

**Département de géomatique appliquée
Faculté des lettres et sciences humaines
Université de Sherbrooke**

**Amélioration de la caractérisation de la neige et du sol arctique afin d'améliorer la
prédiction de l'équivalent en eau de la neige en télédétection micro-ondes**

Julien Meloche

**Thèse présentée pour l'obtention du grade de doctorant en télédétection,
cheminement en physique de la télédétection**

© Julien Meloche, 2021

Directeur de recherche : Alexandre Langlois

Co-directeur de recherche : Nick Rutter

Co-directeur de recherche : Alain Royer

Résumé

Le phénomène de l'amplification arctique consiste en une augmentation plus prononcée des températures de surface dans cette région que sur le reste du globe. Ce phénomène est notamment dû à la diminution marquée du couvert nival provoquant un déséquilibre dans le bilan d'énergie de surface via une réduction généralisée de l'albédo (rétroaction positive). L'accélération du réchauffement est jusqu'à trois fois plus élevée dans ces régions. Il est donc primordial, dans un contexte de changement climatique arctique, de poursuivre et d'améliorer le suivi à grande échelle du couvert nival afin de mieux comprendre les processus gouvernant la variabilité spatio-temporelle du manteau neigeux. Plus spécifiquement, l'Équivalent en Eau de la Neige (EEN) est généralement utilisé pour quantifier deux propriétés (hauteur et densité) de la neige. Son estimation à grande échelle dans les régions éloignées tel que l'Arctique provient actuellement essentiellement de produits en micro-ondes passives satellitaires. Cependant, il existe encore beaucoup d'incertitudes sur les techniques d'assimilation de l'ÉEN par satellite et ce projet vise une réduction de l'erreur liée à l'estimation de l'ÉEN en explorant deux des principales sources de biais tels que : 1) la variabilité spatiale de l'épaisseur et des différentes couches du manteau neigeux arctique liées à la topographie et la végétation au sol influençant l'estimation de l'ÉEN; et 2) les modèles de transfert radiatif micro-ondes de la neige et du sol ne bénéficient pas actuellement d'une bonne paramétrisation en conditions arctiques, là où les erreurs liées à l'assimilation de l'ÉEN sont les plus importantes. L'objectif global est donc d'analyser les propriétés géophysiques du couvert nival en utilisant des outils de télédétection et de modélisation pour diminuer l'erreur liée à la variabilité spatiale locale dans l'estimation du ÉEN à grande échelle, tout en améliorant la compréhension des processus locaux qui affectent cette variabilité. Premièrement, une analyse haute résolution à l'aide de l'algorithme Random Forest a permis de prédire la hauteur de neige à une résolution spatiale de 10 m avec une RMSE de 8 cm (23%) et d'en apprendre davantage sur les processus de distribution de la neige en Arctique. Deuxièmement, la variabilité du manteaux neigeux arctique (hauteur et microstructure) a été incorporée dans des simulations en transfert radiatif micro-ondes de la neige et comparée au capteur satellitaire SSMIS. L'ajout de variabilité améliore la RMSE des simulations de 8K par rapport à un manteau neigeux uniforme. Finalement, une

paramétrisation du sol gelé est présentée à l'aide de mesures de rugosité provenant de photogrammétrie (Structure-from-Motion). Cela a permis d'investiguer trois modèles de réflectivité micro-ondes du sol ainsi que la permittivité effective du sol gelé avec une rugosité SfM d'une précision de 0.1 mm. Ces données de rugosité SfM avec une permittivité optimisée ($\epsilon'_{19} = 3.3$, $\epsilon'_{37} = 3.6$) réduisent significativement l'erreur des températures de brillance simulées par rapport à des mesures au sols (RMSE = 3.1K, $R^2 = 0.71$) pour toutes les fréquences et polarisations. Cette thèse offre une caractérisation des variables de surface (neige et sol) en Arctique en transfert radiatif micro-ondes qui bénéficie aux multiples modélisations (climatiques et hydrologiques) de la cryosphère.

Mot clés : Télédétection, neige, Arctique, ÉEN,

Table des Matières

Liste des figures	v
Listes des tableaux	ix
Liste des acronymes et sigles	x
Liste des symboles	xi
Remerciements.....	xiv
1. Introduction	1
1.1 Problématique	1
1.2 État de l'art.....	2
1.2.1 Prédition locale du ÉEN	2
1.2.2 Prédition de l'ÉEN provenant de PMW satellitaire	4
1.2.3 Erreur liée à la paramétrisation des modèles de transfert radiatif.....	6
1.3 Objectifs.....	9
1.3.1 Canevas de la thèse	9
2 Cadre Théorique.....	10
2.1 Forêt d'arbres décisionnels	10
2.2 Paramètres topographiques (TPI et <i>Sx</i>).....	11
2.3 Représentation de la variabilité de la neige	13
2.4 Bases du transfert radiatif satellitaire.....	14
2.5 Modèle Snow Microwave Radiative Transfer (SMRT).....	16
2.6 Base du transfert radiatif du sol	20
2.6.1 Permittivité du sol	23
2.6.2 Rugosité du sol.....	24
2.7 Algorithme Structure from Motion (SfM)	27
3 Méthode générale de la thèse	29
4 High-resolution snow depth prediction using Random Forest algorithm: a case study in the Greiner Watershed, Nunavut with an ecosystem map	32
4.1 Introduction.....	34
4.2 Method	36
4.2.1 Study site and ecosystems.....	36
4.2.2 Data	37
4.2.2.1 Snow depth measurements.....	37

4.2.2.2 Random Forest (RF) algorithm	38
4.2.2.3 Predictors for snow depth	39
4.3 Results.....	40
4.3.1 Ecotypes and snow depth.....	40
4.3.2 RF algorithm evaluation.....	41
4.3.3 Spatial prediction of snow depth across Greiner Watershed	44
4.4 Discussion and Conclusion.....	45
5 Characterizing Tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals	55
5.1 Introduction.....	59
5.2 Methods.....	61
5.2.1 Study site.....	61
5.2.2 Data	62
5.2.3 Measured brightness temperatures and Snow Microwave Radiative Transfer (SMRT)	64
5.2.4 Gaussian Processes	65
5.3 Results.....	66
5.3.1 Snow depth distribution	66
5.3.2 Analysis of SSA and density per layer	70
5.3.3 DHF predictions using snow depth with Gaussian Processes.....	73
5.3.4 SMRT simulation of sub-grid variability within sensor footprint	74
5.4 Discussion	77
5.5 Conclusion	80
6 Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry	88
6.1 Introduction.....	91
6.2 Background	93
6.2.1 Permittivity model of Zhang et al. (2010)	93
6.2.2 QNH	94
6.2.3 Weg99 model	94
6.2.4 Geo Optics solution.....	95
6.3 Data and methods.....	97
6.3.1 Study site.....	97

6.3.2 Roughness measurements	98
6.3.3 Radiometric data	100
6.4 Results.....	102
6.4.1 Roughness measurements	102
6.4.2 Brightness temperature simulation	103
6.4.3 Analysis of rock sites	106
6.5 Sensitivity analysis and Discussion	108
6.6 Conclusion	111
References.....	114
7 Conclusion	122
7.1 Perspectives et projets futurs.....	124
8 Références (hors articles).....	126
Annexe 1 : Publications	134
Annexe 2: Conférences	134
Annexe 3: Incertitudes	135

Liste des figures

Figure 1-1: Variabilité spatiale de la neige arctique en Alaska due à la topographie et la végétation présente dans le paysage tiré de (Sturm et Wagner, 2010).	3
Figure 1-2: Manteau neigeux arctique typique composé de deux couches: la plaque à vent et le givre de profondeur. La taille des grains de givre de profondeur peut atteindre jusqu'à 20 fois celle des grains ronds de la plaque à vent.	7
Figure 2-1 : Représentation de l'algorithme RF et des multiples arbres décisionnels.	11
Figure 2-2 : Facteur Sx de protection/érosion d'un pixel selon la topographie et la direction du vent. (Tiré de Winstral et al. 2002).....	12
Figure 2-3: Carte globale des catégories du coefficient de variation (CV) pour les distributions de hauteur de neige intrapixel. La température de l'air, la topographie et la vitesse du vent ont été considérées pour catégoriser les régions; v-H, H et L représente très élevé, élevé et faible. (Tirée de Nitta et al. 2014).....	14
Figure 2-4: Diagramme des différentes composantes micro-ondes du signal mesuré par le satellite.....	15
Figure 2-5: Représentation des variables de l'équation différentielle du transfert radiatif (Équation 4.4). (Tirée de Picard et al. 2018)	18

Figure 2-6: Sensibilité de l'émission du manteau neigeux arctique (2 couches) à la hauteur totale du manteau (courbe) et au ratio de givre de profondeur (DHF). Intrant aux simulations pour le givre de profondeur (densité : 266 kg/m ³ , SSA : 11 m ² /kg, température : 250 K) et la plaque à vent (densité : 355 kg/m ³ , SSA : 11 m ² /kg, température : 261 K).....	20
Figure 2-7: Effet sur la température de brillance (<i>TB</i>) de la rugosité (σH) pour trois différents modèles de réflectivité (QNH, Weg99 et Géo optique). Permittivité du sol (3 + 0.1i); température du sol (263 K); <i>TB atm</i> ↓ (10 K); angle d'incidence (55 °); polarisation (verticale).....	23
Figure 2-8: Profile de rugosité d'une surface, le paramètre <i>Ra</i> mesure la rugosité moyenne de la surface tandis que d'autres paramètres, plus locaux, évaluent la hauteur moyenne entre les crêtes et vallées principales. (Tirée de Tonietto et al., 2019).....	25
Figure 2-9: Nuage de point 3D d'une surface naturelle du sol après une rotation appliquée pour définir le nouveau plan normal. L'échelle en z est augmentée de 10x pour accentuer la rugosité. ..	26
Figure 2-10: Semi-variogramme d'une surface rugueuse. La corrélation pour un lag donné est estimée avec le nombre N de pairs correspondants possédant un lag similaire (histogramme rouge). Un modèle théorique gaussien est regressé (courbe verte) avec une longueur de corrélation (<i>lc</i> = 0.21 m).....	27
Figure 2-11: Représentation du processus SfM et de la triangulation des points d'intérêts qui apparaissent sur plusieurs images. Crédit : http://www.theia-sfm.org	28
Figure 3-1: Organigramme de la thèse.	31
Figure 4-1 : Study site of the Greiner watershed, Victoria Island, Nunavut with ecomap from Ponomarenko et al. (2019). Snow depth data (circular and linear transect) selected randomly across the entire dataset for training and validation. Grid of WGS84 lat/long is shown.	37
Figure 4-2: Mean and standard deviation of snow depth with principal ecotypes (Ponomarenko et al. 2019), vegetation height and soil moisture regime. The overall average (across all classes) snow depth is shown by the black dotted line. Vegetation height was estimated based on the type of vegetation in the ecotype. Soil moisture regime is based on the CASBEC classification (McLennan et al. 2018).	41
Figure 4-3: a) Measured and modelled snow depth from RF predictions. b) Residuals with measured values from the RF prediction.	42
Figure 4-4: a) Feature importance in RF snow depth prediction of explanatory variables and b) Correlation matrix between variables calculated with the Pearson coefficient. "Year mean" corresponds to the mean winter snow depth.	42
Figure 4-5 : Feature importance of prediction without the variable TPI. The RMSE of snow depth is 10 cm.....	43
Figure 4-6: Snow depth prediction using the main variables of the RF algorithm (Sx, TPI and ecotype). Only a small subset of ecotypes is shown in the legend although all ecotypes (see Figure 4-1) are displayed on the map and were used in the prediction.	44
Figure 5-1: Locations of study areas in the Canadian Arctic, Cambridge Bay and Trail Valley Creek site. Grid shown is the enhanced 3.125 km EASE grid 2.0 used for satellite data. The ArcticDEM is a 2 m-resolution (Morin et al., 2016) derived from stereo high-resolution visible imagery for the entire Arctic domain, freely available.	62
Figure 5-2: Log-normal and gamma distribution fit to the measured snow depths.....	67
Figure 5-3: RPAS and Lidar dataset of snow depth at TVC (TVC13-Lidar and TVC18-RPAS). TVC13-Lidar is the largest dataset covering 93 km ² . TVC18-RPAS is a smaller dataset	

