

Modèles de Flux Riemanniens pour l'Interférométrie SAR

Georges LE BELLIER* Dana EL HAJJAR† Arnaud BRELOY* Nicolas AUDEBERT‡,*

*Conservatoire national des arts et métiers, CEDRIC, EA4629, Paris, France

†Université Savoie Mont Blanc, LISTIC, EA3703, Annecy, France

‡Université Gustave Eiffel, ENSG, IGN, LASTIG, Saint-Mandé, France

Résumé – L'interférométrie SAR (InSAR) permet l'analyse des changements topologiques de sites naturels ou zones urbaines. Cependant, l'utilisation d'algorithmes de débruitage est nécessaire pour capturer l'information pertinente des interférogrammes. Dans cet article, nous exploitons la structure cyclique des phases interférométriques pour concevoir des modèles de transport de distributions efficaces et assurant la validité des données générées. Nous appliquons cette approche à *i*) la génération d'interférogrammes réalistes pour l'augmentation de données, *ii*) le débruitage d'interférogrammes. Nos expériences sur des données Sentinel-1 montrent l'efficacité des modèles de flux riemanniens pour ces applications.

Abstract – SAR interferometry (InSAR) enables the analysis of topological changes in natural sites or urban areas. However, the use of denoising algorithms is necessary to extract relevant information from interferograms. In this article, we exploit the cyclic structure of interferometric phases to design efficient distribution transports and ensure the validity of the data generated. We apply this approach to *i*) the generation of realistic interferograms for data augmentation, *ii*) the denoising of interferograms. Experiments on Sentinel-1 data illustrate the interest of these approaches.

1 Introduction

Les récentes missions de télédétection (Sentinel-1, UAVSAR, TerraSAR-X, etc.) ont permis d'obtenir une couverture sans précédent d'images de la Terre par radar à synthèse d'ouverture (SAR). Ces acquisitions, prises à intervalles régulières, rendent possible la surveillance de déformation de la surface de la Terre par interférométrie SAR (InSAR). Les applications concernent, par exemple, le suivi de l'affaissement des zones urbaines dû aux travaux de construction, ou l'analyse de faibles changements dans la topologie de sites naturels tels que les volcans. Dans ce contexte, l'information de déformation réside dans la différence de phases entre les pixels (à valeur complexe) de deux images SAR géoréférencées et alignées. Les images SAR présentant des statistiques de bruit particulières, de nombreux travaux traitent de l'estimation des déphasages InSAR et des cartes de déformation correspondantes. On peut relever deux grandes familles d'approches : celles se basant sur un débruitage d'images de phases (visant à lisser spatialement des observations bruitées de franges d'interférométrie), et celles se basant sur des techniques multi-temporelles [1] (parvenant au même but en tirant parti de tous les interférogrammes possibles d'une série temporelle). L'état de l'art récent des méthodes de débruitage d'images de phases InSAR met en œuvre des méthodes d'apprentissage profond [2, 3]. Parallèlement, les modèles génératifs récents, modèles de diffusion [4] et modèles de flux [5, 6] offrent des générations spectaculaires pour de nombreuses modalités (images, structures de molécules, texte...). Ces modèles entretiennent des liens forts avec les objectifs de débruitage. Leur application au domaine de l'InSAR offre donc une perspective prometteuse, mais n'a cependant pas encore été explorée. Le principal verrou réside probablement dans l'espace des images en question : les pixels des images SAR sont en effet à valeur complexe, et l'information utile en InSAR réside dans la phase de ceux-ci.

