour obtenir un ensemble de 4000 géologies plausibles dans la région. Les hétérogénéités sont représentées par des champs aléatoires ayant les mêmes paramètres que la base de données HEMEW-3D : longueurs de corrélation comprises entre 1.5 km et 6 km, coefficients de variation normalement distribués autour de 20% avec un écart type de 10%, et noyau de corrélation de von Karman [2]. Pour faciliter l’interprétation des résultats, toutes les

2. <https://github.com/sem3d/SEM>




FIGURE 1 – (a) Schéma de génération de la base de données HEMEW-3D. (b) V_S dans la base de données du Teil. Pour chacun des 32 niveaux verticaux, la moyenne μ , l'écart-type σ et les percentiles sont calculés sur l'ensemble des points horizontaux des 4 000 données.

Inspiré.e.s par le modèle de vitesse 1D utilisé pour reproduire le séisme du Teil [23], nous avons conçu une base de données de 4000 géologies issues de ce modèle. La *géologie de référence* est un domaine 3D avec six couches horizontales homogènes et les vitesses des ondes S décrites dans le tableau 1. Le rapport des vitesses des ondes P et S (V_P et V_S) est supposé constant et égal à 1.7. Les facteurs de densité et d'atténuation sont calculés à partir de V_P et V_S [24].

Épaisseur (m)	V_S (m/s)
600	2100
600	3500
300	1200
600	2300
5700	3500
1800	4500

TABLE 1 – Modèle géologique 1D de référence pour la région du Teil. Vitesse des ondes S (V_S) et épaisseur de chaque couche horizontale (adapté de [23]).

couches de la base de données du Teil partagent les mêmes paramètres, ce qui n'est pas le cas pour la base de données HEMEW-3D (cela ne signifie pas que les hétérogénéités sont situées au même endroit dans toutes les couches, elles ont seulement des propriétés similaires). La Figure 1b montre la distribution verticale des vitesses des ondes S. Les mouvements du sol ont été obtenus exactement de la même manière que pour la base de données HEMEW-3D.

Parmi les 4000 paires de géologies et de champs d'ondes, jusqu'à 3000 ont été utilisées pour l'entraînement, 300 pour la validation et 700 pour tester le modèle. Avec l'apprentissage par transfert, les poids de l'opérateur neuronal sont initialisés avec les poids du F-FNO entraîné sur la base de données HEMEW-3D. Ensuite, le modèle est entraîné uniquement sur des échantillons de la base de données du Teil, ce qui l'oblige à se spécialiser dans le contexte du Teil et à améliorer ses prédictions. Le nombre de données utilisées pour le deuxième entraînement est appelé nombre d'échantillons de transfert (*transfer learning samples*) et est noté N_{TL} .

3 Résultats

3.1 Avantages de transfert de l'apprentissage

La figure 2 illustre les avantages de l'apprentissage par transfert, même avec un petit nombre de données spécifiques. À des fins de comparaison, le F-FNO a d'abord été entraîné sans pré-entraînement, ce qui signifie que les poids ont été initialisés de manière aléatoire. À la fin de l'entraînement avec 3 000 données spécifiques au Teil, la rMAE était de 40.4 % (ligne grise en pointillés). Avec l'apprentissage par




FIGURE 2 – Évolution de l’erreur rMAE d’entraînement (lignes pleines) et de l’erreur de validation (lignes pointillées), pour un F-FNO entraîné sur la base de données du Teil. Quatre entraînements sont présentés : initialisation aléatoire sans pré-entraînement (lignes grises), apprentissage par transfert avec 250 données (lignes bleues), 1000 données (lignes orange), 3000 données (lignes vertes).

transfert, le F-FNO est initialisé avec les poids du modèle pré-entraîné sur la base de données génériques HEMEW-3D. Après spécialisation sur les données du Teil, la rMAE a été réduite à 31.3 % avec seulement 250 données de transfert (ligne pointillée bleue).

Bien que la rMAE soit pertinente pour entraîner l’opérateur neuronal, cette métrique ne renseigne pas sur l’information physique contenue dans les prédictions du F-FNO. Les critères d’adéquation (GOF, Goodness-Of-Fit) donnent une meilleure évaluation de la précision du F-FNO. Les GOFs ont été calculés à chaque point de la surface et pour chaque donnée de test (donc ces données n’ont pas été vues par le F-FNO pendant l’apprentissage). Le GOF évalue l’accord entre les séries temporelles prédites et les séries temporelles simulées considérées comme la *ground truth*, en termes d’enveloppe et de phase [25]. Les GOF sont donnés sur une échelle variant de 0 à 10, où 10 signifie un accord parfait, et 8 est généralement considéré comme excellent.