within the area of TVC13-Lidar. In a) is shown the snow depth map at 10 m resolution from 2013. b) shows a sub grid of 1 km with CV_{sd} for each cell; c) same as b) but for μ_{sd}	69
Figure 5-4: Snow depth mean (μ_{sd}) (a and b) and variability (CV_{sd}) (c and d) as a function of coverage for sampling area: a) and c) small area, b) and d) large area. Monte Carlo simulations were done using the two datasets in TVC. CB18-RPAS was also added in a) because of the similar coverage. The μ_{sd} and CV_{sd} of both full areas are shown by the black dotted and dashed line.....	70
Figure 5-5: SSA and density variability of Surface Snow (SS), Wind Slab (WS) and Depth Hoar (DH) for the two studied sites (TVC and CB) and different dates (see Table 5-5). In c) the best log-normal fit distribution is shown in black; d) same as c) but for the normal fit distribution. In c) and d), the kernel density estimates (KDE) of the histogram of each layer are also shown (in color).....	71
Figure 5-6: a) Depth hoar fraction (DHF) as a function of total depth for snow pit data from 2015-2019 in Cambridge Bay and 2018-2019 for Trail Valley Creek. Both datasets were separated in equal bins (10 cm) to estimate the mean value shown with dashed line. The black line represents the mean for both site with the 95% interval. b) DHF is shown as a function of NVDI from the snowpit area with the mean DHF and NDVI per sites shown by dashed lines and the gaussian distributions of DHF by the solid lines.....	72
Figure 5-7: Prediction on DHF (cyan) using a GP fit trained on observed data (black). Snow depth were samples from a log-normal distribution with parameters from Table 5-4: Statistical parameters of snow depth distributions.. The GP fit is illustrated in red where darker red represents high posterior probability that follows the mean function.	74
Figure 5-8: Brightness temperature variability simulation a) and c) distribution of simulated TB within a pixel, where vertical lines represent the mean of this distribution for V pol (blue), measured by satellite (green) and T_B value simulated from the mean measured snow depth and mean DHF (black). In b) and d), the mean of the simulated TB for H pol (red) and V pol (blue) as a function of CV_{sd} with mean values (dotted black lines). The CV_{sd} that minimized biases is located at the red/blue-green intersection. Shaded blue and red areas correspond to a 2σ range representing uncertainty inherent from our Bayesian simulations in estimating the mean of simulated TB for the pixel.....	76
Figure 5-9: Overall RMSE (year and site) with the mean simulation (dashed black line) and the GP simulation in blue as a function of the coefficient of variation of snow depth.....	77
Figure 6-1. Study site in Greiner Lake watershed, Nunavut, Canada.	97
Figure 6-2. a) 3D point cloud creation, b) clipped 3D model to field of view of radiometer, c) fitted plane to 3D surface and d) histogram of perpendicular distances to plane, with $\sigma_H = 1.3 \text{ cm}$ and 2 787 233 points.	99
Figure 6-3. Simulations using Weg99, QNH and Geo optics models based on roughness estimates from SfM. Permittivity from Zhang10 was used. Polarization ratio (βf) used for Weg99 are ($\beta f19 = 0.72, \beta f37 = 0.42$) (Table 6-3) and parameters for QNH defined in section 6.2.2.	104
Figure 6-4. Simulated vs measured brightness temperatures for all models with optimized permittivity in a), b), and c) and optimization results in d).	105
Figure 6-5. a) Representation of RMSE as function of permittivity and bias in effective temperature of the rock > 75% sites with Weg99 model and roughness SfM. b) Image of one of the rock sites. c) Simulation with modification of $\epsilon' = 8.3$ and a change in temperature of -8°C (from -9.4°C to -17°C) for rock sites.	107

Figure 6-6. Sensitivity analysis on angular dependency of emission with different roughness values, for 19 and 37 GHz with horizontal and vertical polarization. 110

Listes des tableaux

Tableau 2-1: Résumé des paramètres (y) par fréquence pour la relation linéaire $y = a \cdot p_{wat} + b$.	16
.....	
Tableau A-1 : Incertitudes sur les mesures des intrants de simulations du manteaux neigeux avec SMRT.	135
.....	
Table 4-1: Summary of magnaprobe snow depth survey used for training the RF algorithm. The mean (μ_{sd}) and standard deviation (σ_{sd}) of snow depth (m) from each year are presented.	37
.....	
Table 5-1: Summary of number of snow depth measurements (Magnaprobe and RPAS) and snow pit sites per year. The availability of SSA and density measurements across sites and years are also noted (x). See Table 5-2 for full dates.	63
Table 5-2: Summary of mean basal and air surface temperatures for SMRT simulations, precipitable water (PWAT) used for atmospheric correction and measured (corrected) TB at both polarization vertical (V) and horizontal (H) by the SSMIS sensor (platform F18).	65
Table 5-3: Kolmogorov-Smirnov (KS) test for 2 samples of probability distribution function (PDF).	67
Table 5-4: Statistical parameters of snow depth distributions.	68
Table 5-5: Parameters for best fitting distribution of SSA and density for layers of DH and WS.	72
Table 5-6: Bias between SMRT simulated and measured Tb from SSMIS sensor at each site.	77
Table 6-1. Summary of conditions needed for Geo Optics and IEM. Permittivity from Montpetit et al. (2018) was used for calculation.	96
Table 6-2. Summary of radiometric observations and modeled downward atmospheric contributions.	101
Table 6-3. Parameters (Mont18) from optimization in Montpetit et al. (2018) with different soil moisture permittivity from model of Zhang et al., (2010). VMC stands for volumetric moisture content.	102
Table 6-4. Mean value of roughness parameters measured with SfM photogrammetry.	103
Table 6-5. Simulation results using roughness parameters from SfM and permittivity from Zhang10 model (dry: VMC = 0.05).	104
Table 6-6. Results from optimization of permittivity.	106
Table 6-7. Summary of simulation with a fixed SfM value of roughness for all sites without rock.	108
.....	

Liste des acronymes et sigles

3D, 2D : trois et deux dimensions

ACF: Fonction d'autocorrélation

AIEM: *Advanced Integral Equation Model*

CB: Cambridge Bay

CROCUS: Modèle physique de neige de Vionnet *et al.* (2012)

DH : Givre de profondeur (couche du manteau neigeux : *Depth Hoar*)

DHF: Fraction de givre de profondeur

DMRT: *Dense Media Radiative Transfer*

DORT: *Discrete ordinate and eigenvalue method*

EASE: *Equal-Area Scalable Earth*

ÉEN: Équivalent en Eau de la Neige

FEM: *Finite Element Method*

FOV: *Field of View*

GP: Processus Gaussien

GPS: *Global Positioning System*

GCP: Ground Control Point - Point de contrôle au sol

IEM: *Integral Equation Model*

IBA: *Improved Born Approximation*

LIDAR: *Light Detection and Ranging*

MEMLS: *Microwave Emission Multi-Layer Snowpack*

MoM: *Method of Moment*

Mont18: Étude de Montpetit *et al.* (2018)

MPM: *Millimeter-wave Propagation Model*

MTR: Modèle de Transfert Radiatif

NARR: *North American Regional Reanalysis*

pwat: *precipitable water* – eau précipitable

PMW: micro-ondes passives satellitaires

QNH: modèle de réflectivité du sol QNH

RADAR: *Radio Detection and Ranging*

RF: *Random Forest* (algorithme de régression basé sur les forêts d'arbres décisionnels)

RMSE: *Root Mean Square Error* - Erreur quadratique moyenne

RPAS : *Remotely Piloted Aircraft System*

SAR: *Synthetic Aperture Radar* - Radar à synthèse d'ouverture

SBR: *Surface Based Radiometer*

SfM: *Structure-from-Motion*

SPM: *Small Perturbation Method*

SMAP: *Soil Moisture Active Passive*

SMRT: *Snow Microwave Radiative Transfer*

SSA: *Specific Surface Area*

SSMIS: *Special Sensor Microwave Imager/Sounder*

TPI: *Topographic Position Index*

TVC: *Trail Valley Creek*

Weg99: Modèle de Wegmüller et Mätzler (1999)

WS: Plaque à vent (couche du manteau neigeux)

Zhang10 : Permittivité du modèle de Zhang *et al.* (2010)

Liste des symboles

σ_H : écart type de la hauteur d'une surface

l_c : longueur de corrélation d'une surface

m : *mean square slope*

μ_{sd} : moyenne de la hauteur de neige

CV_{sd} : coefficient de variation de la hauteur de neige

S_x : up wind slope index

d_{max} : rayon de recherche pour le paramètre S_x

A_i : direction de l'azimut du paramètre S_x

T_B : température de brillance

- $T_{B\ TOA}$: température de brillance du haut de l'atmosphère
 $T_{B\ surf}$: température de brillance de la surface
 $T_{B\ atm\uparrow}$: température de brillance de l'atmosphère ascendante
 $T_{B\ atm\uparrow-r-surf}$: température de brillance de l'atmosphère descendante réfléchi par la surface
 γ_{atm} : transmittance de l'atmosphère
 $T_{B\ soil}$: température de brillance du sol
 T_{soil}^{eff} : température effective du sol
 κ_e : coefficient d'extinction d'un medium
 κ_s : coefficient de diffusion d'un medium
 κ_a : coefficient d'absorption d'un medium
 P : fonction de phase
 ε : permittivité d'un medium
 l : indice représentant une couche de neige du manteau neigeux
 I : radiation (*specific intensity*) du manteau neigeux
 T : température du manteau neigeux
 κ : constante de boltzmann
 c_0 : vitesse de la lumière dans le vide
 ν : fréquence de l'onde
 λ : longueur d'onde
 p : polarisation (p ou q)
 L_{Debye} : longueur de corrélation de la microstructure de la neige issu de la formule de Debye
 ρ_{neige} : densité de la neige
 ρ_{glace} : densité de la glace
 Q_R : paramètre Q du modèle QNH
 N_H : paramètre N en polarisation H du modèle QNH
 N_V : paramètre N en polarisation V du modèle QNH

H_R : paramètre H en fonction de la rugosité (σ_H) du modèle QNH

k : nombre d'onde

θ : angle d'incidence

β_f : ratio de polarisation

e_p : émission d'une surface en polarisation p, q (ou H, V)

Γ_p : réflectivité en polarisation p, q (ou H, V)

$\Gamma_p^{Fresnel}$: réflectivité de Fresnel en polarisation p, q (ou H, V)

$\gamma_{p\alpha}$: coefficient bistatique en polarisation p et $\alpha = p,q$

f_s : fraction du sol

f_i : fraction de la glace

f_w : fraction de l'eau

ρ_b : densité apparente

ρ_s : densité spécifique

β : paramètre qui dépend de la composition du sol (%argile, %limon et % sable)

R_a : équivalent à σ_H

\vec{n} : vecteur normal à une surface

h : lag

$\zeta(h)$: fonction d'autocorrélation en fonction d'un lag h

e : nombre naturel

κ_{19}, κ_{37} : facteur d'ajustement pour 19 et 37 GHz pour l'équation de Debye

Remerciements

Je tiens à remercier personnellement mon directeur de recherche, Alexandre Langlois, pour sa confiance, sa présence ainsi que pour le nombre incalculable d'opportunités qui m'ont permis de m'épanouir en tant que scientifique, mais aussi comme humain. Je ne connais pas tant d'étudiants qui peuvent dire qu'ils ont détruit un toughbook avec une perceuse à béton, fait voler des avions en mousse à -30, manger du cassoulet dans les alpes et faire du BBQ digne du Texas à Rock Forest. Merci pour tout Alex.

Je remercie aussi mes co-directeurs, Nick Rutter et Alain Royer, pour m'avoir partagé leur passion pour la science par leur conseil judicieux et sérieux, mais aussi leur folie. J'espère que ce chapitre qui se termine est le début d'une longue relation scientifique et personnelle.

Je tiens à remercier tous mes compatriotes du GRIMP qui m'ont accompagné dans mon projet de recherche: Daniel Kramer, Vincent Sasseville, Jean-Benoit Madore, Paul Billecocq, Alex Mavrovic, Simon Levasseur, Guillaume Couture, Céline Vargel, Charlotte Crevier, Coralie Gautier, Francis Meloche, Jacob Laliberté, Alexandre Blanchette, Caroline Dolant, Nico Marchand, Chloé Martineau, Joëlle Voglimacci et les nouveaux! Vous avez fait de ma thèse une aventure incroyable! Je remercie également Patrick Cliche et Patrick Ménard pour leur conseil et aide avec tous mes bidules électroniques.