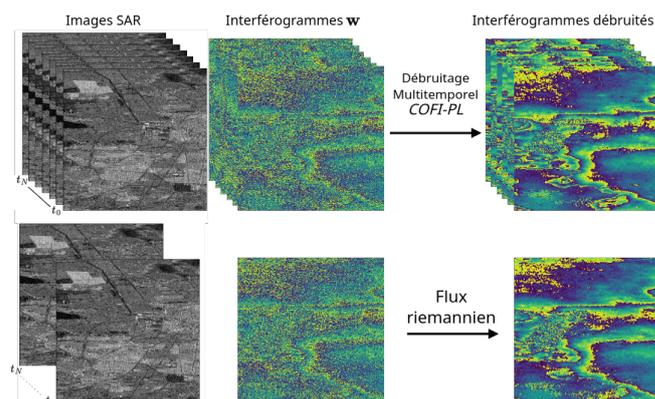


FIGURE 1 : Un modèle de flux riemannien (*bas*) apprend à prédire, à partir d'un unique interférogramme w , sa version débruitée estimée par un modèle traitant une série temporelle d'interférogrammes (*haut*).

Dans cette communication, nous adressons cette problématique sous le prisme de la géométrie : en assimilant un patch d'image de phase InSAR à un point sur un tore (de dimension appropriée), il devient possible de tirer parti de modèles de flux riemanniens [7]. Munis de ces outils, nous considérons alors deux problématiques : *i*) celle de la génération d'images de franges à vue de simulations réalistes [8]; *ii*) celle du débruitage d'images de phases InSAR. Pour ce second point, la plupart des travaux de l'état de l'art construisent généralement un jeu de données simulées pour contrôler la vérité terrain et le niveau de bruit. Nous proposons ici de transporter la distribution des images de phases "brutes" vers celles d'images débruitées par une méthode multi-temporelle (Figure 1). Nous obtenons ainsi un modèle appris sur des données réalistes, et permettant de débruiter efficacement une image InSAR, même lorsqu'une série temporelle n'est pas disponible.

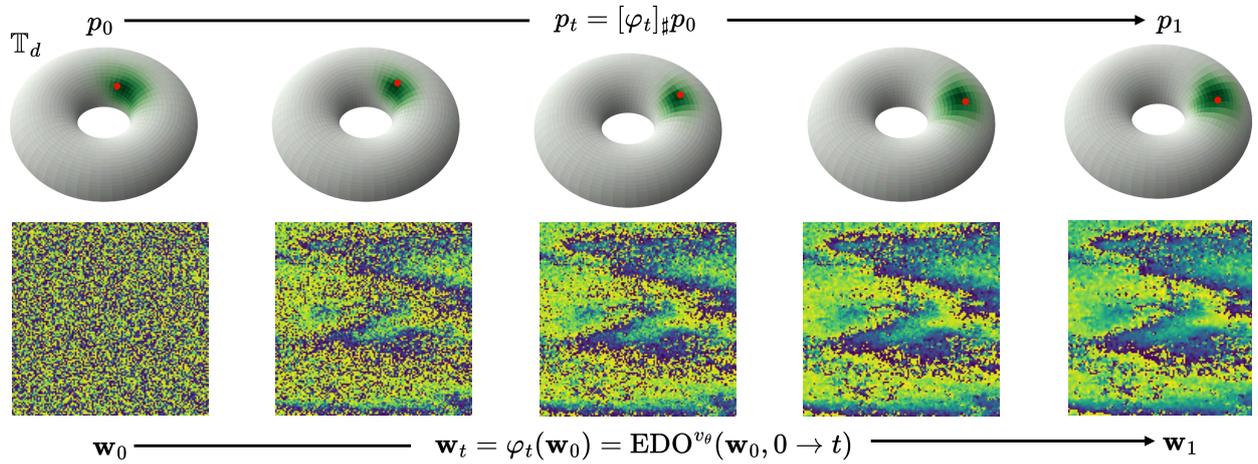


FIGURE 2 : Génération d'interférogrammes \mathbf{w}_1 par transport de la distribution p_0 vers la distribution p_{data} sur le tore \mathbb{T}_d . Les points sont obtenus par résolution par solveur numérique de l'équation différentielle du flux 1 en remplaçant la vitesse u_t par son approximation par le réseau de neurone $v_\theta(t, \cdot)$. L'interférogramme \mathbf{w}_t (en rouge) appartient à la distribution p_t (en vert) qui est transportée sur le tore \mathbb{T}_d par le flux riemannien, assurant ainsi la validité des phases prédites.

