

# Détection non supervisée de changements radiométriques en imagerie radar à synthèse d'ouverture

Thomas BULTINGAIRE<sup>1</sup> Christophe KERVAZO<sup>1</sup> Loïc DENIS<sup>2,1</sup> Florence TUPIN<sup>1</sup>

<sup>1</sup> LTCI, Télécom Paris, Institut Polytechnique de Paris, 91120 Palaiseau, France

<sup>2</sup> Université Jean Monnet Saint-Etienne, CNRS, Institut d'Optique Graduate School, Laboratoire Hubert Curien UMR 5516, F-42023, Saint-Étienne, France

**Résumé** – L'imagerie radar à synthèse d'ouverture est un mode d'imagerie clé pour la détection de changements en télédétection. Cette tâche est difficile à cause du phénomène de chatoiement, un phénomène qui nécessite de réaliser une étape de débruitage pour y être davantage robuste. Cependant, il est nécessaire de prendre en compte les incertitudes de débruitage pour contrôler la probabilité de fausse alarme des changements détectés car les instabilités de débruitage doivent être distinguées des changements. Nous proposons donc un réseau, entraîné de manière auto-supervisée, pour prédire les incertitudes de débruitage menant à une détection de changements radiométriques dont la performance est évaluée sur des images du satellite TerraSAR-X.

**Abstract** – Synthetic Aperture Radar (SAR) imaging is a key imaging technique for change detection in remote sensing. This task is difficult due to the speckle phenomenon, so a denoising step is helpful to be more robust to this phenomenon. However, it is mandatory to take into account the denoising uncertainties for a constant false alarm probability change detection because denoising instabilities must be distinguished from changes. Thus, we propose a neural network, trained in a self-supervised way, to predict denoising uncertainties for a radiometric change detection whose performance is evaluated on TerraSAR-X satellite images.

## 1 Introduction

La détection de changements en télédétection consiste en la localisation de changements sur le sol terrestre sur des paires (ou n-uplets) d'acquisitions de la même zone, à des instants différents, depuis un capteur aérien ou satellitaire. Certaines approches visent à détecter un type de changement associé à une sémantique donnée (comme la construction de nouveaux bâtiments), tandis que les approches de plus bas niveau, qui nous intéressent ici, cherchent des changements de radiométrie, même faibles, dans la scène.

L'imagerie radar à synthèse d'ouverture (Synthetic Aperture Radar, SAR) est une méthode de télédétection active utilisant des ondes radio, et faisant l'acquisition d'images à valeurs complexes (à la fois l'amplitude et la phase de l'écho radar sont mesurées). Cette méthode est très adaptée à la détection de changements grâce à sa robustesse aux variations d'illumination naturelle et à la couverture nuageuse. En effet, ces avantages sont cruciaux pour certaines applications comme la gestion de catastrophes naturelles (besoin rapide d'acquisition en toutes conditions), ou la surveillances de régions à forte couverture nuageuse comme l'Amazonie [11]. Cependant, du fait de l'interférence entre les nombreux échos, le phénomène de chatoiement (speckle, en anglais) corrompt fortement les images en induisant de fortes fluctuations. Il est alors difficile de différencier un changement entre deux images de la stochasticité induite par le speckle. Un traitement adéquat doit être réalisé afin de faciliter l'interprétation des images SAR et la détection des changements.

L'annotation de changements pour des paires d'images est une tâche très fastidieuse, particulièrement avec des images SAR. De ce fait, les méthodes non-supervisées sont préférables et constituent la majorité de l'état de l'art, que ce soit en se basant sur une opération de seuillage [1], de clustering [3],

ou plus récemment l'apprentissage profond. L'apprentissage peut prendre la forme d'apprentissage contrastif [5], ou encore d'apprentissage via des pseudo-labels construits depuis d'autres méthodes non-supervisées [7, 9].

