

Modèles de diffusion pour la synthèse de textures anisotropes[†]

Kinan ABBAS^{1,2} Davy LEO¹ Patrice ABRY¹ Stephane ROUX¹

¹CNRS, ENS de Lyon, LPENSL, UMR5672, 69342, Lyon Cedex 07, France

²XMBAUBLE, Lyon, France

Résumé – Les textures anisotropes, caractérisées par des propriétés statistiques dépendantes de la direction, jouent un rôle important en science des matériaux, informatique graphique et pour les applications biomédicales. Cependant, la synthèse précise de ces textures constitue un défi. Dans cette étude, nous explorons le potentiel des modèles de diffusion pour générer des textures anisotropes. Nous utilisons un modèle de diffusion construit à partir d’une architecture U-Net, entraîné avec un ensemble de textures anisotropes. Pour évaluer la qualité des textures générées, nous employons une transformée en ondelettes directionnelles (dual-tree complex wavelet transform), qui permet de quantifier l’anisotropie. Nos résultats indiquent que le modèle de diffusion synthétise efficacement des textures anisotropes, atteignant une grande fidélité dans la reproduction des propriétés directionnelles à travers de multiples échelles.

Abstract – Anisotropic textures, characterized by direction-dependent statistical properties, play an important role in domains like material science and computer graphics. However, synthesizing these textures accurately poses a significant challenge. In this study, we explore the potential of diffusion models to generate anisotropic textures. We employ a U-Net-based diffusion model, trained on a dataset of anisotropic textures, to produce samples. To evaluate the quality of these generated textures, we use a set of six directional functions acknowledged for their ability to measure anisotropy across various scales and orientations. Our results indicate that the diffusion model effectively synthesizes anisotropic textures, achieving high fidelity in reproducing directional properties across multiple scales.

1 Introduction

Contexte. Les modèles génératifs d’images par réseaux de neurones (NN) sont devenus essentiels pour une grande variété d’applications [10]. Cependant, dans la plupart des applications considérées, les images d’intérêt sont caractérisées par un fort contenu géométrique (par exemple, des visages, des bâtiments, des rues) [12], et consistent rarement en images purement texturées avec peu ou pas de géométrie, et donc caractérisées par des dynamiques spatiales riches ainsi que des propriétés statistiques complexes. L’objectif principal de ce travail est d’étudier si les réseaux de diffusion (DN), le paradigme le plus récent et le plus prometteur en intelligence artificielle (IA) générative [11], peuvent synthétiser efficacement des textures mélangeant ici invariance d’échelle et anisotropie, utilisées comme représentatives de textures bien décrites par des propriétés multi-échelles riches.

Etat de l’art. Les *Generative Adversarial Networks* (GAN), proposés initialement par Goodfellow et al. [10], ont marqué une avancée majeure dans la génération d’images. Ils sont capables de produire des structures géométriques bien marquées mais échouent souvent à préserver les détails statistiques fins, ou à petites échelles [2], ainsi que d’éventuelles anisotropies. Les textures anisotropes dont les propriétés statistiques varient selon la direction, sont également essentielles pour la modélisation de données issues d’applications réelles [4]. Les modèles de diffusion, initiés par Sohl-Dickstein et al. [22] et développés ensuite par [11], se sont depuis imposés comme

une alternative, offrant un meilleur contrôle des propriétés statistiques. Ces modèles transforment itérativement du bruit en sorties structurées par inversion d’un processus de diffusion stochastique. Des avancées ultérieures, telles que les modèles probabilistes de débruitage par diffusion [11] ou les méthodes génératives reposant sur un score [23], ont augmenté l’efficacité et l’applicabilité des DN, notamment pour la génération d’images. Contrairement aux GAN, les modèles de diffusion capturent mieux les propriétés statistiques aux petites échelles, ce qui est particulièrement pertinent pour les applications [9].

Les modèles de diffusion ont récemment été adaptés à la synthèse de textures. Chen et al. [6] ont exploité les modèles de diffusion pour la synthèse de textures 2D guidée par du texte, générant des motifs visuellement riches, Cao et al. [5] ont introduit une méthode pour les textures 3D, synthétisant des détails de surface pour des modèles géométriques. Yu et al. [25] ont démontré leur potentiel dans la génération de textures de maillage, offrant une solution générative pour les applications graphiques. Malgré ces avancées, la synthèse, par modèles de diffusion, de textures dont la dynamique est à la fois anisotrope et multi-échelles demeure peu étudiée, et constitue la question au coeur de ce travail.

