



**HAL**  
open science

# Évaluation du couvert neigeux à partir d'images SAR par apprentissage profond basé sur des images optiques de référence

Mathias Montginoux, Flora Weissgerber, Sylvain Lobry, Jérôme J. Idier

## ► To cite this version:

Mathias Montginoux, Flora Weissgerber, Sylvain Lobry, Jérôme J. Idier. Évaluation du couvert neigeux à partir d'images SAR par apprentissage profond basé sur des images optiques de référence. 29e colloque GRETSI, Aug 2023, Grenoble (38000), France. hal-04256105

**HAL Id: hal-04256105**

**<https://hal.science/hal-04256105>**

Submitted on 24 Oct 2023

**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.

Public Domain

# Évaluation du couvert neigeux à partir d’images SAR par apprentissage profond basé sur des images optiques de référence

Mathias MONTGINOUX<sup>1,2,3</sup> Flora WEISSGERBER<sup>1</sup> Sylvain LOBRY<sup>2</sup> Jérôme IDIER<sup>3</sup>

<sup>1</sup> ONERA/DTIS, Université Paris-Saclay, 91120 Palaiseau, France

<sup>2</sup> LIPADE, Université Paris Cité, 75006 Paris, France

<sup>3</sup> Nantes Université, École Centrale Nantes, LS2N, CNRS, Nantes, France

**Résumé** – Les images satellites optiques sont couramment utilisées pour évaluer le couvert neigeux, mais dépendent des conditions météorologiques telles que les nuages. Pour pallier ce problème, nous proposons de détecter la neige à partir d’images SAR acquises par Sentinel-1 en utilisant un réseau de neurones convolutif entraîné avec des étiquettes issues d’images optiques MODIS. Une segmentation sémantique binaire est calculée à partir de deux entrées SAR polarimétrique : un ratio de neige humide et un ratio de neige sèche. Le modèle, appelé SESAR U-net, est entraîné sur une petite zone puis testé sur l’ensemble d’un bassin versant. Les étiquettes affectées par les nuages sont interpolées et l’incertitude est prise en compte. Notre méthode permet d’obtenir une précision globale supérieure à 80 %.

**Abstract** – Optical satellite images are commonly used to evaluate the snow cover. However, part of the information is lost due to clouds. To fill this gap we propose to detect the snow from Sentinel-1 SAR images using a convolutional neural network trained with labels obtained from MODIS optical images. A binary semantic segmentation is computed from two polarimetric SAR inputs: a wet snow ratio and a dry snow ratio. The model, called SESAR U-net, is trained on a small area and then tested over a whole watershed. The missing labels are interpolated and the uncertainty due to clouds is considered. Our proposed method gives an overall accuracy higher than 80%.

## 1 Introduction

La multiplication des missions spatiales d’observation de la Terre dans le domaine optique et radar offre l’accès à une grande quantité de données permettant le suivi des changements de notre environnement tels que l’enneigement et la déforestation. Les techniques de traitement de ces données doivent tenir compte des différentes résolutions spatiales, temporelles et spectrales des capteurs disponibles afin d’enrichir les informations sur l’état physique de la surface de la Terre.

Dans le contexte du suivi de l’enneigement, l’estimation à grande échelle de la fraction enneigée et de la hauteur de neige ont un intérêt majeur pour l’analyse du changement climatique [1] et pour la gestion du productible hydraulique [2]. Cette estimation peut se faire à l’aide d’acquisitions satellites optiques fournissant un indicateur de neige appelé *Normalized Difference Snow Index* (NDSI). Il est par exemple fourni quotidiennement par l’instrument MODIS des satellites de la NASA Aqua et Terra. Cependant, les images satellites optiques ne fournissent pas d’information sur le couvert neigeux lorsqu’il y a des nuages. Pour pallier ce problème, le recours aux satellites radars peut être intéressant car ceux-ci ne dépendent pas des conditions météorologiques. De plus, les images radars permettent d’estimer certaines propriétés de la neige telles que sa hauteur [3] ou son équivalent en eau [4].