Bien qu'elle ne soit pas utilisée dans de nombreuses méthodes de l'état de l'art, une étape de débruitage est très bénéfique à la détection de changements. Cet article propose de prendre en compte les incertitudes du débruitage après une estimation par apprentissage auto-supervisé. Cela constitue une extension de travaux que nous avons récemment présentés à la conférence européenne EUSIPCO [2]. Nous présentons donc ici une autre méthode de détection de changements radiométriques robuste au speckle et à taux de fausses alarmes constant quel que soit le milieu observé (Constant False Alarm Rate, CFAR). Pour améliorer la qualité de la méthode, voici les contributions supplémentaires présentées dans cet article :

- une méthode de quantification de l'incertitude de débruitage à l'échelle d'un patch, applicable de manière non-supervisée à tout débruiteur,
- la localisation des changements à l'intérieur d'un patch, basée sur un processus d'optimisation, afin de ne pas perdre en résolution.

## 2 Méthode

Nous proposons une approche non supervisée de détection de changements mêlant débruitage et quantification de ses incertitudes par apprentissage profond auto-supervisé basé sur le principe de Noise2Noise [8]. Dans l'article que nous avons publié à EUSIPCO [2], l'incertitude du débruitage est utilisée dans la normalisation de différences d'images débruitées. Les résultats montrent cependant un manque de sensibilité de détection dans les régions de forte incertitude. Puisque ces régions sont

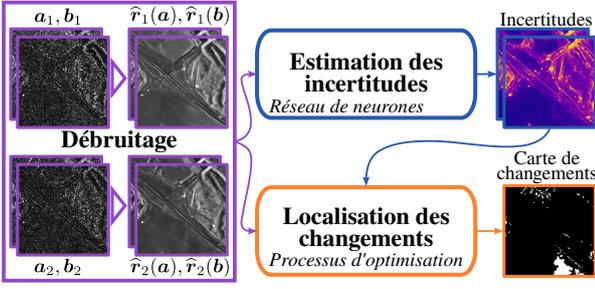


FIGURE 1 : Schéma global de la méthode proposée.

texturées, une information supplémentaire sur les structures des incertitudes peut être capturée et exploitée afin d'améliorer la détection dans ces régions critiques. Pour répondre à ce besoin, nous détaillons dans la partie 2.1 une méthode de quantification de l'incertitude de débruitage à l'échelle d'un patch. Ensuite, dans la partie 2.2, nous proposons une manière originale de localiser les changements à l'intérieur d'un patch une fois la modélisation effectuée (Fig. 1).

## 2.1 Modélisation de la corrélation des erreurs de débruitage

En imagerie SAR, dans le modèle de chatoiement complètement développé de Goodman, l'amplitude complexe des échos radar est modélisée via une gaussienne circulaire complexe de variance la réflectivité du terrain (partie II de [6]). La séparation de la partie réelle  $\mathbf{a}$  et de la partie imaginaire  $\mathbf{b}$  fournit alors deux vues de la scène présentant des réalisations de speckle indépendantes. Cette indépendance est exploitée dans la méthode de réduction de chatoiement MERLIN [6] qui s'appuie sur le principe de Noise2Noise [8]. En effet, le speckle de la partie imaginaire ne pouvant être prédit depuis la partie réelle (et réciproquement), il est possible d'entraîner un réseau à estimer l'image débruitée de façon auto-supervisée. En phase d'inférence, l'application du réseau de débruitage séparément sur la partie réelle et sur la partie imaginaire conduit à deux estimations  $\hat{\mathbf{r}}(\mathbf{a})$  et  $\hat{\mathbf{r}}(\mathbf{b})$  de la log-réflectivité.