Objectif, contribution et organisation. L’objectif de ce travail est d’évaluer le potentiel des modèles de diffusion, choisis comme référence récente en intelligence artificielle générative, à produire des textures dont les dynamiques d’espaces sont riches et complexes, notamment multi-échelles (i.e., impliquant un large continuum d’échelles) et anisotropes.

À cette fin, la section 2 rappelle les définitions et éléments-clés des modèles de diffusions. La section 3 donne ensuite la définition des processus browniens anisotropes autosimilaires [4], choisis comme modèles de textures dans de nom-

[†] Nous remercions Pulsalys pour le soutien apporté à nos travaux. Nous remercions la plateforme de ressources de calcul du Centre Blaise Pascal à l’ENS de Lyon. Cette plateforme exploite la solution SIDUS développée par Emmanuel Quemener [17].

breuses applications réelles où les données à décrire sont caractérisées par des statistiques multi-échelles et anisotropes. Pour caractériser conjointement et correctement les propriétés d'autosimilarité et d'anisotropie, il a été proposé [7, 8] d'utiliser une analyse directionnelle, reposant sur une décomposition en ondelettes complexes calculées par une construction Dual-tree [20, 21], également rappelée en section 3.

Deux ensembles d'entraînement sont constitués, correspondant à des catégories d'anisotropie différentes, et utilisés pour entraîner des réseaux de diffusion. Les performances de ces réseaux dans la production d'images anisotropes autosimilaires sont ensuite quantifiées en comparant les statistiques des coefficients issus des analyses en ondelettes directionnelles pour les textures générées contre celles de l'ensemble d'entraînement. Cette méthodologie et les résultats obtenus, décrits en section 4, montrent la grande aptitude des modèles de diffusion à reproduire conjointement invariance d'échelle et anisotropie.

2 Les modèles de diffusion

Les modèles de diffusion constituent une classe de modèles génératifs qui synthétisent des données en inversant itérativement un processus stochastique d'ajout de bruit, transformant ainsi un bruit pur en sorties structurées [22]. Le processus débute par une étape de diffusion directe, définie comme une chaîne de Markov sur T pas de temps discrets. Ici, un échantillon initial $\mathbf{x}_0 \sim q(\mathbf{x}_0)$ — par exemple, une image de texture — est progressivement perturbé par un bruit gaussien selon :

$$q(\mathbf{x}_t | \mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{1 - \beta_t} \mathbf{x}_{t-1}, \beta_t \mathbf{I}), \quad (1)$$

où $\beta_t \in (0, 1)$ représente la variance du bruit dépendante du temps, contrôlant l'intensité du bruit à chaque étape t . Ce processus direct admet une expression analytique fermée pratique :

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1 - \bar{\alpha}_t) \mathbf{I}), \quad (2)$$

avec $\alpha_t = 1 - \beta_t$ et $\bar{\alpha}_t = \prod_{s=1}^t \alpha_s$, permettant un échantillonnage efficace des états bruités directement à partir des données originales. L'étape de diffusion inverse est apprise à l'aide d'un réseau de neurones, généralement un U-Net [11], et est modélisée comme suit :

$$p_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t) = \mathcal{N}(\mathbf{x}_{t-1}; \boldsymbol{\mu}_\theta(\mathbf{x}_t, t), \sigma_t^2 \mathbf{I}), \quad (3)$$

où $\boldsymbol{\mu}_\theta(\mathbf{x}_t, t)$ prédit la moyenne de l'étape de débruitage, et σ_t^2 est une variance prédéfinie. L'entraînement optimise une borne variationnelle simplifiée, réduisant la perte en erreur quadratique moyenne :

$$\mathbb{E}_{\mathbf{x}_0, \epsilon} [\|\epsilon - \epsilon_\theta(\mathbf{x}_t, t)\|^2], \quad (4)$$