Je remercie ma copine Gabrielle qui a toujours été présente pour moi dans mon quotidien, mes parents Isabelle et Hugo et ma grand-mère Thérèse, pour leur amour inconditionnel. Je les remercie de m'avoir poussé à me dépasser et poursuivre ce qui me passionne.

Finalement je tiens à remercier mon frère Francis, pour qui je serais encore en train de laver de la vaisselle s'il ne m'avait pas encouragé à poursuivre mon parcours académique.

1. Introduction

1.1 Problématique

Le réchauffement de la température de l'air à la surface de Terre dû à l'augmentation de la concentration des gaz à effet de serre est jusqu'à trois fois plus prononcé en Arctique que sur le reste du globe (AMAP, 2019; Notz et Stroeve, 2016; Richter-Menge *et al.*, 2017). Des répercussions sont déjà particulièrement perceptibles sur les régimes thermiques du pergélisol (i.e. cycles de gel-dégel, profondeur de la couche active), de la glace de mer (couverture spatiale, épaisseur, occurrence de polynies) et du couvert nival (épaisseur et couverture spatiale) (DerkSEN *et al.*, 2019; Natali *et al.*, 2019; Pulliainen *et al.*, 2020). L'amplification du réchauffement dans cette région est gouvernée par cinq processus majeurs contribuant à un cycle de rétroactions positives communément appelé « amplification arctique » (Serreze et Barry, 2011). Plus particulièrement, un processus concerne la neige et le sol. La diminution de la couverture spatiale de la glace de mer et du couvert nival terrestre (Goosse *et al.*, 2018; Screen et Simmonds, 2010) mènent à une diminution importante de l'albédo de surface, causant une forte rétroaction positive. De plus, le couvert nival joue aussi un rôle très important quant à la protection et l'isolation du pergélisol (Romanovsky *et al.*, 2010; Stieglitz *et al.*, 2003) qui à son tour serait potentiellement une autre rétroaction positive sur le climat vu les émanations de méthane potentielles issues du dégel du pergélisol. Finalement, la modification des cycles gel/dégel grandement affectés par le couvert nival et la hausse de température auraient pour principale conséquence de modifier le flux de carbone du sol (Böttcher *et al.*, 2014; Natali *et al.*, 2019).

La neige arctique est généralement caractérisée par deux couches : le givre de profondeur peu dense au niveau du sol et une couche très dense : plaque à vent sur le dessus. Chaque couche possède une conductivité thermique différente ayant une incidence sur l'isolation du pergélisol. Dans un contexte de changement climatique où la fonte du pergélisol menace de libérer une grande quantité de carbone et de méthane, il est crucial de mieux comprendre la variabilité spatiale de cette stratigraphie particulière puisque l'isolation thermique du pergélisol en dépend. Des travaux antérieurs ont tenté de mieux comprendre et détecter les cycles de gél/dégel par télédétection micro-ondes passives, en bande-L par exemple (Prince *et al.*, 2018) cependant, il a été démontré

que cette détection est grandement limitée par l'hétérogénéité spatiale de la neige à l'intérieur des pixels. Lors de la fonte printanière, la distribution spatiale de la neige fait en sorte que certaines parties d'un pixel donné demeurent dégelées et d'autres restent gelées influençant ainsi la classification de l'état du sol par satellite. La neige joue ainsi un rôle clé sur le bilan d'énergie de surface, mais de grandes incertitudes subsistent quant à l'impact de la variabilité spatio-temporelle des propriétés du couvert nival sur les patrons de réchauffement observés et dans la paramétrisation des modèles climatiques. Ceci est en grande partie dû au manque de données *in situ* et de stations météorologiques à l'échelle locale. Cette incertitude mène à des biais systématiques dans les prédictions climatiques de la cryosphère (Langlois *et al.*, 2014) qui pourraient bénéficier d'une meilleure représentativité spatiale des phénomènes locaux gouvernant la variabilité spatiale du couvert nival. Ces biais ont aussi des impacts sur d'autres sphères telles que sociales et économiques. Par exemple, le dégel hâtif du pergélisol et la diminution de la couverture spatiale du couvert nival affectent les communautés du Nord et leur infrastructure. On peut penser ici à la planification de construction durable en milieu de pergélisol, des routes de glace pour le ravitaillement des communautés et des déplacements sur terre et sur mer pour les activités traditionnelles. L'échelle de ces éléments (neige et sol) est telle qu'ils ne peuvent pas être représentés ni suivis avec les produits de télédétection micro-ondes actuels vu les résolutions spatiales trop grossières accompagnées de grandes incertitudes (Saberi *et al.*, 2020). Le manque d'information et de compréhension empirique à plus petite échelle est donc critique sur de nombreux aspects motivant ainsi une meilleure caractérisation des paramètres nivaux à l'échelle locale.

1.2 État de l'art

1.2.1 Prédiction locale du ÉEN

L'Équivalent en Eau de la Neige (ÉEN) est la variable la plus utilisée pour décrire le manteau neigeux puisque plusieurs informations comme la quantité d'eau à la fonte ou la conductivité thermique y sont liées. Cette variable nivale est utilisée dans la recherche climatique pour les bilans d'énergie et hydrologiques de la cryosphère (Larue *et al.*, 2019; Luoju *et al.*, 2011). L'ÉEN se calcule à partir du produit entre la hauteur et de la densité du manteau neigeux. La variation du couvert nival (ou ÉEN) en Arctique varie principalement selon la topographie (Benson et Sturm, 1993; Sturm et Wagner, 2010) et la végétation au sol (Domine *et al.*, 2016; Sturm *et al.*, 2001)

pour une même quantité de précipitation donnée, voir Figure 1-1. Plusieurs de ces processus ont déjà été étudiés, mais le manque de données à haute résolution dans l'Arctique limite les applications nécessitant de l'information nivale qui pourrait bénéficier d'une meilleure représentation locale de la neige. Par exemple, les modèles de prédiction de la couche active du pergélisol basé sur des Modèles Numériques de Terrain (MNT) haute résolution (10 – 100 m) nécessite une information sur le couvert nival à une résolution similaire (Gisnas *et al.*, 2016). De plus, le suivi des écosystèmes de la toundra arctique et leur adaptation à la hausse de température pourraient aussi bénéficier d'information haute résolution de la neige. La résolution des produits actuels de prédiction de l'ÉEN par micro-ondes passives satellitaires (PMW; définit dans la prochaine section) est trop large (25 km) pour étudier de telle phénomènes. Ceci motive donc le développement de missions satellites futures, notamment en micro-ondes actives (i.e. radar) (Garnaud *et al.*, 2019) pour l'estimation de l'ÉEN (250 m) qui nécessiteront une connaissance de la variabilité spatiale de la neige à cette échelle.



Figure 1-1: Variabilité spatiale de la neige arctique en Alaska due à la topographie et la végétation présente dans le paysage tiré de (Sturm et Wagner, 2010).

En ce qui concerne les outils de modélisation, il est actuellement très difficile de simuler le manteaux neigeux à haute résolution en Arctique à l'aide de modèle physique de neige comme

CROCUS (Vionnet *et al.*, 2012) ou SNOWPACK (Bartelt *et al.*, 2002). Ces modèles utilisant des données météorologiques à large échelle (10 km – 40 km) en intrant sont difficiles à spatialiser localement (10 m – 1 km) puisque la hauteur de neige varie principalement due à la topographie et le manque de station météorologique rend difficile l’interpolation pour la spatialisation. Des modèles statistiques alors basés sur des régressions linéaires de paramètres topographiques provenant de MNT (Grünewald *et al.*, 2013; Pulwicki *et al.*, 2018) peuvent être utilisés pour prédire la hauteur de neige à haute résolution spatiale cependant, la corrélation entre les variables topographiques limite la précision de la méthode. Ceci dit, une nouvelle étude (Revuelto *et al.*, 2020) basée sur l’algorithme *Random Forest* (RF) a démontré qu’il est possible d’obtenir une bonne précision sur la prédiction de l’épaisseur de neige en utilisant des variables topographiques comme variables explicatives. L’utilisation de l’algorithme RF permet aussi d’estimer l’importance (i.e. poids) des variables explicatives et par conséquent évaluer les processus conditionnant la hauteur de neige en Arctique. Cette quantification peut servir de fondations pour le développement et amélioration de simulations du couvert nival (Gouttevin *et al.*, 2018; Ouellet *et al.*, 2017) dans un tel environnement qui demeure un réel défi (Domine *et al.*, 2018).

1.2.2 Prédiction de l’ÉEN provenant de PMW satellitaire

La télédétection par micro-ondes passives (notée PMW) permet l’observation de la neige à grande échelle dans des régions éloignées telles que l’Arctique en offrant une haute résolution temporelle sur l’ensemble du territoire tout en étant indépendante de l’éclairement solaire et des conditions atmosphériques de manière générale. Ces données souffrent cependant d’une résolution spatiale très grossière qui est inversement proportionnelle à la fréquence (Armstrong *et al.*, 1995). Contrairement à l’imagerie visible qui informe seulement sur la couverture spatiale de neige (Hall *et al.*, 2002), la télédétection micro-ondes permet d’obtenir l’épaisseur ou l’équivalent en eau de la neige (ÉEN) (Saberi *et al.*, 2020) où les données disponibles depuis 1978 permettent un suivi climatique intéressant à grande échelle. La plupart des produits existants sont rééchantillonnés sur une grille de 25x25 km cependant un nouveau produit utilisant les mesures historiques de 1978 à 2017 (Brodzik *et al.*, 2018) avec une technique de reconstruction d’image pour former une nouvelle grille planétaire de traitement (Equal Area Scalable Earth, EASE Grid 2.0) offre maintenant une résolution spatiale allant jusqu’à 3.25 km pour 37 GHz et 6.5 km pour 19 GHz, deux fréquences couramment utilisées pour le suivi du couvert nival (Chang *et al.*, 1982; Kelly *et*

al., 2003). L'influence de la variabilité spatiale locale de l'épaisseur et de la densité de la neige pourrait avoir davantage d'impact sur l'estimation du ÉEN à une telle résolution. De plus, les prochaines missions satellites en développement motivées par une meilleure quantification du ÉEN par radar (King *et al.*, 2015, 2018; Rutter *et al.*, 2019) se concentrent sur des capteurs actifs, motivant davantage le besoin de quantifier la variabilité à l'échelle locale. Ceci motive donc la question de recherche suivante : peut-on utiliser des outils de télédétection pour quantifier et analyser à l'échelle locale le couvert nival et par conséquent, mieux comprendre les processus affectant sa variabilité spatio-temporelle dans le but d'améliorer les modèles de suivi du couvert de neige?

Comme mentionné plus haut, la neige en toundra arctique possède majoritairement deux couches. Ces deux couches ont des propriétés complètement différentes de densité et de taille de grain impliquant un ÉEN et une sensibilité micro-ondes propre à chacune. C'est une des raisons pour laquelle les premiers algorithmes d'estimation de l'ÉEN (Chang *et al.*, 1982; Kelly *et al.*, 2003) pouvaient avoir une erreur allant jusqu'à 100% aux hautes latitudes puisqu'il utilisait la différence de température de brillance (T_B) en polarisation horizontale entre les fréquences 19 et 37 GHz. Plus spécifiquement, la sensibilité micro-ondes au givre de profondeur est très élevée due à la taille de grain importante (forte diffusion de volume) par rapport à la contribution du signal pour les petits grains menant à une surestimation de l'ÉEN. Donc pour mieux estimer l'ÉEN en milieu subarctique/arctique, une nouvelle technique devait être utilisée (Derksen *et al.*, 2010) motivant ainsi les premières techniques d'inversion (Pulliainen et Hallikainen, 2001; Roy *et al.*, 2004). Ces techniques qui devait utiliser de modèles de transfert radiatifs micro-ondes (MTR) ont démontré une erreur significative fortement corrélée à la taille de grain motivant ainsi une amélioration en assimilant la taille de grain à l'aide de stations météorologiques (Pulliainen, 2006). Le produit GlobSnow-2, basé sur cette assimilation, offre des estimations de ÉEN pour l'hémisphère Nord avec une résolution de 25 km de 1978 à 2010 (Takala *et al.*, 2011). Plusieurs ont par la suite exploré le couplage d'un modèle physique de neige à un MTR pour l'inversion de mesures. Cette méthode offre l'avantage d'inverser un modèle multicouche et d'assimiler la taille de grain sans données in situ (Langlois *et al.*, 2012; Larue *et al.*, 2018; Toure *et al.*, 2011).