La figure 3 montre la distribution cumulative du GOF d’enveloppe et du GOF de phase lorsque le nombre d’échantillons d’apprentissage par transfert augmente. On remarque tout d’abord que les distributions sont plus décalées vers la droite pour le GOF de phase que pour le GOF d’enveloppe, ce qui signifie que la F-FNO prédit mieux les temps d’arrivée des ondes (adéquation de la phase) que des amplitudes parfaitement exactes (adéquation d’enveloppe). Avec 250 données de transfert, 91 % des prédictions ont un GOF de phase supérieur à 8, ce qui est très proche de la performance obtenue avec 3000 données de transfert (94 % des prédictions ayant un GOF de phase supérieur à 8). En ce qui concerne l’enveloppe, 62 % des prédictions atteignent un GOF supérieur à 8 avec 250 données de transfert. Il est possible d’entraîner le F-FNO avec moins de 250 données de transfert mais cela dégrade la précision (43 % des prédictions ont un GOF d’enveloppe supérieur à 8 lorsque seulement 20 données de transfert sont utilisées).

3.2 Précision des prédictions

Les GOF de l’enveloppe indiquent qu’il est difficile de prédire des séries temporelles avec des amplitudes exactes pour toute la durée du signal. Or, l’amplitude du mouvement du sol étant corrélée à l’intensité des secousses, il est crucial de s’assurer que le F-FNO donne des estimations fiables du mouvement du sol. La vitesse maximale du sol (PGV, Peak Ground Velocity) a été calculée comme la valeur maximale de la moyenne géométrique des deux composantes horizontales. Comme toutes les séries temporelles sont synthétiques, il convient de noter que le PGV correspond à une fréquence maximale de 5 Hz. Pour chaque donnée et chaque point de la surface, la précision de la PGV a été définie comme le biais relatif entre la prédiction et la référence simulée.

La figure 4 montre le biais relatif de la PGV en fonction de l’amplitude des hétérogénéités de la géologie associée. On remarque que les prédictions sont excellentes lorsque les hétérogénéités ont une




FIGURE 3 – Distribution cumulative des GOFs pour l’enveloppe (à gauche) et la phase (à droite), en fonction du nombre de données de transfert (lignes colorées). Les résultats sont présentés pour 700 données de test.

faible amplitude. En effet, le biais relatif de PGV est inférieur à 3 % pour des coefficients de variation inférieurs à 0.05. Ensuite, en moyenne, le F-FNO tend à sous-estimer légèrement le PGV. En effet, le biais relatif moyen de la PGV se situe entre 1 % et -4 % pour des coefficients de variation autour de 0.1. Lorsque les hétérogénéités ont des amplitudes importantes (coefficients de variation supérieurs à 0.2), la sous-estimation s’aggrave généralement. Toutefois, si l’on considère un nombre suffisamment important de prédictions, il n’existe pas de point où la PGV est systématiquement sous-estimée. Par conséquent, en utilisant la PGV maximale d’un ensemble de géologies hétérogènes, certaines prédictions du F-FNO seront toujours plus grandes que la référence simulée. Ce résultat reste valable si l’on ne considère que les géologies dont le coefficient de variation est inférieur à 0.1.

La figure 5 compare la prédiction du F-FNO et la référence simulée pour quatre géologies (au même point de la surface). Les prédictions sont excellentes lorsque les géologies ont de faibles coefficients de variation (figures du haut). On peut également remarquer que les différences de phase sont significatives entre les échantillons et que le F-FNO est capable de capturer cette variabilité. La figure inférieure gauche illustre une légère surestimation du PGV, même si les petites variations sont encore très bien capturées. La figure inférieure droite (coefficient de variation égal à 0.2) illustre une situation où les hétérogénéités ont créé une amplification du mouvement du sol autour de 3.7 s, ce qui peut correspondre à une arrivée plus tardive des ondes S. Ce cas singulier n’est pas bien prédit par le F-FNO, ce qui suggère que les géologies avec des coefficients de variation supérieurs à 0.2 deviennent difficiles à prédire précisément.

3.3 Implications pour l’aléa sismique

L’influence des hétérogénéités sur le mouvement du sol peut également être évaluée en termes d’accélération pseudo-spectrale (PSA, Pseudo-Spectral Acceleration) avec un taux d’amortissement de 5 %. Avec la géologie 1D de référence, on obtient une valeur de PSA pour chaque point de la surface et chaque période considérée (0.3 s, 1 s et 3 s). Sur la figure 6, la partie inférieure droite représente la carte de PSA (grille 16 × 16) calculée sur la géologie de référence 1D pour la période $T=0.3$ s. Les courbes de PSA bleues dans les trois autres figures sont des extractions de la carte PSA le long de la ligne bleue horizontale (capteurs parallèles à l’axe des x).