Puisque  $\mathbf{a}$  et  $\mathbf{b}$  sont indépendants, les fluctuations du débruitage dans les log-réflectivités estimées  $\hat{\mathbf{r}}(\mathbf{a})$  et  $\hat{\mathbf{r}}(\mathbf{b})$  le sont également. Pour caractériser ces incertitudes, on modélise les log-réflectivités estimées par un modèle Gaussien multivarié  $\hat{\mathbf{r}}(\mathbf{c}) \sim \mathcal{N}(\bar{\mathbf{r}}, \mathbf{C})$ , avec  $\mathbf{c} \in \{\mathbf{a}, \mathbf{b}\}$ ,  $\bar{\mathbf{r}}$  la log-réflectivité du sol et  $\mathbf{C}$  la matrice de covariance (non estimable via une série temporelle à cause des changements) caractérisant les incertitudes de débruitage. On peut noter que  $\hat{\mathbf{r}} = \frac{\hat{\mathbf{r}}(\mathbf{a}) + \hat{\mathbf{r}}(\mathbf{b})}{2} \sim \mathcal{N}(\bar{\mathbf{r}}, \frac{1}{2}\mathbf{C})$  donne une estimation moins incertaine de la log-réflectivité. Cependant, puisque  $\bar{\mathbf{r}}$  est inconnu, on s'intéressera d'avantage à la modélisation de la différence  $\hat{\mathbf{r}}(\mathbf{a}) - \hat{\mathbf{r}}(\mathbf{b}) \sim \mathcal{N}(\mathbf{0}, 2\mathbf{C})$ . Or, la différence  $\hat{\mathbf{r}}(\mathbf{a}) - \hat{\mathbf{r}}(\mathbf{b})$  contient les fluctuations issues à la fois du débruitage de la partie réelle, mais aussi de la partie imaginaire. On peut donc s'appuyer sur le principe de Noise2Noise [8] et entraîner un réseau à prédire la matrice  $\mathbf{C}$  si son entrée est composée uniquement de la partie réelle (ou imaginaire) débruitée. Pour cela on minimise l'opposé de la log-vraisemblance grâce à la fonction de perte suivante (avec la notation  $\|\mathbf{x}\|_Q^2 = \mathbf{x}^T \mathbf{Q} \mathbf{x}$ ):

$$\mathcal{L}_b(\hat{\mathbf{C}}(\mathbf{a})) = \log \det \hat{\mathbf{C}}(\mathbf{a}) + \|\hat{\mathbf{r}}(\mathbf{a}) - \hat{\mathbf{r}}(\mathbf{b})\|_{\hat{\mathbf{C}}(\mathbf{a})^{-1}}^2. \quad (1)$$

Si on néglige la dépendance entre les pixels des images débruitées, ce qui serait similaire à notre étude préliminaire [2], alors la matrice de covariance est diagonale. Sinon, la matrice de covariance  $\hat{\mathbf{C}}(\mathbf{a})$  contient autant d'éléments que le nombre de pixels de l'image au carré. On restreint donc la modélisation à celle de la covariance des pixels au sein de patches de  $n \times n$  pixels de différences de log-réflectivités. De plus, afin de garantir la propriété symétrique définie positive de la matrice de covariance estimée, et pour réduire la complexité du calcul de la fonction de perte (nécessitant l'inversion d'une matrice), on entraîne le réseau de neurones à prédire l'inverse de sa décomposition de Cholesky, c'est-à-dire la matrice triangulaire inférieure  $\hat{\mathbf{L}}(\mathbf{a})$  estimant  $\mathbf{L}$  dans  $\mathbf{C}^{-1} = \mathbf{L}^T \mathbf{L}$ . Dans le cas général, avec  $\cdot_{\square_p}$  l'extraction d'un patch centré en  $p$ , la fonction de perte s'écrit :

$$\mathcal{L}_b(\hat{\mathbf{L}}_p(\mathbf{a})) = - \sum_i \log [\hat{\mathbf{L}}_p(\mathbf{a})]_{i,i} + \left\| \hat{\mathbf{L}}_p(\mathbf{a}) \cdot (\hat{\mathbf{r}}(\mathbf{a}) - \hat{\mathbf{r}}(\mathbf{b}))_{\square_p} \right\|_2^2. \quad (2)$$

Bien que n'importe quel type d'architecture puisse être utilisé avec cette méthode, nous avons choisi l'architecture NAFNet [4] ayant la particularité de remplacer les fonctions d'activation par des produits de cartes de caractéristiques, ce qui est attractif car on cherche à estimer des corrélations. Elle est suivie de « pixel-unshuffle » [10] afin d'éviter un recouvrement des patches pour lesquels on estime la matrice de covariance.