1.2.3 Erreur liée à la paramétrisation des modèles de transfert radiatif

L'ÉEN peut s'obtenir en inversant des mesures satellitaires à l'aide d'un MTR. Cependant, le manteau neigeux doit être considéré comme uniforme spatialement à l'intérieur des pixels sans considération de variabilité spatiale (Saberi *et al.*, 2020). Il est possible d'estimer la variation de la hauteur de neige à l'intérieur d'un pixel en assumant une distribution log normal de la neige (Clark *et al.*, 2011) pour des modèles hydriques et climatiques. À ce jour, il n'existe aucune étude de sensibilité sur l'influence de la variation intrapixel de la hauteur de neige et l'émission micro-ondes. Une étude se concentrant sur une méthode d'inversion bayésienne de mesures micro-ondes (Saberi, Kelly, Pan, *et al.*, 2020) propose l'utilisation de processus gaussien qui permettrait d'incorporer la variation de hauteur de neige pour améliorer ce genre d'inversion. Puisque la hauteur de neige est utilisée dans l'inversion de MTR et dans l'estimation finale de l'ÉEN, il est important de bien paramétriser cette variable et d'estimer si la variation à l'intérieur du pixel peut influencer la modélisation du transfert radiatif.

De plus, il est maintenant clair que la paramétrisation de la taille de grain influence l'erreur sur l'ÉEN. Selon l'article de Derksen *et al.* (2014) qui compare la neige subarctique et arctique, le ratio en hauteur de la couche du givre de profondeur (*depth hoar fraction* : DHF) servant de Proxi à la taille de grain compte pour la quasi-totalité de la différence entre les simulations et les données in-situ de radiomètres. De plus, aucun modèle multicouche actuellement disponible n'est en mesure de bien paramétriser la microstructure du manteau neigeux, notamment le caractère unique en conditions arctiques où le métamorphisme cinétique est très important menant à une couche de givre de profondeur épaisse en place dès le début de l'hiver (Davesne *et al.*, 2021; Gouttevin *et al.*, 2018). Le givre de profondeur en région Arctique peut atteindre des dimensions jusqu'à 20 fois la taille de grain de la plaque à vent (Figure 1-2). Une récente étude de Rutter *et al.*, (2019) en bande Ku mentionne qu'une sous-estimation de 20% sur la taille de grain (Specific Surface Area, SSA) du givre peut engendrer une erreur sur l'ÉEN jusqu'à 60%. De plus, on y tente de quantifier le ratio de givre de profondeur et la plaque à vent par rapport à l'épaisseur totale pour utiliser ces proportions afin d'améliorer l'ÉEN obtenu en bande Ku. En analysant 9000 profils verticaux venant d'imagerie proche infrarouge servant à identifier les différentes couches sur une tranchée de 5 à 10 m, le DHF indépendamment de la hauteur du manteau neigeux constituait en moyenne 30 % de l'épaisseur totale. Pour mesurer ces ratios, des puits de neige traditionnels ou des tranchées

de neige en suivant la méthode de Rutter *et al.*, (2014) ont été utilisés. Le DHF est une variable importante puisque le DHF augmente la diffusion du manteau neigeux arctique. Il est important de quantifier spatialement cette variable et son lien avec la hauteur totale du couvert nival.

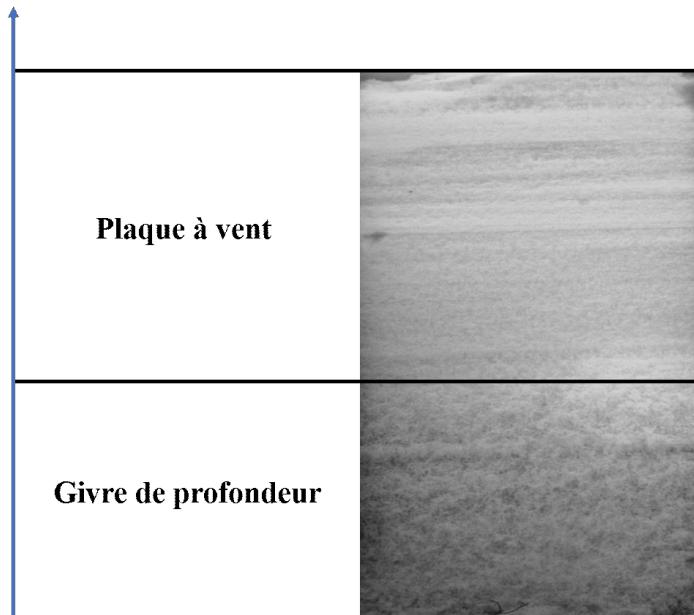


Figure 1-2: Manteau neigeux arctique typique composé de deux couches: la plaque à vent et le givre de profondeur. La taille des grains de givre de profondeur peut atteindre jusqu'à 20 fois celle des grains ronds de la plaque à vent.

L'influence de la végétation (type et hauteur) sur le DHF et l'épaisseur de neige a été déjà observée par plusieurs (Domine *et al.*, 2016; Gouttevin *et al.*, 2018; Sturm *et al.*, 2001) et doit être considérée pour l'analyse de ratio des différentes couches. Les arbustes créent de la rugosité au sol ce qui réduit la vitesse du vent de surface et favorise l'accumulation de neige et le développement de givre de profondeur jusqu'à leur hauteur (Gouttevin *et al.*, 2018). L'humidité du sol elle aussi influence le DHF (Davesne *et al.*, 2021) en favorisant le flux de vapeur en lien avec le métamorphisme du givre de profondeur. Ces ratios gouvernent presque à eux seuls la diffusion du manteau neigeux et motivent la question de recherche suivante : existe-t-il des relations qui gouvernent la variabilité spatiale de ces couches par rapport à l'épaisseur totale, le type de sol et la topographie qui permettrait de quantifier la variabilité intra pixel des produits micro-ondes en toundra arctique?

La contribution de l'émission du sol doit aussi être considérée comme source d'incertitudes bien qu'elle soit moins importante que celle due à la taille de grain (Roy *et al.*, 2016). Plusieurs modèles peuvent être utilisés pour ajouter la contribution du sol à celle de la neige. Cependant, beaucoup d'incertitudes demeurent quant aux propriétés géophysiques du sol gelé telles que la permittivité, l'humidité volumétrique et la rugosité de celui-ci. Des études comme Montpetit *et al.*, (2018) ont tenté d'estimer la permittivité et la rugosité avec des observations multiangles en minimisant l'erreur entre les simulations et les observations radiométriques. Les valeurs trouvées sont effectives et donc propres aux modèles utilisés et peuvent parfois différer de la quantité mesurée qui serait mesurée sur le terrain. Il serait donc important de tenter de valider ces valeurs en les mesurant directement. Certains instruments permettent de mesurer physiquement la rugosité de surface comme le profileur à aiguille (Trudel *et al.*, 2010), mais peuvent cependant devenir complexes à utiliser lors des campagnes terrain en plus d'inclure un biais sélectif de l'utilisateur qui choisit quelle orientation donner au profileur. Plus récemment les lasers terrestres (Turner *et al.*, 2014) ont permis des analyses 3D beaucoup plus complexe en produisant des nuages de point numériques à très haute résolution spatiale, mais ces appareils sont peu portatifs, sensibles au froid en plus d'avoir un coût prohibitif. De ce fait, depuis quelques années, la photogrammétrie traditionnelle jumelée à l'intelligence artificielle, connue comme l'algorithme *Structure-from-Motion* (SfM), rend possible la production de nuages de points 3D avec seulement une caméra digitale. Cette technique efficace permettrait donc de quantifier la rugosité de plusieurs types de sols dans les conditions difficiles de la toundra arctique et ce, à faible coût. Au final, ces méthodes permettent de mesurer plusieurs paramètres de rugosité comme l'écart type de la hauteur (σ_H) et la longueur de corrélation (l_c). Les MTRs du sol comme ceux inclus dans les modèles de neige comme *Dense Media Radiative Transfer* (DMRT) (Picard *et al.*, 2013; Tsang, Chen, *et al.*, 2000) et *Microwave Emission Multi Layer Snowpack* (MEMLS) (Wiesmann et Mätzler, 1999) utilisent le modèle de sol semi-empirique de Wegmüller et Mätzler, (1999) qui caractérise la réflectivité et l'interface du sol seulement avec un seul paramètre (σ_h). Récemment, un nouveau modèle nommé *Snow Microwave Radiative Transfer* (SMRT) (Picard *et al.*, 2018), permet l'utilisation de modèles physiques comme *l'Integral Equation Model* (IEM) (Fung, 1994) et le régime de Géométrie Optique (Kong et Tsang, 2001) pour représenter la rugosité du sol en utilisant un deuxième paramètre : la longueur de corrélation. L'utilisation de ces différents modèles et paramètres avec

SMRT amène à la question suivante : les mesures de rugosité obtenues à l'aide de l'algorithme SfM pourraient-elles être utilisées comme intrants pour améliorer les modélisations de transfert radiatif du sol et quelle est l'impact la variabilité spatiale de la rugosité sur les modélisations?

1.3 Objectifs

L'objectif global de cette thèse est donc d'analyser les propriétés géophysiques du couvert nival et du sol arctique à l'échelle locale en utilisant des outils de télédétection afin d'améliorer la compréhension des processus locaux affectant l'estimation du ÉEN à l'échelle locale et globale à partir de PMW. Les questions de recherches soulevées dans la section précédente motivent les objectifs spécifiques suivants :

- 1) Prédire à hautes résolutions la hauteur de neige en Arctique avec l'algorithme *Random Forest* et approfondir les processus gouvernant la hauteur de neige.
- 2) Quantifier la variabilité spatiale du manteau neigeux (hauteur et le DHF) pour améliorer les simulations en transfert radiatif du manteau neigeux arctique à l'échelle satellitaire.
- 3) Améliorer les simulations en transfert radiatif micro-ondes d'un sol gelé arctique en micro-ondes passives à l'aide de mesures de rugosité de modèle en 3D (Algorithme SfM).

Les trois objectifs constituent une série d'investigations pour tenter d'améliorer le suivi de la neige arctique en s'attardant sur des processus locaux (objectif 1), mais qui ont aussi pour but d'aider le suivi globalement (objectif 2 et 3). Les objectifs 2 et 3 visent à améliorer l'estimation de l'ÉEN satellitaire en se concentrant sur l'amélioration des simulations de la neige arctique en transfert radiatif micro-ondes. Aucune mesure ni inversion de l'ÉEN n'ont été réalisée, ces objectifs se concentrent sur la paramétrisation de la neige et du sol dans le transfert radiatif afin de minimiser la différence avec des observations de T_B .

1.3.1 Canevas de la thèse

Le prochain chapitre porte sur le bagage théorique nécessaire à la compréhension de la thèse et est complémentaire aux articles présentés dans la thèse. Les sous-sections du cadre théorique suivent l'ordre des objectifs spécifiques mentionnés ci-haut. Ensuite, les prochains chapitres présentent trois articles qui répondent aux objectifs spécifiques. Le premier article (chapitre 4) se concentre

sur la prédiction du manteau neigeux localement (1 - 10 km) pour les besoins où la télédétection micro-ondes ne peut être utilisé dues à la résolution spatiale trop grossière. Ensuite les chapitres 5 et 6 portent sur l'amélioration de la paramétrisation de la neige et du sol arctique pour la télédétection PMW à l'échelle globale (> 10 km).

2 Cadre Théorique

Cette section introduit les concepts nécessaires à la compréhension de la thèse suivant l'ordre des objectifs spécifiques. La prédiction de hauteur de neige localement à l'aide d'algorithme RF est introduite en expliquant le concept général des forêts d'arbres décisionnels et les deux paramètres topographiques principaux utilisés pour la prédiction de la hauteur de neige. Ensuite, les dernières sous-sections se concentrent principalement sur le transfert radiatif de la neige. En ordre, la définition des concepts de base du transfert radiatif de la neige et le modèle SMRT. Finalement, le transfert radiatif du sol gelé en plus de la permittivité et rugosité du sol sont approfondis.