2 Interférométrie SAR

Un interférogramme (noté \mathbf{w}) représente la différence de phase entre deux images SAR alignées prises à des dates différentes et contient une information sur la géométrie de la zone observée. Si celle-ci n'est pas stable, on constate typiquement l'apparition de franges d'interférences qui, une fois déroulées, permettent une estimation de la déformation de la surface. Cependant, la perte de cohérence entre les signaux à ces deux dates induit généralement un fort niveau de bruit, qu'il est nécessaire de réduire en vue de réaliser cette estimation. Les techniques multi-temporelles tirent parti de toutes les images qui peuvent être acquises entre les deux dates en question afin de produire une estimation plus fine du déphasage [1].

3 Modèles de Flux

3.1 Cadre théorique général

Les modèles de flux (*flow matching*) apprennent un transport entre deux distributions arbitraires p_0 et p_1 , grâce à un flux $\varphi : [0, 1] \times \mathbb{R}^d$ guidé par un champ de vitesse u_t décrivant les vitesses des particules transportées de p_0 vers p_1 :

$$\frac{d}{dt}\varphi_t(x) = u_t(\varphi_t(x)) \quad (1)$$

Les articles fondateurs [6, 5] ont démontré que φ_t estime un transport entre p_0 et p_1 par la résolution de l'équation différentielle ordinaire (EDO) 1 de $t = 0$ à $t = 1$. Résoudre cette même équation pour les temps décroissants permet de transporter, par construction, p_1 sur p_0 . Si la véritable vitesse u_t est en pratique insoluble, elle peut être apprise via un simple objectif de régression, sans simulation de trajectoire :

$$\mathcal{L}_{\text{FM}}(\theta) = \mathbb{E}_{\substack{x_0, x_1 \sim p(x_0, x_1) \\ t \sim \mathcal{U}([0, 1])}} \|v_\theta(t, x_t) - u_t(x_t | x_0, x_1)\|^2 \quad (2)$$

où les paires (x_0, x_1) sont échantillonnées depuis la distribution jointe $p(x_0, x_1)$ aussi appelée *couplage* et x_t est

construit à partir d'un interpolant $x_t = I_t(x_0, x_1)$. Les interpolants peuvent être exprimés simplement, de sorte à ce que leurs dérivées temporelles, les vitesses conditionnelles $u_t(x_t | x_0, x_1) = \dot{I}(x_0, x_1)$ disposent de formes analytiques. En géométrie euclidienne, l'interpolant linéaire $I_t(x_0, x_1) = (1-t)x_0 + tx_1$ permet d'obtenir un objectif d'apprentissage simple car $u_t(x_t | x_0, x_1) = x_1 - x_0$.

À l'inférence, les points $x_0 \sim p_0$ sont transportés jusqu'à la distribution cible p_1 en suivant le champ de vitesse appris :

$$\hat{x}_1 = \varphi_{t=1}(x_0) = \text{EDO}^{v_\theta}(x_0, 0 \rightarrow 1) \quad (3)$$

où $\text{EDO}^{v_\theta}(\cdot, t_0 \rightarrow t_1)$ est la résolution numérique de l'équation (1) entre les temps t_0 et t_1 en remplaçant la vitesse u_t par son approximation par le réseau de neurone $v_\theta(t, \cdot)$.