où $\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ est le bruit ajouté, et $\epsilon_\theta(\mathbf{x}_t, t)$ est la prédiction du bruit par le U-Net au pas de temps t . Le choix du *noise scheduler* $\{\beta_t\}_{t=1}^T$ — qu'il soit linéaire, cosinus, quadratique ou sigmoïde — influence davantage la capacité du modèle à équilibrer la préservation des détails et la précision statistique. Un *scheduler linéaire* augmente progressivement β_t d'une petite valeur (par exemple, 0.0001) à une valeur plus grande (par exemple, 0.02) sur T étapes [11]. Cette augmentation de bruit simple et cohérente aide à maintenir un équilibre entre l'efficacité de l'entraînement et la diversité des échantillons :

$$\beta_t = \beta_{\text{start}} + \frac{t-1}{T-1} (\beta_{\text{end}} - \beta_{\text{start}}). \quad (5)$$

3 Textures anisotropes auto-similaires : définitions et analyses

Champs browniens fractionnaires anisotropes. Les champs browniens fractionnaires anisotropes, en abrégé ci-après, AFBF pour *Anisotropic Brownian Fractional Fields*, définis comme des processus gaussiens autosimilaires, permettent un contrôle théorique fin, précis et conjoint, à la fois de propriétés d'invariance d'échelle, ou autosimilarité, et d'anisotropie [3, 4, 18]. Ils fournissent donc une famille paramétrable de modèles de textures très utilisée dans les applications réelles.

Les AFBF sont définis via leur densité spectrale de puissance $f(\xi)$, par

$$(\forall t \in \mathbb{R}^d) \quad X^f(t) = \int_{\mathbb{R}^d} \left(e^{i\langle t, \xi \rangle} - 1 \right) \sqrt{f(\xi)} \widehat{W}(\xi) d\xi \quad (6)$$

où $\widehat{W}$ désigne la transformée de Fourier d'un bruit blanc gaussien, et $d = 2$ la dimension de l'espace.

La densité spectrale permet de contrôler les propriétés visuelles et statistiques (anisotropies et corrélations spatiales courtes ou longues) des textures [19]. Notamment, pour imposer conjointement anisotropie et autosimilarité, il a été montré que $f(\xi)$ peut prendre la forme suivante [4, 18, 19] :

$$f(\xi) = \tau \left(\frac{\xi}{|\xi|} \right) \|\xi\|^{-(2h(\frac{\xi}{|\xi|})+d)}, \quad (7)$$

paramétrée par la *fonction de Hurst*, $h : \mathbb{S}_{d-1} \rightarrow (0, 1)$, qui module l'exposant d'autosimilarité H selon les directions de l'axe des fréquences, et la *topothèse* $\tau : \mathbb{S}_{d-1} \rightarrow \mathbb{R}_+$, qui module l'intensité du processus. De manière évidente, les choix $h(\xi) = H_0$ et $\tau(\xi) = \sigma_0$ correspondent au cas particulier du mouvement brownien fractionnaire isotrope autosimilaire de paramètre d'autosimilarité H_0 . Les fonctions h et τ permettent donc, tout en préservant une dynamique spatiale invariante d'échelle et autosimilaire, de lui adjoindre différente forme d'autosimilarité : h affecte la structure de dépendance (la corrélation) spatiale de la texture tandis que τ n'agit que comme un modulateur directionnel d'amplitude.

Analyses en ondelettes complexes dual-tree. Il a été bien et abondamment documenté que les analyses en ondelettes constituent des outils idoines pour l'analyse de signaux ou textures isotropes autosimilaires (cf. e.g., [15, 16, 24]). Pour prendre en compte correctement conjointement autosimilarité et anisotropie, l'utilisation de transformée en ondelettes complexes directionnelles a été mise en avant, notamment par des implantations par *Dual-tree*, abrégé ci-après en DTCWT (Dual Tree Complex Wavelet Transform) [13, 20, 21]. Nous utiliserons ici l'algorithme non décimé développé dans [7, 8].