On peut alors calculer le PSA sur cette ligne pour toutes les géologies dont le coefficient de variation est inférieur à 0.2. La figure 6 montre que la borne supérieure de la distribution prédite du PSA (zone rouge) est significativement plus grande que le PSA du modèle 1D de référence (ligne bleue). Cela signifie que, même si les prévisions du F-FNO ne sont pas parfaites, l’utilisation d’un ensemble de géologies hétérogènes offre une marge de sécurité par rapport à la méthode habituelle qui consiste à considérer un seul modèle homogène.




FIGURE 4 – Chaque géologie de la base de test est représentée par son coefficient de variation (axe des x). Pour le champ d’ondes associé, l’erreur relative sur la PGV est indiqué par la moyenne du biais sur tous les capteurs (point noir) et l’écart-type (barre d’erreur grise).

On peut également remarquer que les erreurs entre les PSA prédites (zones grises) et les PSA réelles (zones rouges) diminuent lorsque la période augmente. Cela reflète les conclusions précédentes selon lesquelles les variations de petite échelle sont plus difficiles à prédire que les évolutions à grande échelle [18].

4 Discussion et conclusion

Nous avons entraîné un opérateur neuronal de Fourier factorisé (F-FNO) sur la base de données générique HEMEW-3D afin de prédire la relation entre les géologies et le mouvement du sol en surface. L’acquisition de la base de données de simulations haute-fidélité requiert des temps de calcul importants, et l’entraînement d’un opérateur neuronal 3D sur une grande base de données nécessite également des ressources informatiques importantes. Cependant, le F-FNO pré-entraîné est disponible et peut être utilisé comme initialisation pour un second entraînement beaucoup moins coûteux grâce à l’apprentissage par transfert. Nous avons montré qu’il suffisait de 250 données de transfert pour obtenir une précision quasi optimale pour une base de données de mouvements du sol basée sur le séisme du Teil. Cet apprentissage n’a pris que 26 minutes sur un GPU Nvidia A100, ce qui le rend abordable pour d’autres applications spécifiques à des sites d’intérêt.

Nous avons prouvé que le F-FNO a une excellente précision de phase pour 91% des prédictions et une excellente précision d’amplitude pour plus de 62% des prédictions (GOF plus grand que 8). L’intensité du mouvement du sol a été évaluée à l’aide de la vitesse maximale du sol (PGV) et de l’accélération pseudo-spectrale (PSA). Les résultats indiquent que le F-FNO tend à sous-estimer légèrement les mesures d’intensité lorsque l’on compare les prédictions et les simulations pour la même géologie. Cependant, lorsque l’on examine un ensemble de géologies hétérogènes, les prédictions du F-FNO sont statistiquement plus élevées que les mesures d’intensité obtenues avec une seule simulation de la géologie homogène de référence. Cela indique que les opérateurs neuronaux sont des outils appropriés pour quantifier les incertitudes sur les mouvements du sol découlant d’une connaissance limitée de la géologie sous une installation nucléaire. De plus, comme les prédictions sont des séries temporelles de mouvements du sol, n’importe quelle mesure d’intensité peut être calculée pour les analyses d’aléa sismique.

Il convient toutefois de noter que l’apprentissage par transfert a été utilisé entre des géologies de même taille et avec la même source sismique. L’extension des domaines à des zones plus vastes et la modification de la position et de l’orientation de la source n’entraient pas dans le cadre de cette étude. L’apprentissage par transfert peut aider dans ces directions, mais les propriétés fondamentales des opérateurs neuronaux devraient également être explorées.

L’apprentissage par transfert a également été appliqué avec succès à une base de données de géologies




FIGURE 5 – Mouvements du sol correspondant à trois géologies avec des coefficients de variation de 0.05 (en haut à gauche), 0.1 (en haut à droite), 0.2 (en bas à gauche et à droite). Les séries temporelles sont représentées au même capteur pour les résultats de la simulation (ligne noire) et les prédictions du F-FNO (ligne pointillée rouge).

contenant des inclusions de points durs (non montrée ici). Bien que cette base de données ne provienne pas d'une géologie de référence et que les points durs aient des formes et des emplacements très différents à l'intérieur du domaine, les prédictions du F-FNO étaient précises avec seulement 500 données de transfert. En conséquence, l'apprentissage par transfert sur les opérateurs neuronaux semble prometteur pour réduire les coûts de calcul associés à l'acquisition de données synthétiques et à l'entraînement de larges modèles d'apprentissage profond.