3.2 Flux sur le tore pour l'InSAR

L'utilisation de modèles de flux dans le domaine de l'InSAR requiert quelques adaptations afin de prendre en compte la géométrie sous-jacente des données. En effet, chaque pixel d'un interférogramme représente une phase $\phi \in [0, 2\pi[$. Ainsi un interférogramme de d pixels est un vecteur de phases $[\phi_0, \phi_1, \dots, \phi_d]$ et peut être représenté par un point sur le tore riemannien $\mathbb{T}_d = (S^1)^d$. La généralisation des modèles de flux à des géométries Riemanniennes a été proposée par [7]. L'objectif d'apprentissage 2 se généralise en tenant compte du fait que les vitesses en chaque point, notées $\mathbf{v}_\theta(t, \mathbf{w}_t)$ et $\mathbf{u}_t(\mathbf{w}_t | \mathbf{w}_0, \mathbf{w}_1)$, appartiennent désormais à l'espace tangent au tore au point \mathbf{w}_t , dénoté $T_{\mathbf{w}_t}\mathbb{T}_d$. Ici, on considérera \mathbb{T}_d comme une sous-variété et on utilisera la métrique Euclidienne sur, induisant simplement la norme $\|u\|_{\mathbf{w}}^2 = \langle u, u \rangle$ sur l'espace $T_{\mathbf{w}_t}\mathbb{T}_d$. L'objectif 2 se réécrit en

$$\mathcal{L}_{\text{RFM}}(\theta) = \mathbb{E}_{\substack{\mathbf{w}_0, \mathbf{w}_1 \sim p(\mathbf{w}_0, \mathbf{w}_1) \\ t \sim \mathcal{U}([0, 1])}} \|\mathbf{v}_\theta(t, \mathbf{w}_t) - \mathbf{u}_t(\mathbf{w}_t | \mathbf{w}_0, \mathbf{w}_1)\|_g^2 \quad (4)$$

Les extrémités sont échantillonnées comme précédemment, cependant l'interpolant choisi doit respecter la géométrie afin que tous les points \mathbf{w}_t construits appartiennent au tore \mathbb{T}_d .

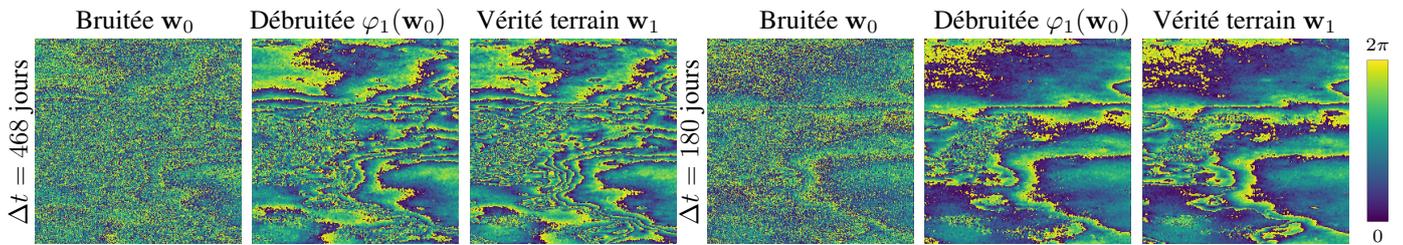


FIGURE 3 : Le flux riemannien génère les versions débruités $\varphi_1(\mathbf{w}_0)$ de deux interférogrammes \mathbf{w}_0 correspondant à deux différences temporelles Δt différentes. Les prédictions du flux à partir d'un unique interférogramme sont proches des débruitages proposés par les modèles multi-temporel \mathbf{w}_1 tirant profit d'une série temporelle de phases pour établir leurs prédictions.