2.1 Forêt d'arbres décisionnels

L'Algorithme de Forêt d'arbres décisionnels aléatoire (tirée de l'anglais *Random Forest* ou RF) est un algorithme d'apprentissage par machine le plus versatile, facile d'utilisation procurant des résultats de qualité. RF permet de faire des prédictions soit par une régression ou classification grâce à des variables explicatives et se base sur les arbres décisionnels pour faire des prédictions en construisant une « forêt » (i.e. multitude d'arbres décisionnels) afin d'obtenir une prédiction finale (Breiman, 2001). Les arbres sont joints pour obtenir des prédictions constantes et précises en moyennant les prédictions de tous les arbres de la forêt (Figure 2-1). L'algorithme est entraîné sur des sous-ensembles de données légèrement modifiées faisant appel au « *bagging* » ou « *bootstrap* » qui est une méthode statistique répliquant le jeu de données de façon aléatoire selon une technique d'échantillonnage. Ce rééchantillonnage consiste à créer de nouveaux échantillons avec un tirage par remise de l'échantillon initial. Bien que RF soit simple d'utilisation avec un nombre limité d'hyperparamètre en comparaison à d'autres méthodes d'apprentissage machine, quelques paramètres permettent d'ajuster les prédictions. Le paramètre le plus important est le nombre d'estimateurs qui est le nombre d'arbres décisionnels que l'algorithme construit avant de

prendre la moyenne des prédictions pour un cas de régression. Un autre paramètre est le nombre maximal de « *feature* » ou poids par arbre décisionnel avant de séparer un nœud. Plusieurs autres paramètres peuvent être aussi optimisés, mais l'algorithme réputé pour sa simplicité offre d'excellentes prédictions par défaut.

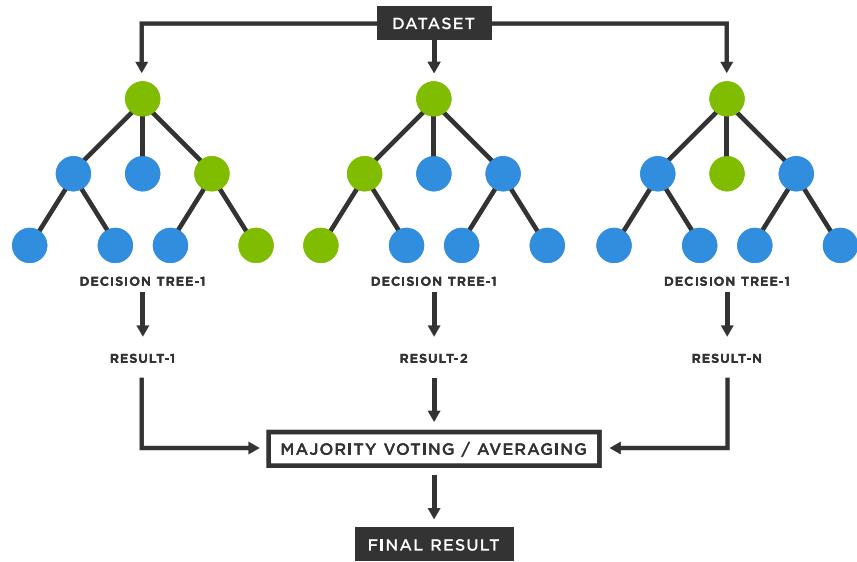


Figure 2-1 : Représentation de l'algorithme RF et des multiples arbres décisionnels.

Cet algorithme sera utilisé en régression pour prédire la hauteur de neige en utilisant des paramètres topographiques calculés à partir de MNT. Il est possible de créer un jeu de données de validation et d'entraînement suivant un certain ratio avec des mesures de hauteurs de neige mesurées sur le terrain avec les paramètres topographiques correspondants. Bien que certains paramètres soient simples comme la pente et l'élévation, deux paramètres plus complexes sont définis dans la prochaine section.

2.2 Paramètres topographiques (TPI et S_x)

Le paramètre TPI (*Topographic Position Index*) (Weiss, 2000) est un paramètre souvent utilisé pour décrire le paysage et peut être utilisé avec la pente afin de classifier ce dernier (vallée, crête, plaine, etc.). Il permet de quantifier l'altitude d'un pixel par rapport au pixel voisin dans un rayon déterminé par l'utilisateur. L'altitude du pixel est alors comparée à la moyenne des pixels voisins

à l'intérieur du rayon où un $TPI > 0$ indique que le pixel est plus bas que la moyenne (vallée) alors qu'un $TPI < 0$ indique une crête.

Le paramètre S_x (Winstral *et al.*, 2002) est un indice de redistribution de la neige qui définit les pixels par leur capacité de protection (de l'épaisseur de neige) et érosion selon la direction du vent dans un rayon donné. La valeur de cet indice, le paramètre S_x , est défini par un vecteur émanant du pixel d'intérêt représenté à la Figure 2-2.

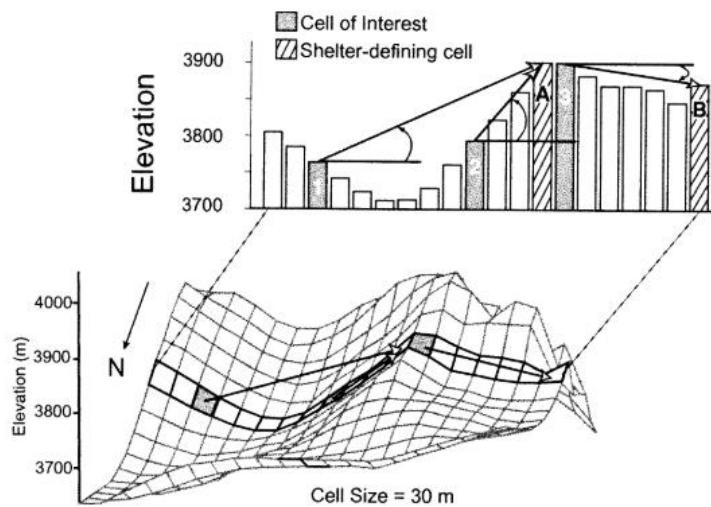


Figure 2-2 : Facteur S_x de protection/érosion d'un pixel selon la topographie et la direction du vent.
(Tiré de Winstral *et al.* 2002)

Une augmentation positive du facteur S_x indique un possible obstacle naturel produisant un degré de protection et réduction de la vitesse du vent. À l'inverse, lorsque la variabilité de l'indice est négative, cela indique une exposition plus importante et par conséquent, une augmentation de la vitesse du vent ou encore une érosion favorisée. Le pixel d'intérêt est aussi défini par un arc de cercle formé de deux azimuts de rayon de recherche (d_{max}) de taille définie par l'utilisateur, autour de la direction du vent choisi. Donc si la direction du vent dominant est 260° et une taille de 60° , alors l'azimut $A_1 = 230^\circ$ et $A_2 = 290^\circ$. La valeur de S_x est ensuite calculée pour chaque azimut en commençant par A_1 , par incrément de 5° ou 10° jusqu'à A_2 avec l'Équation 2.1 pour ensuite calculer la moyenne de S_x de tous les azimuts (Équation 2.2).

$$S_{x_{a,dmax}}(x_i, y_i) = \max \left[\tan \left(\frac{ELEV(x_v, y_v) - ELEV(x_i, y_i)}{[(x_v - x_i)^2 + (y_v - y_i)^2]^{0.5}} \right) \right] \quad (2.1)$$

$$\overline{S_x}_{dmax}(x_i, y_i) | \frac{A_2}{A_1} = \frac{1}{n_v} \sum_{A_1}^{A_2} S_{x_{A,dmax}}(x_i, y_i) \quad (2.2)$$

2.3 Représentation de la variabilité de la neige

En modélisation climatique, il est commun d'utiliser le coefficient de variation de la neige (CV_{sd}) (Liston, 2004; Nitta *et al.*, 2014) pour représenter la variabilité de la hauteur de neige intrapixel dans un modèle global de surface (Figure 2-3). Il est possible de représenter une distribution de neige à l'intérieur d'un pixel avec deux paramètres : la moyenne (μ_{sd}) et le coefficient de variation (CV_{sd}). Ce paramètre est en fait l'écart type normalisé ($CV_{sd} = \sigma_{sd}/\mu_{sd}$) et permet de quantifier la largeur d'une distribution de hauteur de neige. Une valeur élevée ($CV_{sd} = 0.7-1$) indique des zones faibles combinées à des zones fortes en accumulation en raison d'une topographie favorisant le transport de neige des zones faibles vers les zones fortes (Parr *et al.*, 2020). Un CV_{sd} faible (< 0.4) indique des valeurs regroupées autour de la moyenne avec peu de valeurs extrêmes. Le paramètre CV_{sd} varie globalement (Figure 2-3, Nitta *et al.*, 2014) en fonction du type de neige et du climat, mais varie aussi localement dues à la topographie et la végétation. L'utilisation de ce paramètre avec des simulations en transfert radiatif n'a jamais été utilisé et sera exploré dans le chapitre 4. De plus, l'impact de la hauteur de neige sur les propriétés de microstructure (DHF) sera évalué et incorporé aux simulations pour ajouter une variation intrapixel de la hauteur et du DHF.

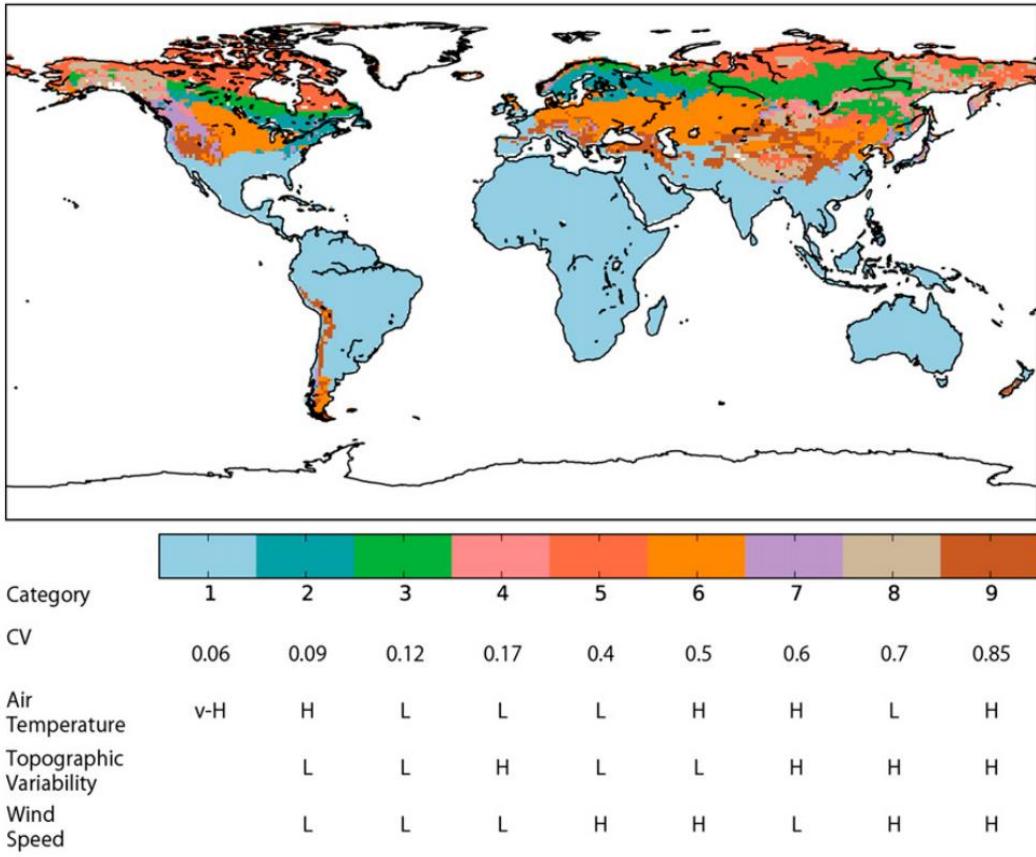


Figure 2-3: Carte globale des catégories du coefficient de variation (CV) pour les distributions de hauteur de neige intrapixel. La température de l'air, la topographie et la vitesse du vent ont été considérées pour catégoriser les régions; v-H, H et L représente très élevé, élevé et faible. (Tirée de Nitta *et al.* 2014)

2.4 Bases du transfert radiatif satellitaire

Pour obtenir un ÉEN par mesure de micro-ondes passives, la température de brillance (T_B) du haut de l'atmosphère (T_{BTOA}) mesurée par le satellite doit être simulée pour ensuite inverser cette simulation afin d'obtenir l'ÉEN. Des MTRs permettent de simuler la mesure du haut de l'atmosphère (T_{BTOA}). Cette mesure est en fait le signal de l'émission planétaire composé d'une multitude de composantes représentées par l'Équation 2.3 pour chacune des fréquences et polarisations,

$$T_{BTOA} = (T_{Bsurf} + T_{Batm\downarrow} - r_{surf}) \gamma_{atm} + T_{Batm\uparrow} \quad (2.3)$$

où $T_B \text{surf}$ est la contribution de la surface, $T_B \text{atm}\downarrow - r - \text{surf}$ est la contribution atmosphérique descendante réfléchie de la surface assumé à 100%, γ_{atm} est la transmittance de l'atmosphère et $T_B \text{atm}\uparrow$ est la contribution atmosphérique ascendante. À noter que nous faisons abstraction ici de la contribution cosmique, négligeable dans l'inversion de l'ÉEN. La Figure 2-4 représente les différentes composantes du signal micro-ondes (Équation 2.3) mesurées par le satellite. Le modèle SMRT permet de simuler la contribution de la surface ($T_B \text{surf}$) constituée du signal provenant de la neige et du sol.