## 2.2 Localisation des changements

Dans cette partie, on cherche à localiser les changements dans des patches issus de plusieurs dates. On simplifie donc les notations en notant  $\hat{\mathbf{r}}_i = \frac{\hat{\mathbf{r}}_i(\mathbf{a}) + \hat{\mathbf{r}}_i(\mathbf{b})}{2} \sim \mathcal{N}(\bar{\mathbf{r}}_i, \Sigma_i)$ , avec  $\Sigma_i = \frac{1}{2}\mathbf{C}_i$ , un patch de log-réflectivité estimée pour une date  $t_i$ . Le blanchiment d'un patch via une estimation de sa matrice de covariance conduit à une perte de localisation des pixels initiaux. Contrairement à la normalisation dans l'étude préliminaire [2], on ne peut donc pas blanchir un patch de différence log-réflectivités estimées  $\hat{\mathbf{r}}_1 - \hat{\mathbf{r}}_2$  pour faire ressortir les changements en chaque pixel. De plus, une décision à l'échelle d'un patch (comme un test généralisé de rapport de vraisemblance) mène à une perte de résolution. Il est donc nécessaire de mettre en place une méthode de localisation des changements au sein d'un patch.

Pour répondre à ce problème, on se base sur l'intuition suivante : les fluctuations qui ne proviennent pas de changements peuvent être expliquées par les incertitudes du débruitage. On peut donc essayer de minimiser la valeur, en chaque pixel, de la différence des images débruitées, tout en restant cohérent avec le modèle au niveau des patches. Ainsi, les fluctuations provenant uniquement des incertitudes de débruitage seront compensées (log-réflectivité commune), contrairement à celles issues de changements suffisamment importants. Cela peut se traduire sous la forme du problème d'optimisation suivant :

$$\begin{aligned} \begin{pmatrix} \mathbf{r}_1^*(\alpha) \\ \mathbf{r}_2^*(\alpha) \end{pmatrix} &= \arg \min_{\mathbf{r}_1, \mathbf{r}_2} \frac{\alpha}{2} \|\mathbf{r}_1 - \mathbf{r}_2\|_1 + \frac{1}{2} \|\mathbf{r}_1 - \hat{\mathbf{r}}_1\|_{\Sigma_1^{-1}}^2 \\ &\quad + \frac{1}{2} \|\mathbf{r}_2 - \hat{\mathbf{r}}_2\|_{\Sigma_2^{-1}}^2, \quad (3) \\ \text{s.c. } &\frac{1}{2} \|\mathbf{r}_1^*(\alpha) - \hat{\mathbf{r}}_1\|_{\Sigma_1^{-1}}^2 + \frac{1}{2} \|\mathbf{r}_2^*(\alpha) - \hat{\mathbf{r}}_2\|_{\Sigma_2^{-1}}^2 \leq \tau. \end{aligned}$$

Le terme de différence  $\|\mathbf{r}_1 - \mathbf{r}_2\|_1$  rapproche les valeurs de  $\mathbf{r}_1$  et de  $\mathbf{r}_2$  sans trop qu'elles ne s'éloignent des centres  $\hat{\mathbf{r}}_1$  et  $\hat{\mathbf{r}}_2$  des ellipsoïdes décrites par  $\hat{\Sigma}_1$  et  $\hat{\Sigma}_2$ , et ce grâce aux termes de régularisation de la première ligne. La tolérance d'éloignement aux centroïdes est définie par le paramètre  $\alpha$  dont la valeur dépend de la contrainte, et donc du paramètre  $\tau$ , lui-même déterminé d'après la probabilité de fausse alarme désirée. Dans cette interprétation, la contrainte vise à ne pas « introduire de faux changements » dans  $\mathbf{r}_1^*(\alpha)$  et  $\mathbf{r}_2^*(\alpha)$  par rapport aux patches estimés  $\hat{\mathbf{r}}_1$  et  $\hat{\mathbf{r}}_2$ .