Références bibliographiques

- [1] M. CAUSSE et al. "Exceptional Ground Motion during the Shallow Mw 4.9 2019 Le Teil Earthquake, France". In : *Communications Earth & Environment* 2.1 (déc. 2021), p. 14. ISSN : 2662-4435. DOI : 10.1038/s43247-020-00089-0. (Visité le 11/01/2022).
- [2] F. LEHMANN et al. "Machine Learning Opportunities to Conduct High-Fidelity Earthquake Simulations in Multi-Scale Heterogeneous Geology". In : *Frontiers in Earth Science* 10 (2022). ISSN : 2296-6463. DOI : 10.3389/feart.2022.1029160.
- [3] C. ZHU et al. "Seismic Aggravation in Shallow Basins in Addition to One-dimensional Site Amplification". In : *Journal of Earthquake Engineering* 24.9 (1^{er} sept. 2020), p. 1477-1499. ISSN : 1363-2469. DOI : 10.1080/13632469.2018.1472679.




FIGURE 6 – Accélération pseudo-spectrale (PSA) aux périodes 0.3 s, 1 s et 3 s pour une ligne de capteurs parallèle à l’axe des x et située à $y=5$ km. Le panneau inférieur droit montre la PSA de la géologie de référence pour tous les points de la surface et indique la ligne où les courbes ont été calculées (ligne horizontale bleue). Sur les courbes de PSA (trois autres panneaux), la ligne bleue indique la PSA obtenue avec la géologie 1D de référence, la ligne noire indique la PSA simulée moyenne pour les géologies dont le coefficient de variation est inférieur à 0.2, et la ligne rouge indique la prédiction moyenne pour les mêmes géologies.

- [4] F. DE MARTIN et al. “Influential Parameters on 3-D Synthetic Ground Motions in a Sedimentary Basin Derived from Global Sensitivity Analysis”. In : *Geophysical Journal International* 227.3 (1^{er} déc. 2021), p. 1795-1817. ISSN : 0956-540X. DOI : 10 . 1093 / gji / ggab304. (Visité le 06/07/2023).
- [5] A. HEINECKE et al. “Petascale High Order Dynamic Rupture Earthquake Simulations on Heterogeneous Supercomputers”. In : SC ’14 : Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis. New Orleans, LA, USA, nov. 2014, p. 3-14. ISBN : 2167-4337. DOI : 10.1109/SC.2014.6.
- [6] S. TOUHAMI et al. “SEM3D : A 3D High-Fidelity Numerical Earthquake Simulator for Broadband (0–10 Hz) Seismic Response Prediction at a Regional Scale”. In : *Geosciences* 12.3 (2 mars 2022), p. 112. ISSN : 2076-3263. DOI : 10.3390/geosciences12030112. (Visité le 25/04/2022).
- [7] A. ALIMORADI et J. L. BECK. “Machine-Learning Methods for Earthquake Ground Motion Analysis and Simulation”. In : *Journal of Engineering Mechanics* 141.4 (avr. 2015), p. 04014147. ISSN : 0733-9399, 1943-7889. DOI : 10 . 1061 / (ASCE) EM . 1943 - 7889 . 0000869. (Visité le 11/01/2022).
- [8] P. SOCHALA, F. DE MARTIN et O. LE MAÎTRE. “Model Reduction for Large-Scale Earthquake Simulation in an Uncertain 3D Medium”. In : *International Journal for Uncertainty Quantification*