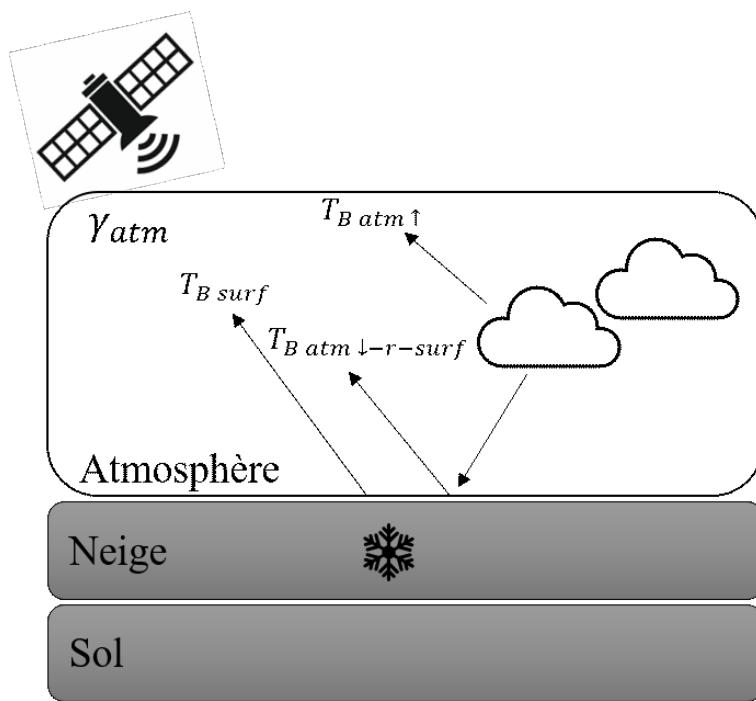


Figure 2-4: Diagramme des différentes composantes micro-ondes du signal mesuré par le satellite.

Dans les chapitres 5 et 6, les mesures radiométriques qui ont été utilisées nécessite une correction atmosphérique. Ces corrections permettent de tenir compte de tous les facteurs atmosphériques ($T_B \text{atm}\downarrow$, γ_{atm} , $T_B \text{atm}\uparrow$) dans l'Équation 2.3. Un capteur satellitaire est représenté par le $T_B \text{TOA}$. La correction atmosphérique permet d'obtenir le $T_B \text{surf}$ en estimant les facteurs atmosphériques ($T_B \text{atm}\downarrow$, γ_{atm} , $T_B \text{atm}\uparrow$) et utiliser l'Équation 2.3 pour isoler $T_B \text{surf}$. Pour la validation terrain avec

des radiomètres au sol (chapitre 6), le T_B mesurée par le radiomètre au sol est représenté seulement par $T_{B \text{ surf}}$ et $T_{B \text{ atm}\downarrow - r - \text{surf}}$ dans la parenthèse de l'équation 2.3.

Pour estimer les paramètres atmosphériques ($T_{B \text{ atm}\downarrow}$, γ_{atm} , $T_{B \text{ atm}\uparrow}$), une technique (Roy *et al.*, 2012; Vargel *et al.*, 2020) basée sur le modèle atmosphérique *Millimeter-wave Propagation Model* (MPM) (Liebe, 1989) permet d'utiliser des relations linéaires entre la vapeur d'eau précipitable (pwat) et les contributions atmosphériques ($T_{B \text{ atm}\downarrow}$, γ_{atm} , $T_{B \text{ atm}\uparrow}$), avec intrant de température et humidité de l'air afin d'estimer $T_{B \text{ atm}\downarrow}$, γ_{atm} , $T_{B \text{ atm}\uparrow}$. Les coefficients des relations linéaires pour chacune des variables est présenté dans le Tableau 2-1 provenant de Vargel *et al.* (2020).

Tableau 2-1: Résumé des paramètres (y) par fréquence pour la relation linéaire $y = a \cdot \text{pwat} + b$ (Vargel *et al.*, 2020).

Parameters	Frequency (GHz)			
	11	19	37	89
$T_{B \text{ atm}\uparrow}$	a	0.108	1.029	0.627
	b	7.234	8.721	25.040
$T_{B \text{ atm}\downarrow}$	a	0.097	0.977	0.608
	b	4.045	5.189	20.656
γ_{atm}	a	0.000	-0.003	-0.002
	b	0.979	0.977	0.913
				0.818

2.5 Modèle Snow Microwave Radiative Transfer (SMRT)

Le modèle SMRT est un modèle multicouche de transfert radiatif micro-ondes offrant trois modes : passif, actif et altimétrie. Il a été conçu principalement pour résoudre les équations de transfert radiatif comme avec les modèles existants DMRT et MEMLS (Tsang, Chen, *et al.*, 2000; Wiesmann et Mätzler, 1999), mais aussi pour permettre la comparaison des différentes représentations de microstructure et de modèles électromagnétiques. Ces modèles résolvent les équations de transfert radiatif (Équation 2.4) pour calculer la propagation de l'énergie à travers les différentes couches (Figure 2-5).

$$\begin{aligned} \mu \frac{\partial I(\mu, \phi, z)}{\partial z} = & -\kappa_e(\mu, \phi, z) I(\mu, \phi, z) \\ & + \frac{1}{4\pi} \iint_{4\pi} P(\mu, \phi; \mu', \phi', z) I(\mu', \phi', z) d\Omega' + \kappa_a(\mu, z) \alpha T(z) \end{aligned} \quad (2.4)$$

Plus spécifiquement, les modèles de microstructure des couches de neige permettent le calcul des coefficients d'extinction ($\kappa_e = \kappa_s + \kappa_a$) utilisés dans les équations de transfert radiatif. La dernière couche, substrat, défini le milieu sous la neige soit du sol gelé en arctique ou de la glace de mer par exemple. Les modèles électromagnétiques (*Dense Media Radiative Transfer* ou *Improved Born Approximation* offert dans SMRT) définissent certaines variables (κ_a, κ_s et P) et hypothèses nécessaires au calcul de la propagation de l'énergie radiative à l'intérieur du médium (neige). Chaque couche de neige (l) est définie par la permittivité (ϵ), les coefficients de diffusion et absorption (κ_s, κ_a), la fonction de phase (P) et les conditions initiales et limites. Lorsque les équations différentielles du transfert radiatif sont définies pour chaque couches et substrats, SMRT offre une méthode de résolution numérique (DORT) à 32 flux pour obtenir l'émission finale ($I(\theta, \phi)$) de la surface. Les directions sont définies par l'angle azimutal ϕ , le cosinus de l'angle d'incidence ($\mu = \cos\theta$) et l'angle solide Ω . La température du médium (neige) est définie par $T(z)$ en fonction de la hauteur.

Cette équation est valide pour les deux modes : actif et passif. Pour obtenir la température de brillance (T_B) en polarisation p , on utilise l'approximation de Rayleigh-Jeans pour obtenir l'intensité spécifique réduite $I_p = \alpha T_{B,p}$ avec $\alpha = 2\nu^2 k / c_0^2$ où κ , c_0 et ν sont la constante de Boltzmann, la vitesse de la lumière dans le vide et la fréquence de l'onde.

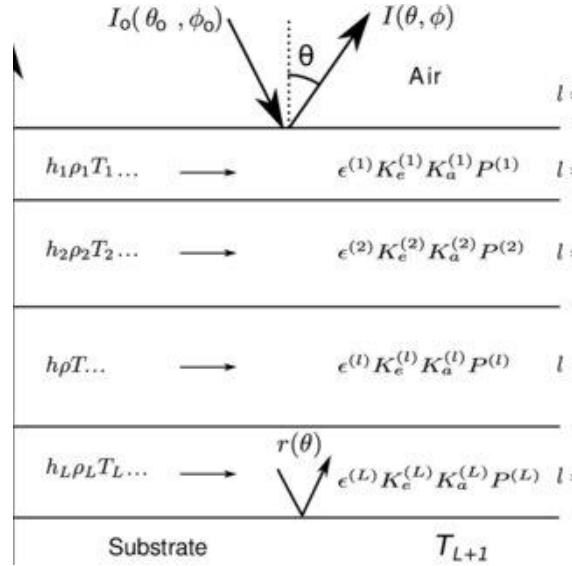


Figure 2-5: Représentation des variables de l'équation différentielle du transfert radiatif (Équation 4.4). (Tirée de Picard *et al.* 2018)

Le modèle SMRT permet donc de simuler la température de brillance qui serait mesurée par un capteur passif (radiomètre). Pour ce faire, on doit spécifier plusieurs intrants nécessaires à la simulation. Premièrement, le type de capteurs (actif, passif ou altimétrie) doit être spécifier en plus de la fréquence d'utilisation. Ensuite, le manteau neigeux est défini par couche où plusieurs variables doivent être définies; la température, la densité de la neige et un paramètre de microstructure issue de mesures terrain de la surface spécifique des grains de neige (SSA) (Gallet *et al.*, 2009). Différents termes de microstructure peuvent être utilisés dépendamment du modèle théorique comme la théorie DMRT qui assume des diffuseurs de glace sphérique et un terme de cohésion de sphère appelé « stickiness » (Tsang, Chen, *et al.*, 2000). Les différentes représentations de microstructure de la neige (Picard *et al.*, 2018) ainsi que les instruments pour la mesurer (Krol et Löwe, 2016; Montpetit *et al.*, 2012; Proksch *et al.*, 2015) représentent un enjeu de recherche très actuel (Sandells *et al.*, 2021; Vargel *et al.*, 2020). Dans cette thèse, le modèle de microstructure IBA exponentielle sera utilisé avec le paramètre de longueur de corrélation exponentielle estimé par la formule de Debye (Équation 2.5) (L_{Debye}). Ce modèle utilise une fonction d'autocorrélation (ACF) exponentielle pour représenter le médium air/glace. Cette ACF définit en quelque sorte la représentation dans l'espace de notre diffuseur, les cristaux de glace qui constituent les grains de neige. Pour estimer la longueur de corrélation, la formule de Debye offre une approximation issue de mesure de terrain. Une mesure terrain de densité ainsi que de la SSA

est nécessaire pour obtenir la longueur de corrélation. Les mesures de densité (ρ_{neige}) sont obtenus de plusieurs méthodes équivalentes comme par exemple des couteaux à densité (Proksch *et al.*, 2016) et les mesures de SSA à l'aide de sphère laser intégrante qui mesure la réflectivité d'un échantillon de neige à 1310 nm (Montpetit *et al.*, 2012; Gallet *et al.*, 2009). Il est aussi possible d'utiliser un facteur d'ajustement micro-ondes à la formule de Debye pour l'estimation de la longueur de corrélation (Vargel *et al.*, 2021).

$$L_{Debye} = 4 \frac{\left(1 - \frac{\rho_{neige}}{\rho_{glace}}\right)}{\rho_{glace} SSA} \quad (2.5)$$

Dans la Figure 2-6, la forte sensibilité du signal à 37 GHz due à la hauteur de neige et au ratio de givre de profondeur (DHF) est illustrée à l'aide de simulation d'un manteau neigeux typique de l'arctique avec SMRT. Cette sensibilité permet donc d'utiliser les PMW pour estimer l'ÉEN. La hauteur de neige est estimée à partir d'une inversion de modèle de transfert radiatif et de mesures de PMW satellitaire à 25 km de résolution spatiale. Cependant, dans le processus d'inversion, le manteau neigeux est considéré comme uniforme alors que beaucoup de variabilité au niveau de la hauteur et du DHF de la neige arctique est observée au sol (Derksen *et al.*, 2012; King *et al.*, 2018; Rutter *et al.*, 2014; Saberi, Kelly, Pan, *et al.*, 2020). La Figure 2-6 illustre l'impact de la hauteur et du DHF sur le signal à 37 GHz au T_B . Les grains de neige agissent comme diffuseur du signal micro-ondes, de sorte que plus le couvert de neige augmente en épaisseur (augmentation du nombre de diffuseurs), plus le signal est atténué. Le DHF affecte aussi le signal similairement puisque les grains de givre de profondeur (DHF) diffusent davantage que les grains ronds de la plaque à vent donc un DHF élevé diminue la T_B mesurée par le capteur. Il serait potentiellement intéressant d'estimer sur les simulations l'ajout d'une variabilité intrapixel de la neige (hauteur et DHF) avec un produit de PMW satellitaire.