Le suivi de l’enneigement à l’aide de systèmes *Radar à Synthèse d’Ouverture* (RSO, SAR en anglais) satellitaires s’est développé ces dernières années, notamment via l’apprentissage [5] et plus particulièrement l’apprentissage profond [6]. Par exemple, les réseaux de neurones convolutifs réussissent à extraire l’information des images SAR polarimétriques pour

des tâches de segmentation appliquées à la neige [7]. Pour l’observation de la neige par des ondes radars, il faut distinguer la neige humide et la neige sèche. La détection de neige humide est souvent réalisée à partir d’une méthode de détection de changement basée sur deux polarisations d’une même acquisition SAR [8, 9]. La détection de neige sèche est plus complexe. Elle peut également être réalisée par des approches polarimétriques [10]; de plus, il est possible d’estimer une hauteur de neige à l’aide d’images optiques en complément des images radars [3].

Dans cet article, nous proposons de détecter la neige à partir d’acquisitions SAR de Sentinel-1, qui ne sont pas impactées par la présence de nuages. La détection est effectuée par une méthode d’apprentissage profond entraînée à partir d’étiquettes dérivées du NDSI obtenu par MODIS. Cette méthode permet de détecter la neige, qu’elle soit humide ou sèche, contrairement aux méthodes proposées précédemment. Nous proposons également d’étudier l’impact de l’interpolation temporelle de la vérité terrain issue des données optiques en présence de nuages.

Nous décrivons dans la Section 2 les données SAR et optiques, dans la Section 3 la méthode implémentée, et dans la Section 4 les résultats. Enfin, nous proposons des perspectives de généralisation spatiale et temporelle de notre modèle.

## 2 Zone d’études et données

La zone d’étude choisie est le bassin du Guil, d’environ 420 km<sup>2</sup>, dans les Alpes françaises à la frontière de l’Italie (voir Figure 1). Une plus petite zone de 59 km<sup>2</sup> autour d’Abriès (voir Figure 1) est choisie afin de constituer les jeux de données

d'entraînement et de validation. Le reste du bassin est réservé pour la phase de test. La période choisie va de juillet 2018 à décembre 2019, de sorte à disposer d'un hiver hydrologique complet et le début de l'hiver suivant.



FIGURE 1 : Le bassin du Guil et Abriès.

Les données Sentinel-1 utilisées sont les acquisitions SLC (*Single Look Complex*) dans le mode interférométrie large (IW), permettant de couvrir des grandes zones (plusieurs bassins) avec une résolution de  $5 \times 20$  m en distance-azimut. Chacune de ces acquisitions fournit deux images complexes, respectivement en polarisation VV et VH. Cela signifie que l'onde est émise dans la polarisation verticale et réceptionnée dans la polarisation verticale (VV) ou horizontale (VH). Pour le bassin du Guil, trois orbites sont sélectionnées : l'orbite ascendante A88 et les orbites descendantes D66 et D139. Les séries temporelles SAR pour chaque orbite sont produites à l'aide de l'algorithme de recalage *LabSAR* [11].

L'instrument MODIS fournit le produit d'enneigement NDSI quotidiennement à une résolution de  $500 \times 500$  m. Le NDSI est entre 0 et 100 et indique une présence de neige lorsque celui-ci est supérieur à 40. Il n'est pas défini en présence de nuages ou de défauts d'acquisition. Dans ce travail, les images optiques sont recalées dans la géométrie de chacune des orbites de Sentinel-1 afin de préserver les propriétés statistiques radars.

Pour la zone autour d'Abriès entre juin 2018 et septembre 2019, nous avons 108 acquisitions SAR de taille  $1024 \times 1024$  pixels grâce aux trois orbites et 433 images MODIS. Trois classes sont extraites du NDSI de MODIS : `no_ndsi`, `no_snow` (NDSI < 40) et `snow` (NDSI  $\geq$  40). Toutes ces images constituent les jeux de données d'entraînement et de validation. Pour la zone du Guil entre juin 2018 et décembre 2019, nous avons 19 acquisitions SAR de taille  $1800 \times 8700$  pixels environ. Ces images constituent le jeu de données de test. La zone du Guil est plus grande que celle d'Abriès d'un facteur 13 en nombre de pixels.