- 10.2 (2020), p. 101-127. ISSN : 2152-5080. DOI : 10.1615/Int.J.UncertaintyQuantification.2020031165. (Visité le 11/01/2022).
- [9] J. M. REKOSKE, A.-A. GABRIEL et D. A. MAY. “Instantaneous Physics-Based Ground Motion Maps Using Reduced-Order Modeling”. In : *Journal of Geophysical Research : Solid Earth* 128.8 (août 2023), e2023JB026975. ISSN : 2169-9313, 2169-9356. DOI : 10.1029/2023JB026975. (Visité le 24/08/2023).
- [10] S. BLOEMHEUVEL et al. “Graph Neural Networks for Multivariate Time Series Regression with Application to Seismic Data”. In : *International Journal of Data Science and Analytics* 16.3 (sept. 2023), p. 317-332. ISSN : 2364-415X, 2364-4168. DOI : 10.1007/s41060-022-00349-6. (Visité le 24/08/2023).
- [11] Z. ZHANG et Y. WANG. “A Spatiotemporal Model for Global Earthquake Prediction Based on Convolutional LSTM”. In : *IEEE Transactions on Geoscience and Remote Sensing* (2023), p. 1-1. ISSN : 0196-2892, 1558-0644. DOI : 10.1109/TGRS.2023.3302316. (Visité le 17/08/2023).
- [12] M. RAISSI, P. PERDIKARIS et G. KARNIADAKIS. “Physics-Informed Neural Networks : A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations”. In : *Journal of Computational Physics* 378 (fév. 2019), p. 686-707. ISSN : 00219991. DOI : 10.1016/j.jcp.2018.10.045. (Visité le 10/01/2022).
- [13] Y. DING et al. “Self-Adaptive Physics-Driven Deep Learning for Seismic Wave Modeling in Complex Topography”. In : *Engineering Applications of Artificial Intelligence* 123 (août 2023), p. 106425. ISSN : 09521976. DOI : 10.1016/j.engappai.2023.106425. (Visité le 22/05/2023).
- [14] B. MOSELEY, A. MARKHAM et T. NISSEN-MEYER. *Solving the Wave Equation with Physics-Informed Deep Learning*. 2020. DOI : 10.48550/arxiv.2006.11894. preprint.
- [15] Z. LI et al. *Neural Operator : Graph Kernel Network for Partial Differential Equations*. 6 mars 2020. arXiv : 2003.03485. URL : <http://arxiv.org/abs/2003.03485> (visité le 13/06/2022). preprint.
- [16] L. LU et al. “Learning Nonlinear Operators via DeepONet Based on the Universal Approximation Theorem of Operators”. In : *Nature Machine Intelligence* 3.3 (1^{er} mars 2021), p. 218-229. ISSN : 2522-5839. DOI : 10.1038/s42256-021-00302-5.
- [17] Z. LI et al. “Fourier Neural Operator for Parametric Partial Differential Equations”. In : *International Conference on Learning Representations*. 2021. DOI : 10.48550/arXiv.2010.08895.
- [18] F. LEHMANN et al. “Fourier Neural Operator Surrogate Model to Predict 3D Seismic Waves Propagation”. In : 5th ECCOMAS Thematic Conference on Uncertainty Quantification in Computational Sciences and Engineering. Athens, Greece, juin 2023. DOI : 10.48550/ARXIV.2304.10242.
- [19] P. WITTE, R. HEWETT et R. CHANDRA. “Industry-Scale CO2 Flow Simulations with Model-Parallel Fourier Neural Operators”. In : *NeurIPS 2022 Workshop Tackling Climate Change with Machine Learning*. Déc. 2022. URL : <https://www.microsoft.com/en-us/research/publication/industry-scale-co2-flow-simulations-with-model-parallel-fourier-neural-operators/>.
- [20] A. TRAN et al. “Factorized Fourier Neural Operators”. In : *The Eleventh International Conference on Learning Representations*. 2023. URL : <https://openreview.net/forum?id=tmIiMP14IPa>.
- [21] B. DELOUIS et al. “Constraining the Point Source Parameters of the 11 November 2019 Mw 4.9 Le Teil Earthquake Using Multiple Relocation Approaches, First Motion and Full Waveform Inversions”. In : *Comptes Rendus. Géoscience* 353.S1 (8 sept. 2021), p. 1-24. ISSN : 1778-7025. DOI : 10.5802/crgeos.78. (Visité le 11/01/2022).
- [22] J. QUIÑONERO-CANDELA, éd. *Dataset Shift in Machine Learning*. Neural Information Processing Series. Cambridge, Mass : MIT Press, 2009. 229 p. ISBN : 978-0-262-17005-5 978-0-262-54587-7.

- [23] C. SMERZINI et al. “Regional Physics-Based Simulation of Ground Motion within the Rhône Valley, France, during the Mw 4.9 2019 Le Teil Earthquake”. In : *Bulletin of Earthquake Engineering* 21.4 (mars 2023), p. 1747-1774. ISSN : 1570-761X, 1573-1456. DOI : 10.1007/s10518-022-01591-w. (Visité le 24/08/2023).
- [24] F. LEHMANN. *Physics-Based Simulations of 3D Wave Propagation : A Dataset for Scientific Machine Learning*. Recherche Data Gouv, août 2023. DOI : 10.57745/LAIYU.
- [25] M. KRISTEKOVÁ, J. KRISTEK et P. MOCZO. “Time-Frequency Misfit and Goodness-of-Fit Criteria for Quantitative Comparison of Time Signals”. In : *Geophysical Journal International* 178.2 (août 2009), p. 813-825. ISSN : 0956540X, 1365246X. DOI : 10.1111/j.1365-246X.2009.04177.x. (Visité le 10/01/2022).