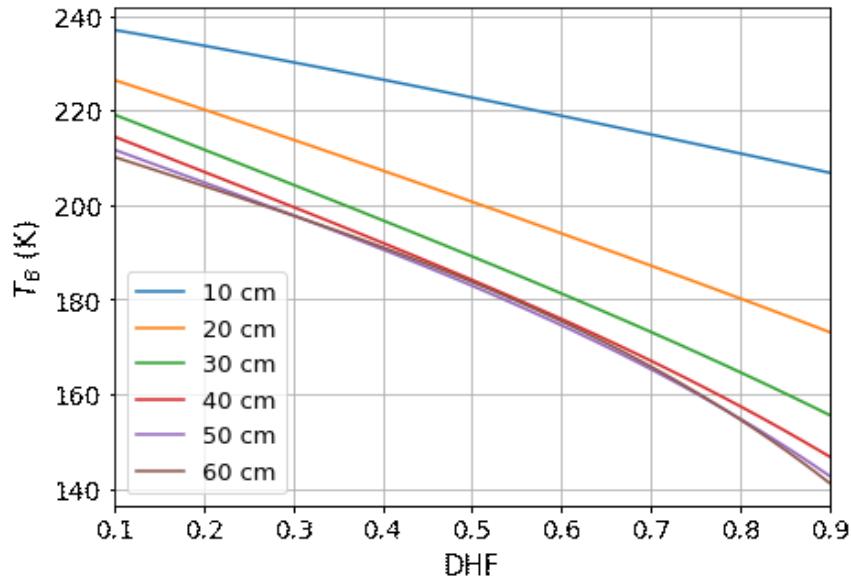


Figure 2-6: Sensibilité de l'émission du manteau neigeux arctique (2 couches) à la hauteur totale du manteau (courbe) et au ratio de givre de profondeur (DHF). Intron aux simulations pour le givre de profondeur (densité : 266 kg/m³, SSA : 11 m²/kg, température : 250 K) et la plaque à vent (densité : 355 kg/m³, SSA : 11 m²/kg, température : 261 K).

2.6 Base du transfert radiatif du sol

En plus de la neige, le substrat doit aussi être défini dans les modèles de transfert radiatif puisqu'il émet et reflète dans le domaine micro-ondes. Cette couche représente le médium sous les couches de neige. Il est possible de créer dans SMRT un médium similaire au sol arctique possédant une certaine rugosité et permittivité. Dans cette section, la contribution du sol en transfert radiatif est définie plus en détails.

L'émissivité d'une surface peut être calculée en utilisant le concept de réciprocité et de conservation d'énergie avec la réflectivité du sol (équation 2.6) (Loi de Kirchoff).

$$e_p = 1 - \Gamma_p \quad (2.6)$$

La réflectivité (Γ_p) d'une surface lisse est calculé avec les équations de Fresnel (Tsang, Kong, et al., 2000) et la permittivité du sol. Cependant, les surfaces naturelles ont une rugosité qui peut

influencer les ondes électromagnétiques si l'échelle de rugosité est comparable à la longueur d'onde. Dans le domaine micro-ondes, la rugosité du sol (0.1 - 10 cm) doit être prise en compte si on utilise des longueurs d'onde sensibles à la neige; 19 GHz, $\lambda \approx 1.6$ cm et 37 GHz; $\lambda \approx 0.8$ cm. Différents modèles permettent de simuler l'émission d'une surface rugueuse en se basant sur les équations de Fresnel.

Trois modèles de réflectivité peuvent être utilisés dans SMRT. Le premier modèle de réflectivité du sol : QNH (Wang *et al.*, 1983; Wang et Choudhury, 1981) est semi-empirique et utilise les coefficients de Fresnel avec un ratio de polarisation et un coefficient d'atténuation pour modéliser la réflectivité d'une surface de rugosité aléatoire Γ_p (Équation 2.7-2.8) pour les polarisations horizontales et verticales. Plusieurs études ont tenté d'optimiser les paramètres du modèle QNH (Q_R , N_H , N_V , H_R , a_1 , a_2 et a_3) de leurs valeurs originales tout en proposant des formulations différentes pour H_R . Montpetit *et al.*, (2015) ont trouvé des valeurs (a_1 , a_2 et a_3) (Équation 2.9) qui élargissaient le domaine fréquentiel de 1-90 GHz pour les fréquences normalement utilisées en étude de la neige.

$$\Gamma_{H_{QNH}} = [(1 - Q_R)\Gamma_H^{Fresnel}(\theta, \varepsilon) + Q_R\Gamma_V^{Fresnel}(\theta, \varepsilon)]e^{-H_R \cos^{N_H}(\theta)} \quad (2.7)$$

$$\Gamma_{V_{QNH}} = [(1 - Q_R)\Gamma_V^{Fresnel}(\theta, \varepsilon) + Q_R\Gamma_H^{Fresnel}(\theta, \varepsilon)]e^{-H_R \cos^{N_V}(\theta)} \quad (2.8)$$

$$H_R = \left(\frac{a_1 \sigma_H}{a_2 \sigma_H + a_3} \right)^6 \quad (2.9)$$

Le modèle développé par (Wegmüller et Mätzler, 1999) (Weg99) est également semi-empirique et visait à élargir le domaine fréquentiel à 1-90 GHz puisque QNH avait été développé seulement pour la bande L à l'époque. L'idée était de joindre la simplicité du modèle QNH avec des fondements plus théoriques d'une paramétrisation (Mo et Schmugge, 1987) basée sur l'approximation de Kirchhoff. Le modèle utilise aussi les coefficients de Fresnel, un ratio de polarisation (β_f), représenté par Q_R dans le modèle QNH, mais un facteur d'atténuation différent en fonction du nombre d'onde (k), l'écart type de la hauteur de la surface (σ_H) et l'angle d'incidence (θ). La réflectivité de surface en polarisation horizontale est décrite à l'Équation 2.10

et la réflectivité en polarisation verticale décrite à l'Équation 2.11 est fonction de la réflectivité en polarisation horizontale.

$$\Gamma_{H_{Weg}} = \Gamma_H^{Fresnel}(\theta, \varepsilon) e^{-k\sigma^{\sqrt{0.1\cos\theta}}} \quad (2.10)$$

$$\Gamma_{V_{Weg}} = \Gamma_H \cos\theta^{\beta_f} \quad (2.11)$$

La solution analytique de l'émissivité en polarisation q d'une surface rugueuse peut se résoudre en intégrant les coefficients bistatiques $\gamma_{P\alpha}$ en polarisation p de la solution de géométrie optique sur une demi-sphère (Équation 2.12) (Tsang, Kong, *et al.*, 2000). La surface rugueuse aléatoire est décrite par une fonction d'autocorrélation de type gaussienne en fonction de la pente moyenne au carré définie par l'écart type de la hauteur et la longueur de corrélation ($m = 2\sigma_h^2/l_c^2$). Les coefficients bistatiques de la solution de géométrie optique sont définis à l'Équation 2.13 (Kong et Tsang, 2001) avec comme conditions $k\sigma_h \gg 1$ et $kl_c \gg 1$. Pour plus d'information sur la définition des vecteurs $\hat{k}_i, \hat{k}_s, k_d, k_{dz}, k_{dx}, k_{dy}$ et $f_{P\alpha}$ se référer à (Kong et Tsang, 2001).

$$e_{P_{Geo}}(\theta_i, \phi_i) = 1 - \Gamma_Q = 1 - \frac{1}{4\pi} \sum_{\alpha=p,q} \int_0^{\frac{\pi}{2}} d\theta \sin\theta \int_0^{2\pi} d\phi \gamma_{P\alpha}(\theta, \phi, \theta_i, \phi_i) \quad (2.12)$$

$$\gamma_{P\alpha_{Geo}}(\hat{k}_i, \hat{k}_s) = \frac{|k_d|^4}{\cos\theta_i |\hat{k}_i \times \hat{k}_s|^4 k_{dz}^4 2m} e^{-\frac{k_{dx}^2 + k_{dy}^2}{2k_{dz}^2 m}} f_{P\alpha} \quad (2.13)$$

La Figure 2-7 illustre l'influence de la rugosité du sol ainsi que le choix du modèle utilisé sur la simulation de la température de brillance. Ces trois différents modèles: QNH, Weg99 et géométrie optique, sont définis plus bas. La rugosité influence positivement l'émission du sol en augmentant la surface de contact ce qui augmente l'émission (ou réduit la réflexion). Les différents modèles, semi-empiriques (QNH et Weg99) ou théoriques (Géo Optique), influencent l'émission différemment (Figure 2-7). Il serait donc intéressant d'investiguer en détail quel modèle est le plus adapté pour les mesures en arctique du sol gelé.

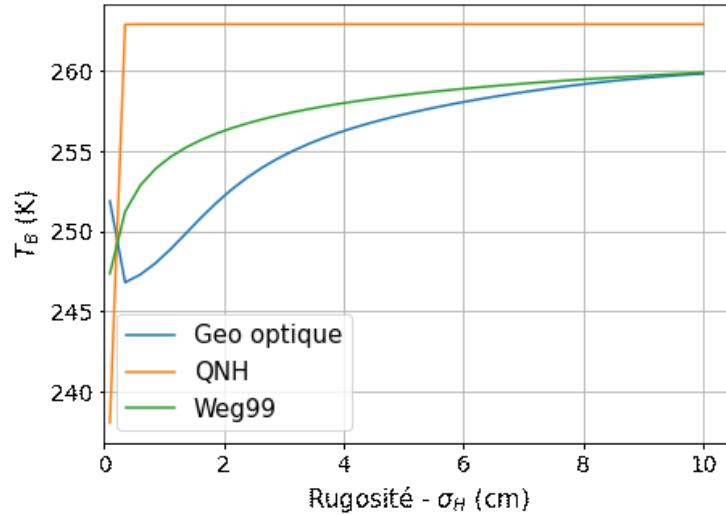


Figure 2-7: Effet sur la température de brillance (T_B) de la rugosité (σ_H) pour trois différents modèles de réflectivité (QNH, Weg99 et Géo optique). Permittivité du sol ($3 + 0.1i$); température du sol (263 K); $T_B \text{ atm}^{-1}$ (10 K); angle d'incidence (55 °); polarisation (verticale).

2.6.1 Permittivité du sol

Le calcul de l'émission d'une surface nécessite de connaître la permittivité électrique du sol. Cette variable peut être mesurée ou estimée à l'aide d'un modèle et représente la réponse d'un milieu à un champ électrique. La permittivité du sol est dépendante de la fréquence, de l'humidité, de la température et varie selon le milieu ou l'état. Pour le sol avec un certain contenu en eau, la permittivité de la glace et de l'eau liquide est très différente ce qui permet notamment de détecter les cycles de gel-dégel du sol (Mavrovic *et al.*, 2021). Dans un contexte de télédétection nivale, la permittivité du sol est souvent estimée à l'aide d'un modèle soit Zhang *et al.* (2010) ou Mironov *et al.* (2015) puisqu'il permet de simuler dans le domaine micro-ondes. Le modèle de Zhang est un modèle semi-empirique pour estimer la permittivité micro-ondes à partir de paramètres physiques du sol (Équation 2.14). Il est basé sur un modèle de mixage diélectrique d'un mélange composé de sol, d'air, d'eau liquide et de glace :

$$\epsilon^{\alpha_z} = 1 + \frac{\rho_b}{\rho_s} (\epsilon_s'^{\alpha_z} - 1) + f_w^\beta \epsilon_w^{\alpha_z} - f_w + f_i \epsilon_i^{\alpha_z} - f_i \quad (2.14)$$

Où la ε est la permittivité du mélange de sol, α_z est une constante optimisée par (Zhang *et al.*, 2003), f est la fraction de chaque composante avec comme indices s : sol, i : glace, w : eau. En plus de spécifier la permittivité de la glace (ε_i) et de l'eau (ε_w) qui varie selon la fréquence, la densité apparente (ρ_b) et spécifique (ρ_s) doivent aussi être spécifiés. Le paramètre β dépend de la composition du sol (%argile, %limon et % sable). Ce modèle nécessite un grand nombre de paramètres qui doivent être mesurés ce qui peut devenir compliqué lors d'une inversion du couvert de neige. De plus, ces modèles (Mironov *et al.*, 2015; Zhang *et al.*, 2010) se concentrent surtout sur le domaine fréquentiel en bande L (1.4 GHz) pour le suivi des sols alors que le suivi de la neige opère à des fréquences plus élevées (19 et 37 GHz). Dans cette thèse, le modèle de Zhang *et al.* (2010) sera utilisé dans le chapitre 6 comme base de l'optimisation pour estimer la permittivité du sol gelé à l'aide de mesures radiométriques (19 et 37 GHz). Cette optimisation sera faite à l'aide de mesure de rugosité du sol obtenu à l'aide de photogrammétrie terrestre et d'un nuage de point 3D. La permittivité ainsi que la rugosité du sol sont les deux paramètres nécessaires pour simuler le transfert radiatif du sol en contexte de télédétection micro-ondes du couvert de neige.