## 3 Méthode

### 3.1 Génération des entrées radars

L'angle d'incidence local ayant une influence forte sur la valeur de la rétrodiffusion pour un même matériau, nous avons privilégié une approche permettant de détecter les changements d'état de surface engendrés par la neige. Le ratio  $R_{\text{wet}}$  permet de mesurer la diminution de la rétrodiffusion engendrée par la neige humide [8] à partir des coefficients de rétrodiffusion

$\sigma^0$  :

$$R_{\text{wet}}(t) = \frac{1}{2} \frac{\sigma_{\text{vh}}^0}{\sigma_{\text{vh,ref}}^0}(t) + \frac{1}{2} \frac{\sigma_{\text{vv}}^0}{\sigma_{\text{vv,ref}}^0}(t). \quad (1)$$

Pour mesurer l'augmentation de la rétrodiffusion volumique due à la neige sèche, nous avons introduit le ratio  $R_{\text{dry}}$  :

$$R_{\text{dry}}(t) = \frac{\sigma_{\text{vh}}^0 / \sigma_{\text{vv}}^0}{\sigma_{\text{vh,ref}}^0 / \sigma_{\text{vv,ref}}^0}(t). \quad (2)$$

En effet, il a été montré que le ratio  $\frac{\sigma_{\text{vh}}^0 / \sigma_{\text{vv}}^0(t)}{\sigma_{\text{vh}}^0 / \sigma_{\text{vv}}^0(t + \delta t)}$  est proportionnel à la hauteur de neige accumulée entre  $t$  et  $t + \delta t$  [3]. Ces ratios permettent aussi de s'affranchir de la calibration radiométrique [12]. Les références  $\sigma_{\text{vv,ref}}^0$  et  $\sigma_{\text{vh,ref}}^0$  sont estimées temporellement par l'estimateur du maximum de vraisemblance d'une loi Gamma à partir de 9 images acquises entre août 2018 et octobre 2018, qui sont choisies car elles ne comportent pas de neige d'après les images MODIS.

Ces ratios sont ensuite convertis en dB avant d'être normalisés entre 0 et 1. La présence de speckle et de cibles brillantes dans les images SAR engendre ponctuellement des valeurs extrêmes de ratio qui peuvent perturber l'apprentissage. Ces valeurs ne présentent qu'un faible pourcentage sur l'ensemble de la pile d'images SAR et nous avons choisi de les saturer en définissant  $p$ , le pourcentage de valeurs saturées de part et d'autre de la distribution. Le paramètre  $p$  choisi est de 0.1 % de sorte à avoir une dynamique de valeur entre 0 et 1 la plus grande possible tout en limitant l'impact des valeurs aberrantes. Finalement, les images ayant servi de références sont retirées des jeux de données d'entraînement et de validation.

### 3.2 Interpolation temporelle du NDSI

Les images MODIS sont très affectées par la présence de nuages : 52 % de `no_ndsi` (voir Table 1). Cependant, il est préférable d'avoir le plus d'étiquettes possible pour la phase d'entraînement. Puisque la neige persiste sur une surface pendant une certaine période de temps, une interpolation temporelle du NDSI peut alors être envisagée pour diminuer la proportion de `no_ndsi`. D'après [13], un intervalle de 3 jours est optimum pour réaliser cette interpolation temporelle car un nuage peut persister au-dessus d'une même zone entre 2 et 3 jours en moyenne. La même étude sur la continuité des nuages a été réalisée sur nos données MODIS sur une période d'un an et donne des résultats similaires : la persistance d'un nuage est légèrement supérieure à 2 jours en moyenne. Nous avons donc implémenté deux méthodes : une interpolation partielle simple sur un intervalle de trois jours et une interpolation par lissage de Kalman. Ceci fournit quatre jeux d'étiquettes différents : `MODIS` pour les étiquettes brutes de MODIS, `MODIS+` pour les étiquettes interpolées partiellement, `MODIS+K` pour les étiquettes interpolées par Kalman, `MODIS+Kerr` pour les étiquettes interpolées par Kalman incluant la variance de l'erreur d'interpolation.