Pour résoudre efficacement ce problème d'optimisation, nous utilisons conjointement la méthode itérative des moindres carrés repondérés (Iteratively Reweighted Least Squares, IRLS) et l'algorithme de recherche de zéros de Brent comme décrit dans l'algorithme 1. Puisque IRLS fournit un résultat *approximativement* parcimonieux, on peut seuiller les pixels du patch  $|\mathbf{r}_1^*(\alpha) - \mathbf{r}_2^*(\alpha)|$  via une valeur faible  $\epsilon = 0.05$  pour détecter les pixels où la différence n'a pas été totalement compensée.

---

**Algorithme 1 :** Algorithme utilisé pour résoudre (3).

---

**Entrées :**  $\alpha^{(0)}, \alpha_{\min}, \alpha_{\max},$  # Initialisation de  $\alpha$   
 $\hat{\mathbf{r}}_1, \hat{\mathbf{r}}_2, \hat{\Sigma}_1^{-1}, \hat{\Sigma}_2^{-1}$  # Modèles des patches  
 $\alpha \leftarrow \alpha^{(0)}, \delta(\alpha) = +\infty;$   
**tant que**  $|\delta(\alpha)| > 10^{-6}$  **faire**  
  # Optimisation de la 1<sup>ère</sup> ligne de (3) :  
   $\mathbf{r}_1^*(\alpha), \mathbf{r}_2^*(\alpha) \leftarrow \text{IRLS}(\alpha, \hat{\mathbf{r}}_1, \hat{\mathbf{r}}_2);$   
  # Erreur sur la contrainte, 2<sup>nd</sup>e ligne de (3) :  
   $\delta(\alpha) \leftarrow \frac{1}{2} \|\mathbf{r}_1^*(\alpha) - \hat{\mathbf{r}}_1\|_{\hat{\Sigma}_1^{-1}}^2$   
   $\quad + \frac{1}{2} \|\mathbf{r}_2^*(\alpha) - \hat{\mathbf{r}}_2\|_{\hat{\Sigma}_2^{-1}}^2 - \tau;$   
  # Itération de la recherche de zéros de Brent :  
   $\alpha \leftarrow \text{Itération Brent}(\delta(\alpha), \alpha, \alpha_{\min}, \alpha_{\max});$   
**fin**

---

## 3 Expériences et analyses

Afin de mesurer les qualités de la méthode proposée, nous la comparons à PCA k-means [3], une méthode basée sur du clustering, deux méthodes récentes d'apprentissage profond sur des pseudo-labels, en l'occurrence Siamese Adaptive Fusion Network (SAFNet) [7] et Feature Fusion of Information Transfer Network (FFITN) [9], ainsi que la méthode avec estimation des incertitudes pixelliques du débruitage [2].

### 3.1 Présentation des données utilisées

Dans toutes les expériences, nous utilisons des images SLC du satellite TerraSAR-X acquises avec le mode stripmap. Lors de la phase d'estimation d'incertitude, on utilise deux séries temporelles<sup>1</sup> composées 26 images de  $1024 \times 1024$  pixels chacune, ainsi que cinq images<sup>2</sup> de lieux différents de quelques centaines de millions de pixels chacune. Pour évaluer la performance de la détection de changements, on s'intéresse à la série temporelle Saint-Gervais de 26 images dont les changements radiométriques entre le 6 août 2009 et le 5 mai 2011 ont été annotés manuellement sur une zone de  $384 \times 384$

pixels (première ligne de Fig. 2). Ces annotations contiennent nécessairement des erreurs car la tâche est très compliquée. Pour compléter les annotations, des changements ont été simulés dans des images afin de constituer une base avec des annotations contrôlées fiables. La deuxième et la troisième lignes de la figure 2 montrent un exemple de paires d'images  $224 \times 224$  pixels avec la simulation de petits ou de grands changements. 50 paires d'images de chaque type sont utilisées lors de l'évaluation quantitative des performances.