Les coefficients de la DTCWT sont obtenus par produit scalaire de la texture à analyser, X , contre une collection $b = 1, \dots, B = 6$ d'ondelettes-mères, dilatées et translatées :

$$c_{j,k}^{(b)} = \langle X(\cdot), 2^{-j} \psi^{(b)}(2^{-j}(\cdot - k)) \rangle. \quad (8)$$

Il a été montré [7, 8] que la moyenne du carré des modules des $c_{j,k}^{(b)}$ d'un AFBF se comporte approximativement comme une loi de puissance à travers les échelles :

$$S(j, b) \equiv \sum_k |c_{j,k}^{(b)}|^2 \sim \mathcal{V}(\tau, h, \psi^{(b)}) 2^{j(2H(h, \psi^{(b)})+1)}, \quad (9)$$

dont les exposants $H(h, \psi^{(b)})$ et constantes multiplicatives $\mathcal{V}(\tau, h, \psi^{(b)})$ dépendent simultanément de l'ondelette $\psi^{(b)}$ et donc de la direction, et de la fonction h pour le premier et des fonctions h et τ . Des différences entre les exposants $H(h, \psi^{(b)})$, $b = 1, \dots, B$ signifient donc l'anisotropie de la texture induite par la modulation directionnelle de la fonction h , tandis que des différences entre les constantes multiplicatives $\mathcal{V}(h, \psi^{(b)})$, $b = 1, \dots, B$ rendent compte d'anisotropies induites par la modulation directionnelle des fonctions τ et h , en pratique essentiellement celles produites par τ [7].

4 Performance de la synthèse

4.1 Conditions d'expériences

Modèles de diffusion. Le modèle de diffusion suit le cadre classique DDPM proposé par Ho et al. [11]. Le modèle emploie une architecture U-Net inspirée des blocs ConvNeXt pour effectuer le processus de débruitage [14]

Paramètres d'entraînement. Le modèle utilise 1000 pas de temps (epochs) pour le processus de diffusion. L'entraînement a été réalisé sur un GPU AD102GL [RTX 6000 Ada Generation]. Selon nos résultats dans [1], les modèles de diffusion avec un *scheduler* linéaire régénèrent efficacement la fonction de Hurst H (paramètre d'échelle). Par conséquent, dans cette étude, nous testons uniquement le *scheduler* linéaire.

Données d'entraînement. Nous avons considéré deux jeux de données comprenant 3000 images d'AFBF générées pour deux paramétrisations de la densité spectrales. Les fonctions τ et h sont affichées dans la Figure 1 permettent une modélisation d'anisotropie dans deux scénarios distincts.

Deux formes d'anisotropie. Deux scénarios sont testés, qui correspondent à deux classes de textures dont les anisotropies sont différentes. Pour le scénario 1, l'anisotropie est induite par la fonction de Hurst h seulement, tandis que la topothèse est uniforme. Pour le scénario 2, l'anisotropie est plus complexe, induite à la fois par les directionnalités de h et τ . Ces fonctions sont représentées sur les colonnes 2 et 3 de la figure 1.

Mesures de performances. Les comportements multi-échelles des fonctions $\log_2 S(j, b)$ joueront le rôle de métriques permettant de quantifier la qualité de la synthèse des textures par les modèles de diffusion, validant notamment la qualité de la reproduction conjointe de l'anisotropie et de l'autosimilarité. Il est essentiel de noter que les fonctions $\log_2 S(j, b)$ ne sont utilisés que comme mesures de qualité et n'entrent pas dans la définitions des fonctions de coût utilisées pour l'entraînement des réseaux : le modèles de diffusion ne sont donc jamais informés a priori des propriétés statistiques d'anisotropie et d'autosimilarité de textures d'intérêt mais doivent les découvrir et en apprendre les paramètres.

4.2 Discussion des résultats

La Figure 1 présente des exemples de textures d'entraînement et d'images générées correspondantes associées à chaque scénario, accompagnés de leurs analyses statistiques. Le dernier graphique de chaque ligne illustre le comportement multi-échelle des six fonctions $\log_2 S(j, b)$, moyennées sur 100 échantillons de chaque ensemble. Ces fonctions quantifient l'évolution du logarithme des variances des coefficients d'ondelettes en fonction du logarithme des échelles pour chaque

bande. Ces évolutions rendent donc compte conjointement de l'anisotropie et de l'autosimilarité.

Le Scénario 1 montre un léger défaut à l'échelle 1, à laquelle les fonctions $\log_2 S(j, b)$ des textures générées présentent une légère déviation par rapport à celles des textures d'entraînement, suggérant une difficulté à capturer les statistiques directionnelles à petite échelle. Cependant, pour les échelles plus grandes, l'alignement s'améliore considérablement.