#### 3.2.1 Interpolation partielle

Pour chaque pixel classé comme nuage à une date  $t$ , la valeur du NDSI calculée est la moyenne entre le NDSI des dates  $t - 1$  et  $t + 1$ . En présence de nuage pour seulement une de ces dates, on attribue à la date  $t$  la valeur du NDSI à la date disponible.

En présence de nuage pour ces deux dates, le pixel à la date  $t$  reste classé comme `no_ndsi`.

### 3.2.2 Interpolation par lissage de Kalman

L'utilisation d'un lisseur de Kalman présente deux avantages majeurs dans notre cas : d'une part, il permet d'interpoler la totalité des pixels classés `no_ndsi` ; d'autre part, il fournit une mesure d'incertitude liée à l'interpolation. Le modèle d'état considéré est le suivant :

$$\begin{cases} x_{t+1} = x_t + \epsilon_t^p & \text{avec } \epsilon_t^p \sim \mathcal{N}(0, \sigma_p^2) \\ y_t = x_t \end{cases} \quad (3)$$

où  $x_t$  représente l'état du NDSI d'un seul pixel à une date  $t$  et  $y_t$  représente le NDSI d'un seul pixel mesuré par MODIS à une date  $t$ . L'état initial  $x_0 \sim \mathcal{N}(0, \sigma_0^2)$  a peu d'impact sur le résultat car il est en dehors de la fenêtre d'étude. L'équation d'état est celle d'une marche aléatoire. Le mode opératoire implémenté est celui d'un lissage de Kalman à intervalle fixe [14, p. 187-190], car nous avons la totalité de la série temporelle MODIS pour la période choisie. Les paramètres  $\sigma_p^2$  et  $\sigma_0^2$  sont fixés à 1 dans ce travail (1% du NDSI maximum qui est 100).

### 3.2.3 Proportions des classes

Après avoir retiré les images ayant servi de référence dans le jeu de données d'Abriès, nous regardons la proportion de chacune des classes dans les différentes méthodes d'obtention d'étiquettes (voir Table 1). La proportion de `no_ndsi` dans les étiquettes MODIS+K est due au recalage des images optiques dans la géométrie radar. Cette étape nécessite l'utilisation d'un modèle numérique de terrain. Celui utilisé, fourni par l'IGN, est d'une résolution de 1 m mais n'est pas disponible en Italie : certaines parties des images optiques autour d'Abriès ne peuvent pas être recalées et n'ont donc pas d'étiquettes. Cette proportion liée au recalage est présente dans les trois types d'étiquettes. On en déduit que la méthode d'interpolation partielle permet de réduire de plus de 50 % la proportion de `no_ndsi`. Les deux méthodes d'interpolation ont pour effet d'augmenter légèrement la proportion de `no_snow`.

Enfin, ce jeu de données est réparti de façon à obtenir environ 80% de pixels «utiles» pour l'entraînement et environ 20 % pour la validation, tout en conservant une proportion des classes `no_snow` et `snow` équilibrée et en ayant des dates réparties de manière uniforme sur l'hiver 2018-2019.

TABLE 1 : Proportion des classes dans les trois jeux de données autour d'Abriès et dans le jeu de données de test.