Dans notre cas, on utilisera l'interpolant suivant :

$$\mathbf{w}_t = I_t(\mathbf{w}_0, \mathbf{w}_1) = \exp_{\mathbf{w}_1}(\kappa(t) \log_{\mathbf{w}_1}(\mathbf{w}_0)) \quad (5)$$

où κ est une fonction décroissante monotone, dérivable et vérifiant $\kappa(0) = 1$ et $\kappa(1) = 0$, permettant l'interpolation entre p_0 et p_1 , et $\exp_{\mathbf{w}}(\cdot) : T_{\mathbf{w}}\mathbb{T}_d \rightarrow \mathbb{T}_d$ et $\log_{\mathbf{w}}(\cdot) : \mathbb{T}_d \rightarrow T_{\mathbf{w}}\mathbb{T}_d$ sont des opérateurs permettant faire correspondre l'espace tangent à la variété, et vice-versa. Pour le tore plat à d dimensions $[0, 2\pi]^d$, les applications $\exp_{\mathbf{w}}(\cdot)$ et $\log_{\mathbf{w}}(\cdot)$ communément employées sont les suivantes (elles sont appliquées élément par élément sur chaque entrée) :

$$\begin{cases} \exp_w(u) = (w + u) \pmod{2\pi} \\ \log_{w_a}(w_b) = \arctan2(\sin(w_b - w_a), \cos(w_b - w_a)) \end{cases} \quad (6)$$

Nous illustrons sur la Figure 2 (haut) un transport simplifié entre deux distributions p_0 et p_1 sur le tore \mathbb{T}_2 .

4 Applications en InSAR

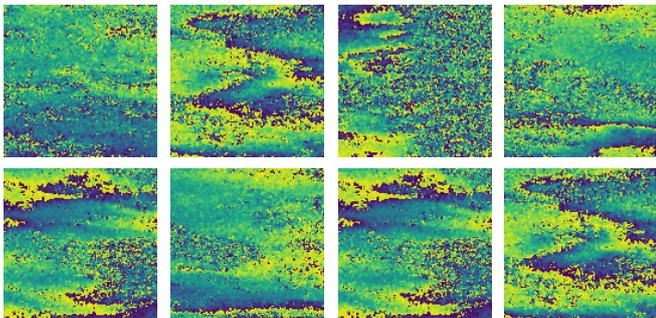


FIGURE 4 : Tuiles générées par le modèle de flux sur la variété riemannienne \mathbb{T}_d . Les interférogrammes produits ont des propriétés visuelles similaires aux vrais : bruit poivre et sel et présence de franges d'interférences.

Jeu de données : nous utilisons des données réelles collectées sur la ville de Mexico. Nous disposons d'un cube de données comportant 40 acquisitions SAR Sentinel-1 SLC de dimensions 3638×16709 pixels, acquises tous les 12 jours entre le 14 août 2019 et le 6 décembre 2020 [9, 10], pré-traitées à l'aide de SNAP. Les acquisitions sont traitées de sorte à conserver seulement les déphasages entre chaque t et la date initiale t_0 . Nous divisons le jeu de données en deux zones spatialement disjointes. Les interférogrammes sont sous échantillonnés par décimation d'un facteur 4 et découpés en

images de différences de phases de dimensions 128×128 , avec un recouvrement de 75% pour l'entraînement, résultant en un total de 4,6 millions d'exemples d'apprentissage.

Implémentation : Pour tous les scénarios, nous approximations la vélocité $v_\theta(t, x_t)$ par un U-Net avec conditionnement temporel [11] entraîné pendant 100 000 itérations avec lots de 32 exemples. Nous utilisons un pas d'apprentissage de 1×10^{-4} , une troncature des gradients à 0,5 et une moyenne exponentielle des poids (EMA) pour stabiliser l'apprentissage. À l'inférence, nous générons les points $\hat{x}_1 \sim p_1$ en intégrant l'EDO 1 à l'aide d'un résolveur numérique Euler avec 50 étapes de discrétisation.

4.1 Modèles génératifs

Les modèles de flux peuvent être employés comme modèles génératifs, transportant une loi a priori simple $p_0 = p_{\text{prior}}$ que l'on sait échantillonner (par exemple une gaussienne $\mathcal{N}(0, I_d)$) vers la distribution des données $p_1 = p_{\text{data}}$. Dans ce cas, leur formulation est similaire à celle des modèles de diffusion.