Pour le scénario 2, les statistiques des textures générées sont quasi-identiques à celles des textures d'entraînement à toutes les échelles et pour toutes les bandes. Le modèle de diffusion a donc parfaitement reproduit les propriétés d'anisotropie.

Ces deux scénarios montrent que les modèles de diffusion peuvent reproduire efficacement les propriétés d'anisotropie des textures.

Au delà de reproduire les comportements moyens des fonctions $\log_2 S(j, b)$, la Figure 2 montre la distribution du logarithme du carré des coefficients d'ondelettes pour le scénario 2 à l'échelle 5, bande 6 et à l'échelle 1, bande 1. Les deux histogrammes indiquent que les distributions des textures générées reproduisent précisément celles textures d'entraînement. Cela indique que le modèle de diffusion reproduit non seulement les moyennes des statistiques des textures d'entraînement mais aussi leur variabilité à travers les échantillons d'une même classe.

Le Tableau 1 rapporte les moments, moyennés sur 100 images pour chaque ensemble de textures. Ce tableau montre une excellente reproduction des moments des textures d'entraînement par les textures générées. La *skewness* et la *kurtosis* indiquent que le caractère gaussien des textures est bien reproduit, tandis que la variance montre que la variabilité statistique naturelle de chaque texture est également bien apprise.

TABLE 1 : Statistiques des textures d'entraînement et générées

Moment	Scénario 1		Scénario 2	
	Entraînement	Diffusion	Entraînement	Diffusion
Moyenne	0.00	0.00	0.00	0.00
Variance	0.23	0.20	0.23	0.22
Asymétrie	-0.01	0.00	-0.01	-0.03
Kurtosis	2.38	2.8	2.39	2.70

5 Conclusions et perspectives

Cette étude démontre que les modèles de diffusion avec un *scheduler* linéaire synthétisent efficacement des textures anisotropes, comme en témoigne l'alignement étroit des textures générées avec les données d'entraînement sur toutes les échelles et bandes. Les histogrammes confirment également la capacité du modèle à reproduire les non seulement les moyennes d'ensemble mais aussi la variabilité entre réalisations d'un même ensemble. Les travaux futurs exploreront la synthèse de textures aux dynamiques plus complexes, par exemple non gaussiennes, multifractales, multivariées ou hétérogènes.

Références

- [1] Kinan ABBAS, Patrice ABRY et Stéphane G. ROUX : Diffusion Models for Multifractal Texture Synthesis. In *The 33rd European Signal Processing Conference (EUSIPCO 2025)*, Palerme (Italie), Italy, septembre 2025.




FIGURE 1 : **Performance de la synthèse de textures.** De gauche à droite : (a) Échantillon d'entraînement. (b) Fonction de Hurst H . (c) Fonction de tophothèse τ . (d) Échantillon généré par le modèle de diffusion. (e) Moyennes spatiales du logarithme en base 2 de la variance du module des coefficients d'ondelettes complexes multibandes, pour chacune des six bandes indépendamment, en fonction des octaves. Les deux lignes correspondent aux scénarios, caractérisés par des anisotropies différentes.




FIGURE 2 : Distribution des coefficients d'ondelettes en logarithme au carré pour le scénario 2, comparant les textures d'entraînement et générées : (gauche) Échelle 5, Bande 6 ; (droite) Échelle 1, Bande 1.

[2] P. ABRY, V. MAUDUIT, E. QUEMENER et S. ROUX : Multivariate multifractal texture dcgan synthesis : How well does it work ? how does one know ? *J. Signal Process. Syst.*, pages 1–17, 2022.

[3] H. BIERMÉ, M. MOISAN et F. RICHARD : A turning-band method for the simulation of anisotropic fractional Brownian field. *J. Comput. Graph. Statist.*, 24(3):885–904, 2015.

[4] A. BONAMI et A. ESTRADÉ : Anisotropic analysis of some gaussian models. *J. Fourier Anal. Appl.*, 9:215–236, 2003.

[5] T. CAO, K. KREIS, S. FIDLER, N. SHARP et K. YIN : Textfusion : Synthesizing 3d textures with text-guided diffusion models. *In Proc. IEEE/CVF Int. Conf. Comput. Vis.*, pages 4169–4181, 2023.