		Abriès			Guil
		MODIS	MODIS+	MODIS+K	MODIS+
Toutes classes	<code>no_ndsi</code>	52.21	23.79	06.95	31.97
	<code>no_snow</code>	25.90	43.69	53.99	36.17
	<code>snow</code>	21.89	32.52	39.06	31.86
Classes utiles	<code>no_snow</code>	54.19	57.32	58.02	53.16
	<code>snow</code>	45.8	42.67	41.97	46.84

## 3.3 Modèle

Nous formulons le problème comme une tâche de segmentation sémantique car on souhaite connaître l'état de chaque

pixel pour pouvoir ensuite calculer des proportions (de neige par exemple). Nous utilisons un réseau U-net [15] avec un encodeur `Efficientnet-B0`. Cette architecture est souvent utilisée et a l'avantage d'avoir un relativement faible nombre de paramètres (environ 6 millions). La classe `no_ndsi` est ignorée par le modèle et la fonction de coût choisie est l'entropie croisée binaire qui s'écrit pour chaque pixel comme  $\mathcal{L} = \mathcal{L}_{\text{BCE}} \mathcal{M}$  où  $\mathcal{M}$  est un masque binaire qui vaut 0 pour la classe `no_ndsi`. La détection des ombres et des zones de *layover* pourrait être ajoutée à ce masque, afin que le modèle ne soit pas pénalisée sur ces zones où la détection de neige n'est soit pas possible (ombre) soit ambiguë (*layover*).

Les modèles ont été entraînés sur les différentes étiquettes MODIS avec l'algorithme du gradient stochastique avec un taux d'apprentissage de  $5.10^{-5}$  et des découpages d'image de taille  $256 \times 256$ .

### 3.3.1 Augmentation de données

Pour augmenter artificiellement la taille des données et rendre notre modèle plus robuste, un découpage aléatoire est réalisé pour l'entraînement, tandis que ce découpage est régulier pour la validation. Les données SAR présentant deux orbites descendantes et une orbite ascendante, le relief autour d'Abriès n'est pas observé de façon identique selon les orbites. En effet, l'angle d'incidence change d'une orbite à l'autre, et surtout les effets de contraction et de repliement des images SAR font que certaines faces des montagnes peuvent être observées de manière très précise pour une orbite ascendante, et très peu pour une orbite descendante, et inversement. Pour rendre notre modèle plus robuste à ces différentes acquisitions, des rotations de  $180^\circ$  sont appliquées de manière aléatoire pour l'entraînement, de sorte à équilibrer artificiellement la proportion d'images acquises dans des orbites ascendante et descendante. L'utilisation des rotations dans les augmentations de données n'est pas facilement interprétable par rapport aux spécificités d'acquisition des images SAR [16]. Ainsi, nous avons limité les rotations à  $180^\circ$  pour conserver l'orientation de l'axe azimut (à la verticale) et la direction de visée et pour passer d'une orbite ascendante à descendante, et inversement.

### 3.3.2 Prise en compte de l'erreur de Kalman

Pour les étiquettes MODIS+KERR, le lisseur de Kalman fournit également pour chaque acquisition la variance de l'erreur  $\gamma_t$  qui est prise en compte dans la fonction de coût :

$$\mathcal{L}_K = \frac{1}{1 + \gamma_t} \mathcal{L}_{\text{BCE}} \mathcal{M}. \quad (4)$$

## 4 Résultats et discussions

La Table 2 montre de meilleures performances globales sur les jeux de données interpolés. D'après la Table 1, ces jeux de données ont plus de pixels utiles pour la tâche à réaliser, ce qui explique ce gain. De plus, le modèle entraîné sur MODIS+K détecte mieux la neige que celui entraîné sur MODIS+. Cependant, on remarque dans un premier temps que pour le modèle entraîné sans les rotations, la prise en compte de la variance de l'erreur  $\gamma_t$  n'améliore pas les performances globales à cause d'une sur-prédiction de la classe neige.

TABLE 2 : Métriques sur les images de test des modèles sans et avec rotations des données. *OA* signifie *Overall Accuracy*, *IoU* signifie *Intersection over Union*. Les meilleurs résultats par métrique sont indiqués en gras.