Nous entraînons un modèle de flux Riemannien à générer des différences de phases en transportant une distribution a priori vers le cube de données de Mexico débruité par l'algorithme COFI-PL [1]. Plus précisément, nous utilisons un a priori $p_0 = \exp_{0_d} \mathcal{N}(0, I_d)$ et la distribution des données $p_1 = p_{\text{data}}$ est constituée des interférogrammes du jeu de données précédemment décrit. Comme illustré par les exemples qualitatifs de la figure 2 et figure 4, cette approche permet de générer des différences phases vraisemblables et qui présentent les mêmes caractéristiques que les données réelles : présence de franges et bruit poivre et sel. Cette approche pourrait par exemple servir à la simulation de données InSAR synthétiques, une approche couramment utilisée dans la littérature pour entraîner et/ou évaluer des modèles profonds [2, 3].

De plus, les modèles de flux que nous avons entraînés sur une variété euclidienne échouent à générer des interférogrammes valides. En effet, ces modèles génèrent des points ne se trouvant pas sur le tore \mathbb{T}_d (leurs valeurs sont en dehors de $[0, 2\pi]$), en particulier à proximité des franges, comme illustré par la figure 5.

4.2 Débruitage

Les modèles de flux permettent le transport entre deux distributions arbitraires p_0 et p_1 , ce qui ouvre la voie à de nouvelles méthodes de débruitage. D'un point de vue pratique, cette approche nous permet de nous affranchir de la connaissance du

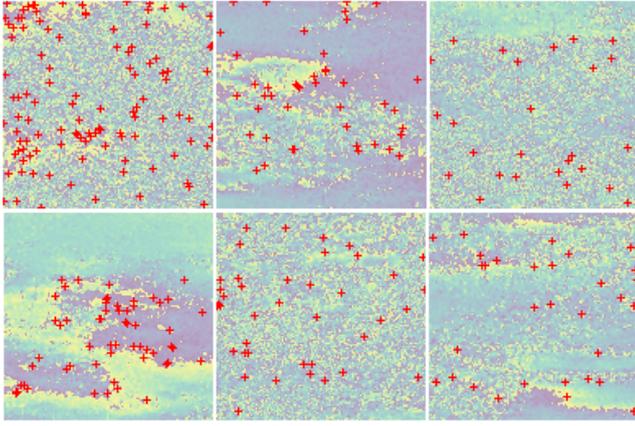


FIGURE 5 : Tuiles générées par le modèle de flux sur la variété euclidienne \mathbb{R}^d avec 25 étapes d’intégration. Les pixels invalides, aux phases prédites non incluses dans le segment $[0, 2\pi[$, sont indiqués par une croix rouge.

processus de bruitage des données, car aucune hypothèse sur la nature du bruit n’est faite pendant l’apprentissage du flux.

Les interférogrammes du jeu de données sont naturellement bruités et difficilement exploitables pour la production d’une carte de déplacement et/ou déformation des sols, justifiant l’application d’une étape d’une débruitage. Nous proposons d’apprendre le flux entre p_0 la distribution des différences de phases réelles, et p_1 la distribution des différences de phases débruitées à l’aide de l’algorithme *COFI-PL* [1]. Nous traitons ainsi ces phases débruitées comme une vérité terrain, bien que cela ne soit pas exactement le cas. Le procédé revêt néanmoins l’intérêt de distiller la connaissance *a priori* sur la nature spatiale et temporelle du bruit retiré par *COFI-PL* dans le modèle de flux. Toutefois, remarquons que cet algorithme exploite toute la pile temporelle, tandis que le modèle de flux ne prend en entrée qu’un seul interférogramme. Cela nous permet d’évaluer à quel point le débruiteur basé sur le flux riemannien est en mesure de reproduire la qualité d’un débruitage multi-temporel à partir d’un interférogramme unique (et non d’une série temporelle complète).