[6] D. Z. CHEN, Y. SIDDIQUI, H.-Y. LEE, S. TULYAKOV et M. NIESSNER : Text2tex : Text-driven texture synthesis via diffusion models. *In Proc. IEEE/CVF Int. Conf. Comput. Vis.*, pages 18558–18568, 2023.

[7] L. DAVY, N. PUSTELNIK et P. ABRY : Combining dual-tree wavelet analysis and proximal optimization for anisotropic scale-free texture segmentation. *In IEEE ICASSP 2023*, Rhodes Island, Greece, 2023.

[8] L. DAVY, N. PUSTELNIK et P. ABRY : Local wavelet analysis of gaussian fields : Application to anisotropic scale-free segmentation. 2025. Preprint.

[9] P. DHARIWAL et A. NICHOL : Diffusion models beat gans on image synthesis. *Adv. Neural Inf. Process. Syst.*, 34:8780–8794, 2021.

[10] I. GOODFELLOW, J. POUGET-ABADIE, M. MIRZA, B. XU, D. WARDEFARLEY, S. OZAIR, A. COURVILLE et Y. BENGIO : Generative adversarial nets. *Adv. Neural Inf. Process. Syst.*, 27, 2014.

[11] J. HO, A. JAIN et P. ABBEEL : Denoising diffusion probabilistic models. *Adv. Neural Inf. Process. Syst.*, 33:6840–6851, 2020.

[12] T. KARRAS, S. LAINE et T. AILA : A style-based generator architecture for generative adversarial networks. *In Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, pages 4401–4410, 2019.

[13] Nick KINGSBURY : Rotation-invariant local feature matching with complex wavelets. *In 2006 14th European Signal Processing Conference*, pages 1–5. IEEE, 2006.

[14] Z. LIU, H. MAO, C.-Y. WU, C. FEICHTENHOFER, T. DARRELL et S. XIE : A convnet for the 2020s. *In Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, pages 11976–11986, 2022.

[15] C.-G. LUCAS, G. DIDIER, H. WENDT et P. ABRY : Multivariate selfsimilarity : Multiscale eigenstructures for selfsimilarity parameter estimation. *IEEE Trans. Signal Process.*, 2024.

[16] B. PASCAL, S. VAITER, N. PUSTELNIK et P. ABRY : Automated data-driven selection of the hyperparameters for total-variation-based texture segmentation. *J. Math. Imaging Vis.*, 63(7):923–952, 2021.

[17] E. QUEMENER et M. CORVELLEC : Sidus—the solution for extreme deduplication of an operating system. *Linux J.*, 2013(235), 2013.

[18] F. RICHARD : Anisotropy of hölder gaussian random fields : characterization, estimation, and application to image textures. *Statistics and Computing*, 28:1155–1168, 2018.

[19] F. RICHARD et H. BIERME : Statistical tests of anisotropy for fractional brownian textures. application to full-field digital mammography. *J. Math. Imaging Vis.*, 36(3):227–240, 2010.

[20] I. W. SELESNICK, R. G. BARANIUK et N. C. KINGSBURY : The Dual-Tree Complex wavelet transform. *IEEE Signal Process. Mag.*, 22(6):123–151, 2005.

[21] I. W. SELESNICK et I. BAYRAM : On the Dual-Tree Complex wavelet packet and M-band transforms. *IEEE Trans. Signal Process.*, 56(6):2298–2310, 2008.

[22] J. SOHL-DICKSTEIN, E. WEISS, N. MAHESWARANATHAN et S. GANGULI : Deep unsupervised learning using nonequilibrium thermodynamics. *In Int. Conf. Mach. Learn.*, pages 2256–2265. PMLR, 2015.

[23] Y. SONG, J. SOHL-DICKSTEIN, D. P. KINGMA, A. KUMAR, S. ERMON et B. POOLE : Score-based generative modeling through stochastic differential equations. *arXiv preprint arXiv :2011.13456*, 2020.

[24] H. WENDT, S. G. ROUX, P. ABRY et S. JAFFARD : Wavelet leaders and bootstrap for multifractal analysis of images. *Signal Process.*, 89(6):1100–1114, 2009.

[25] X. YU, Z. YUAN, Y.-C. GUO, Y.-T. LIU, J. LIU, Y. LI, Y.-P. CAO, D. LIANG et X. QI : Texgen : A generative diffusion model for mesh textures. *ACM Trans. Graph.*, 43(6):1–14, 2024.