		MODIS		MODIS+		MODIS+K		MODIS+Kerr	
		no_snow	snow	no_snow	snow	no_snow	snow	no_snow	snow
sans rotations	<b>F1</b>	61.38 ± 1.28	73.17 ± 0.94	63.64 ± 4.51	74.41 ± 0.79	78.98 ± 2.83	80.22 ± 1.63	74.97 ± 2.37	79.52 ± 1.18
	<b>Recall</b>	47.37 ± 2.49	92.19 ± 3.25	49.89 ± 6.32	92.89 ± 2.74	72.38 ± 6.25	87.95 ± 4.67	63.61 ± 3.48	<b>93.24 ± 1.09</b>
	<b>Precision</b>	87.72 ± 4.13	60.69 ± 0.46	89.26 ± 2.73	62.17 ± 2.32	87.62 ± 3.96	74.03 ± 3.69	<b>91.46 ± 1.16</b>	69.36 ± 1.97
	<b>IoU</b>	44.30 ± 1.33	57.70 ± 1.16	46.84 ± 4.88	59.25 ± 1.01	65.36 ± 3.92	67.01 ± 2.25	60.02 ± 3.05	66.02 ± 1.63
	<b>OAaccuracy</b>	68.36 ± 0.58		70.03 ± 2.09		79.68 ± 2.01		77.49 ± 1.67	
avec rotations	<b>F1</b>	64.69 ± 1.59	74.51 ± 1.67	67.92 ± 3.18	75.31 ± 1.02	81.0 ± 1.15	79.45 ± 0.86	<b>81.59 ± 0.42</b>	<b>80.26 ± 1.11</b>
	<b>Recall</b>	50.99 ± 1.86	92.45 ± 3.55	55.78 ± 4.44	90.68 ± 1.76	79.23 ± 2.81	81.45 ± 2.44	<b>79.36 ± 3.36</b>	82.82 ± 4.43
	<b>Precision</b>	88.77 ± 4.74	62.42 ± 1.01	87.26 ± 1.47	64.46 ± 1.92	82.96 ± 1.45	77.64 ± 1.95	84.2 ± 2.85	<b>78.1 ± 1.97</b>
	<b>IoU</b>	47.83 ± 1.74	59.40 ± 2.1	51.51 ± 3.59	60.41 ± 1.32	68.09 ± 1.61	65.91 ± 1.19	<b>68.91 ± 0.6</b>	<b>67.05 ± 1.54</b>
	<b>OAaccuracy</b>	70.4 ± 1.57		72.13 ± 1.79		80.27 ± 0.9		<b>80.98 ± 0.32</b>	

On observe pour les modèles entraînés avec rotations de meilleures performances globales et aussi un meilleur équilibre dans les prédictions des classes `snow` et `no_snow`. De plus, la prise en compte de la variance de l'erreur fournie par le lisseur de Kalman améliore alors les performances.

Finalement, la Figure 2 montre un bon potentiel de généralisation spatiale. En effet, l'apprentissage n'a été réalisé que sur une petite zone du bassin et la prédiction sur le bassin en entier est satisfaisante visuellement ainsi qu'en termes de performance globale sur cette image.




FIGURE 2 : Prédiction du modèle entraîné avec des rotations sur Abriès avec MODIS+Kerr. L'étiquette MODIS est celui de MODIS+. L'encadré rouge représente la zone autour d'Abriès ayant servi pour l'entraînement et la validation.