Le débruitage obtenu pour deux dates différentes (figure 3) est précis et parvient à reconstruire les franges même lorsque les motifs sont fins, y compris dans le cas où l’interférogramme bruité est calculé entre les images avec la plus grande différence temporelle $\Delta t = 468$ jours). Les écarts de reconstruction (RMSE) obtenus sont de 0,77 et 1,09 pour respectivement $\Delta t = 180$ et $\Delta t = 468$ jours. Ainsi, le flux prédit un interférogramme débruité similaire à celui de l’algorithme *COFI-PL*.

5 Conclusion

Dans cet article, nous avons exploré l’utilisation de modèles de flux Riemanniens pour la génération et le débruitage d’interférogrammes en InSAR. L’entraînement des ces modèles sur le tore \mathbb{T}_d permet d’assurer la validité des interférogrammes générés. Dans le cadre génératif, les images produites présentent la texture ainsi que les motifs de frange attendus. De plus, les modèles de flux proposent un débruitage performant à partir d’un unique interférogramme, comparable à celui obtenu à partir d’un débruiteur multi-temporel. Ces modèles ouvrent la voie à une disponibilité plus rapide des interférogrammes débruités en accélérant les algorithmes de débruitage multi-temporel.

Références

- [1] Phan Viet Hoa Vu, Arnaud Breloy, Frédéric Brigui, Yajing Yan Member, and Guillaume Ginolhac, “Covariance fitting interferometric phase linking : Modular framework and optimization algorithms,” *IEEE Transactions on Geoscience and Remote Sensing*, 2025.
- [2] Sergio Vitale, Giampaolo Ferraioli, Vito Pascazio, and Gilda Schirinzi, “Insar-monet : Interferometric sar phase denoising using a multiobjective neural network,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–14, 2022.
- [3] Carla Geara, Colette Gelas, Louis De Vitry, Elise Colin, and Florence Tupin, “Insar2insar : A self-supervised method for insar parameters estimation,” in *2024 32nd European Signal Processing Conference (EUSIPCO)*, 2024, pp. 651–655.
- [4] Jonathan Ho, Ajay Jain, and Pieter Abbeel, “Denoising diffusion probabilistic models,” *Advances in neural information processing systems*, vol. 33, pp. 6840–6851, 2020.
- [5] Michael S Albergo, Nicholas M Boffi, and Eric Vandeen-Eijnden, “Stochastic interpolants : A unifying framework for flows and diffusions,” *arXiv preprint arXiv :2303.08797*, 2023.
- [6] Yaron Lipman, Ricky TQ Chen, Heli Ben-Hamu, Maximilian Nickel, and Matthew Le, “Flow matching for generative modeling,” in *The Eleventh International Conference on Learning Representations*, 2022.
- [7] Ricky T. Q. Chen and Yaron Lipman, “Flow matching on general geometries,” in *The Twelfth International Conference on Learning Representations*, 2024.
- [8] Zhongrun Zhou, Xinyao Sun, Fei Yang, Zheng Wang, Ryan Goldsbury, and Irene Cheng, “Ganinsar : Deep generative modeling for large-scale insar signal simulation,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 17, pp. 5303–5316, 2024.
- [9] Dana El Hajjar, Yajing Yan, Guillaume Ginolhac, and Mohammed Nabil El Korso, “Sequential Phase Linking : Progressive Integration of SAR Images for Operational Phase Estimation,” in *International Geoscience and Remote Sensing Symposium (IGARSS)*, Athènes, Greece, July 2024, IEEE.
- [10] Dana El Hajjar, Guillaume Ginolhac, Yajing Yan, and Mohammed Nabil El Korso, “Robust sequential phase estimation using multi-temporal sar image series,” *IEEE Signal Processing Letters*, vol. 32, pp. 811–815, 2025.
- [11] Yang Song, Jascha Sohl-Dickstein, Diederik P Kingma, Abhishek Kumar, Stefano Ermon, and Ben Poole, “Score-based generative modeling through stochastic differential equations,” in *International Conference on Learning Representations*, 2021.