## 3.2 Expériences

Pour nos expériences, nous choisissons de fixer la probabilité de fausse alarme de la méthode proposée à 1%. La figure 2 illustre les performances de la méthode sur une donnée réelle, la zone annotée de Saint-Gervais, et sur des changements simulés. Tout d'abord, dans les images réelles, les changements radiométriques faibles (dans les champs, à droite) sont difficilement détectés par les méthodes n'utilisant pas d'étape de débruitage. Également, on constate que la prise en compte de l'incertitude du débruitage permet, dans tous les cas, d'équilibrer le nombre de fausses alarmes entre les milieux urbains très texturés et les milieux plus homogènes. Enfin, que ce soit le bâtiment entouré dans les images réelles, ou les changements de petite tailles dans les images simulées, les changements très structurés et plus difficiles à débruiter sont mieux détectés avec la modélisation de l'incertitude de débruitage à l'échelle d'un patch comme attendu.

Quantitativement, nous comparons les méthodes selon quatre métriques résumées dans la figure 2. On remarque tout d'abord qu'une étape de débruitage est très bénéfique à la détection de changements pour toutes les méthodes. Également, toute quantification d'incertitude de débruitage permet de réduire le taux de fausses alarmes tout en ayant globalement une meilleure détection. Certaines méthodes peuvent sembler présenter un meilleur rappel, mais, compte tenu du taux de fausses alarmes et de la précision, cela met en évidence une forte sur-détection des changements. Enfin, entre la prise en compte à l'échelle du pixel ou à l'échelle d'un patch des incertitudes de débruitage, l'amélioration de la précision à taux de fausses alarmes plus faible, sans perte importante sur l'erreur globale ou le rappel, traduit que la prise en compte d'informations de structures permet une meilleure localisation des changements.

## 4 Conclusion

Dans cet article, nous proposons une méthode de détection de changements radiométriques non supervisée d'images SAR complexes. Pour répondre à l'enjeu du speckle, une méthode de débruitage de l'état de l'art est employée. La nouvelle forme d'incertitude introduite par le débruitage est quantifiée à l'échelle d'un patch pour capturer des informations de structure supplémentaires, et ainsi les exploiter dans la détection de changements. Enfin, une méthode originale de localisation des changements à l'intérieur d'un patch, depuis une modélisation sous forme de loi jointe des pixels, est proposée pour éviter une perte de résolution. Nos expériences montrent, d'une part, que la quantification des incertitudes de débruitage permet d'équilibrer le taux de fausses alarmes dans les différents mi-

<sup>1</sup>Projets DLR-MTH0232 et DLR-LAN1746, German Space Agency DLR.

<sup>2</sup>Disponibles dans les archives de l'ESA©

		Méthodes : PCA k-means		SAFNet		FFITN		Incert. pixellique		Proposée			
		Métriques : OE / FAR / Pre / Rec		OE / FAR / Pre / Rec		OE / FAR / Pre / Rec		OE / FAR / Pre / Rec		OE / FAR / Pre / Rec			
Saint-Gervais	6 août 2009								27.6/27.8/36.1/73.4 (16.0/11.9/53.9/65.3)	13.2/3.12/73.3/51.7 (7.97/4.27/78.9/74.8)	17.1/8.56/51.7/46.9 (8.65/6.00/73.8/79.0)	<b>4.60/2.03/89.8/86.5</b>	4.61/1.95/90.1/83.0
	5 mai 2011												
Petits changements	Simulation 1								34.0/34.2/3.13/83.3 (7.61/7.69/14.5/98.5)	6.20/5.76/9.35/54.2 (0.79/0.61/59.8/82.2)	8.38/7.53/2.12/14.8 (7.94/6.54/29.4/60.7)	<b>0.30/0.26/80.4/96.1</b>	0.39/0.12/89.7/79.5
	Simulation 2												
Gros changements	Simulation 1								29.4/30.1/13.5/82.6 (3.39/3.42/61.8/97.1)	8.08/5.32/20.3/30.4 (6.07/6.20/41.1/96.8)	2.53/2.25/64.5/91.1 (1.35/1.34/44.4/97.4)	<b>0.34/0.16/96.4/95.7</b>	0.50/0.14/97.5/93.1
	Simulation 2												
		<b>Vrai positifs</b>		<b>Vrai négatifs</b>		<b>Faux positifs</b>		<b>Faux négatifs</b>					