## 5 Conclusion

Les étiquettes optiques altérées par les nuages rendent l'apprentissage délicat par le manque de données utiles pour la détection de neige. Une interpolation temporelle simple, même partielle, produit un gain de performance significatif pour un coût de calcul faible. Cependant, nous avons montré que de meilleurs résultats étaient possibles par une interpolation temporelle plus avancée. Le gain de données utiles mais aussi la continuité spatiale dans les étiquettes sans nuages permettent d'obtenir de premiers résultats intéressants. De plus, la prise en compte de l'incertitude semble être favorable pour l'apprentissage, et pourra être améliorée. L'impact de la variance d'erreur dans la fonction de coût est à étudier, de même que des variantes du lisseur de Kalman, afin de tenir compte de l'incertitude temporelle et spatiale des données. En effet, la différence de résolution entre les entrées SAR et les étiquettes obtenues depuis les images MODIS étant grande (d'un facteur 25 à 100) une incertitude sur les bords, *la ligne de neige*,

pourrait être ajoutée dans l'entraînement. L'utilisation d'autres données optiques de résolution plus fine comme Sentinel-2 pourrait aussi faciliter l'apprentissage et améliorer l'évaluation des performances du modèle. Des travaux futurs pourront s'orienter vers l'ajout de métadonnées, telle que l'altitude, et la comparaison des entrées SAR : les ratios évoqués précédemment par rapport aux rétrodiffusions VV et VH directement, ainsi que l'influence des orbites sur l'apprentissage.

## Références

- [1] F. Aguirre *et al.*, « Snow cover change as a climate indicator in Brunswick Peninsula, Patagonia », *Frontiers in Earth Science*, vol. 6, 2018.
- [2] L. Rouhier, *Régionalisation d'un modèle hydrologique distribué pour la modélisation de bassins non jaugés. Application aux vallées de la Loire et de la Durance*, Thèse de Doctorat, Sorbonne université, 2018.
- [3] H. Lievens *et al.*, « Snow depth variability in the Northern Hemisphere mountains observed from space », *Nature Communications*, vol. 10, 1, pp. 4629, déc. 2019.
- [4] N. Besic *et al.*, « Dry snow backscattering sensitivity on density change for SWE estimation », in *IGARS*, 2012, pp. 4418–4421.
- [5] J. Park *et al.*, « Prediction of active microwave backscatter over snow-covered terrain across Western Colorado using a land surface model and support vector machine regression », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 14, pp. 2403–2417, 2021.
- [6] N. Usami *et al.*, « PolSAR wet snow mapping with incidence angle information », *IEEE Geosci. Remote. Sens. Lett.*, vol. 13, 12, pp. 2029–2033, 2016.
- [7] F. M. Bianchi *et al.*, « Snow avalanche segmentation in SAR images with fully convolutional neural networks », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 14, pp. 75–82, 2021.
- [8] T. Nagler *et al.*, « Advancements for snowmelt monitoring by means of Sentinel-1 SAR », *Remote Sensing*, vol. 8, 04 2016.
- [9] F. Karbou *et al.*, « Monitoring wet snow over an alpine region using Sentinel-1 observations », *Remote Sensing*, vol. 13, 3, pp. 381, fév. 2021.
- [10] A. Reppucci *et al.*, « Estimation of snow-pack characteristics by means of polarimetric SAR data », in *Remote Sens. Agric., Ecosyst. Hydrol. XIV*, 2012, vol. 8531.
- [11] F. Weissgerber *et al.*, « LabSAR, a one-GCP coregistration tool for SAR–InSAR local analysis in high-mountain regions », *Front. Remote Sens.*, vol. 3, 2022.
- [12] N. Miranda et P. Meadows, « Radiometric calibration of s-1 level-1 products generated by the s-1 ipf », Rapport interne, ESA, 2015.
- [13] J. Hou *et al.*, « Gap-filling of MODIS fractional snow cover products via non-local spatio-temporal filtering based on machine learning techniques », *Remote Sensing*, vol. 11, 1, 2019.
- [14] B. D. O. Anderson et J. B. Moore, *Optimal filtering*, Dover Publ, 2005.
- [15] O. Ronneberger *et al.*, « U-net : Convolutional networks for biomedical image segmentation », in *MICCAI*. Springer, 2015, pp. 234–241.
- [16] X. X. Zhu *et al.*, « Deep learning meets SAR : Concepts, models, pitfalls, and perspectives », *IEEE Geosci. Remote Sens. Mag.*, vol. 9, 4, pp. 143–172, 2021.