FIGURE 2 : Résultats qualitatifs et quantitatifs sur des images TerraSAR-X (Saint-Gervais) et des changements simulés. Les deux premières colonnes sont les deux images dans lesquelles on recherche les changements. Les cinq colonnes suivantes sont les résultats de différentes méthodes. De gauche à droite : PCA k-means [3], SAFNet [7], FFITN [9], incertitude pixellique [2] et proposée. Les sous-titres indiquent des performances sur quatre métriques en pourcentage : l'erreur globale (OE =  $(FP + FN) / (\mathbb{T}P + TN + FP + FN)$ ), le taux de fausses alarmes (FAR =  $FP / (TN + FP)$ ), la précision (Pre =  $\mathbb{T}P / (\mathbb{T}P + FP)$ ) étant le pourcentage de bonnes détections parmi toutes les détections, et le rappel (Rec =  $\mathbb{T}P / (\mathbb{T}P + FN)$ ) mesurant la capacité à ne pas manquer des changements. Les métriques entre parenthèses sont celles des méthodes de l'état de l'art précédées par une étape de débruitage.

lieux (CFAR), et d'autre part que l'information de structure capturée améliore la précision sur des régions très texturées.

## 5 Remerciements

Ce travail a été partiellement soutenu par l'Agence de l'Innovation de Défense – AID – via Centre Interdisciplinaire d'Études pour la Défense et la Sécurité – CIEDS – (projet 2023 - ALIA).

Merci à Berlivet Kilian et Lecomte Bastien, deux étudiants de Télécom-Paris qui ont contribué à la synthèse d'images de changements.

## Références

- [1] L. BRUZZONE et AL. : Automatic analysis of the difference image for unsupervised change detection. *IEEE TGRS*, mai 2000.
- [2] T. BULTINGAIRE et AL. : Unsupervised Radiometric Change Detection from Synthetic Aperture Radar Images. *In EUSIPCO*, août 2024.
- [3] T. CELIK : Unsupervised Change Detection in Satellite Images Using Principal Component Analysis and k-Means Clustering. *IEEE GRSL*, octobre 2009.
- [4] L. CHEN et AL. : Simple Baselines for Image Restoration. *In ECCV*, 2022.
- [5] Y. CHEN et AL. : Self-Supervised Change Detection in Multiview Remote Sensing Images. *IEEE TGRS*, 2022.
- [6] E. DALSSASSO et AL. : As If by Magic : Self-Supervised Training of Deep Despeckling Networks With MERLIN. *IEEE TGRS*, 2022.
- [7] Y. GAO et AL. : Synthetic Aperture Radar Image Change Detection via Siamese Adaptive Fusion Network. *IEEE JSTRS*, 2021.
- [8] J. LEHTINEN et AL. : Noise2Noise : Learning Image Restoration without Clean Data. *In ICML*, juillet 2018.
- [9] M. MA et AL. : Unsupervised SAR Image Change Detection Based on Feature Fusion of Information Transfer. *IEEE GRSL*, 2023.
- [10] W. SHI et AL. : Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. *In IEEE CVPR*, juin 2016.
- [11] W. SHI et AL. : Change Detection Based on Artificial Intelligence : State-of-the-Art and Challenges. *Remote Sensing*, janvier 2020.