2.6.2 Rugosité du sol

Les surfaces naturelles possèdent toutes une rugosité qui est en fait une déviation répétitive ou aléatoire en trois dimensions d'une surface formant la topographie. La rugosité en contexte de télédétection micro-ondes affecte l'émission de la surface. Plus une surface est rugueuse, plus l'émission est grande puisque la quantité d'émetteurs à la surface est augmentée. Plusieurs paramètres permettent de quantifier la rugosité d'une surface. Chaque paramètre possède une information spécifique (global, local, fréquentielle ...) de la surface et il est très difficile de représenter la totalité de la rugosité avec seulement un paramètre. Le paramètre le plus utilisé en télédétection micro-ondes est l'écart type de la hauteur, σ_H ou R_a dans la Figure 2-8. Ce paramètre global représente la hauteur moyenne de la surface par rapport au plan central (Équation 2.15).

$$\sigma_H = \sqrt{\frac{1}{n} \sum_{i=1}^n z_i^2} \quad (2.15)$$

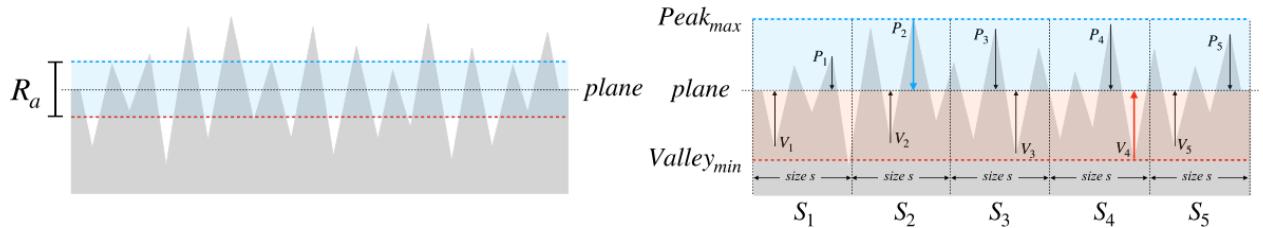


Figure 2-8: Profile de rugosité d'une surface, le paramètre R_a mesure la rugosité moyenne de la surface tandis que d'autres paramètres, plus locaux, évaluent la hauteur moyenne entre les crêtes et vallées principales. (Tirée de Tonietto *et al.*, 2019)

Certains paramètres permettent aussi d'analyser localement les déviations de la hauteur de la surface. La surface est séparée en sous-section ce qui permet d'identifier les crêtes et vallées (Figure 2-8). Une multitude de paramètres comme la hauteur moyenne de crêtes, la distance moyenne crêtes-vallée et plusieurs autres peuvent être calculés, voir Santos et Júlio (2013). Tous ces paramètres, y compris le σ_H , décrivent l'amplitude de la hauteur de la surface. Il est également possible et nécessaire d'analyser comment ces amplitudes varient dans l'espace. Pour ce faire, d'autres paramètres sont calculés comme la longueur de corrélation et la dimension fractale. Ces paramètres nécessitent certaines assumptions sur la fonction d'autocorrélation, mais de façon générale, ils permettent de quantifier comment l'amplitude est corrélée par rapport à une distance h entre une paire de points. Si l'amplitude s'exprime dans l'axe z par rapport à un plan qui traverse la surface, la longueur de corrélation s'exprime dans le plan x-y.

Pour calculer ces paramètres, un nuage de point 3D représentant une surface naturelle est nécessaire. Pour rectifier l'orientation aléatoire d'un nuage de point, un plan ($ax + by + cz + d = 0$) en 2D est défini en minimisant la distance moyenne perpendiculaire de chacun des points par rapport au plan. Une matrice de rotation (R) doit être appliquée à tous les points (P) afin d'obtenir un nouveau plan ayant comme vecteur normal $\vec{n} = [a = 0, b = 0, c = 1]$ de sorte que les nouveaux points (P') définis avec l'équation 2.16 ont une hauteur uniquement dans l'axe z. La Figure 2-9 illustre le plan normal avec le nuage de points. La composante z de chaque point est utilisée pour calculer le σ_H ou autre paramètre qui analyse l'amplitude de la rugosité.

$$P = [x_i, y_i, z_i] \text{ and } R = \begin{bmatrix} \frac{b}{\sqrt{a^2 + b^2}} & \frac{-a}{\sqrt{a^2 + b^2}} & 0 \\ \frac{ac}{\sqrt{a^2 + b^2}} & \frac{bc}{\sqrt{a^2 + b^2}} & \sqrt{a^2 + b^2} \\ \frac{\sqrt{a^2 + b^2}}{a} & \frac{b}{\sqrt{a^2 + b^2}} & c \end{bmatrix}; \quad P' = R \cdot P \quad (2.16)$$

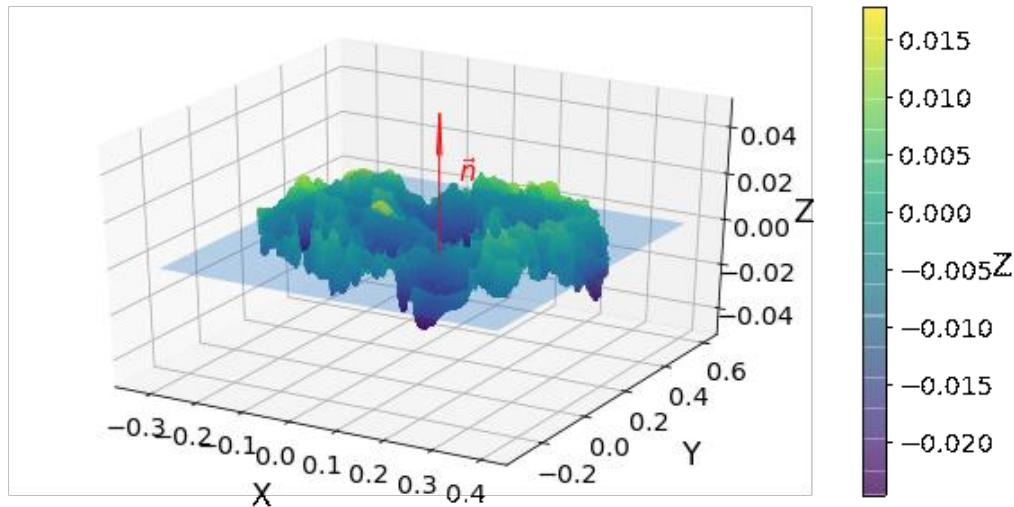


Figure 2-9: Nuage de point 3D d'une surface naturelle du sol après une rotation appliquée pour définir le nouveau plan normal. L'échelle en z est augmentée de 10x pour accentuer la rugosité.

Cette transformation permet aussi de calculer une fonction d'autocorrélation $\zeta(h)$ pour estimer la longueur de corrélation. Cette fonction (équation 2.17) représente la corrélation entre les hauteurs (z_i) de deux points séparés par une distance h .

$$\zeta(h) = \frac{\sum_{i=1}^{N(h)} z_i z_{i+h}}{\sum_{i=1}^N z_i^2} \quad (2.17)$$

Le nombre $N(h)$ est le nombre de paires de point avec une distance ou lag h . Un semi-variogramme est construit et permet d'analyser la semi-variance ou autocorrélation en fonction du lag h . Un modèle théorique (Gaussien, sphérique, linéaire, circulaire ou exponentiel) est régressé aux observations expérimentales dans la Figure 2-10. Cette courbe permet finalement d'estimer la longueur de corrélation (l_c) où la courbe $\zeta(l_c) = 1/e$ (Martinez-Agirre *et al.*, 2019).

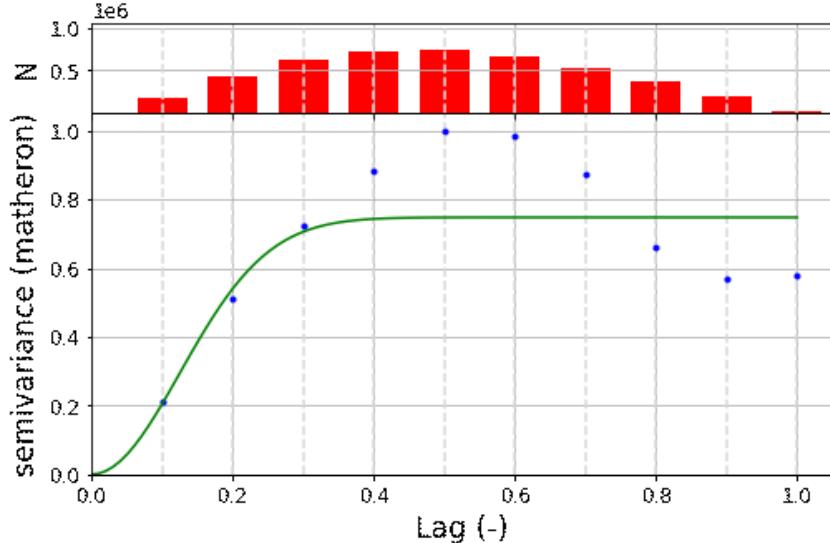


Figure 2-10: Semi-variogramme d'une surface rugueuse. La corrélation pour un lag donné est estimée avec le nombre N de pairs correspondants possédant un lag similaire (histogramme rouge). Un modèle théorique gaussien est regressé (courbe verte) avec une longueur de corrélation ($l_c = 0.21$ m).

Pour pouvoir calculer ces paramètres, un nuage de points représentant la surface naturelle doit être produit. Il existe plusieurs façons d'obtenir des nuages de point en géoscience. Premièrement la technologie LIDAR est bien utilisée dans le domaine (Turner *et al.*, 2014), mais une nouvelle technique de photogrammétrie jumelée à l'intelligence artificielle, appelée Structure-from-Motion (SfM) permet aussi d'obtenir l'information 3D de surfaces (Martinez-Agirre *et al.*, 2019). Dans la prochaine section, cet algorithme utilisé dans la thèse est défini.

2.7 Algorithme Structure from Motion (SfM)

La photogrammétrie est l'art et la science d'obtenir des données 3D à partir de la superposition d'une ou plusieurs images. Plusieurs photos sont prises en mouvement autour de la structure ou d'une surface dont on veut modéliser l'aspect 3D. Cet algorithme provient plus spécifiquement du domaine de la vision artificielle ou numérique (Lowe, 2004). Elle diffère de la photogrammétrie traditionnelle puisqu'il est possible d'obtenir toutes les informations directement des images 2D. L'algorithme SfM utilise donc la vision par ordinateur pour repérer les points d'intérêts (point rouge dans la Figure 2-11), qui sont des points qui apparaissent sur plusieurs images. La position en trois dimensions de ces points sera donc déterminée par la théorie classique de

photogrammétrie. Pour chaque photo, l'approche SfM estime numériquement la position et les paramètres optiques de la caméra nécessaire (James *et al.*, 2017) à la triangulation des points d'intérêts, de sorte qu'il n'est pas nécessaire de connaître ceux-ci à l'avance comme en photogrammétrie traditionnelle. Un nuage de point contenant seulement les points d'intérêts est donc produit. Finalement, une dernière étape permet la création d'un nuage de point dense, cette étape permet d'augmenter la densité du nuage de point en utilisant la texture présente dans les images.

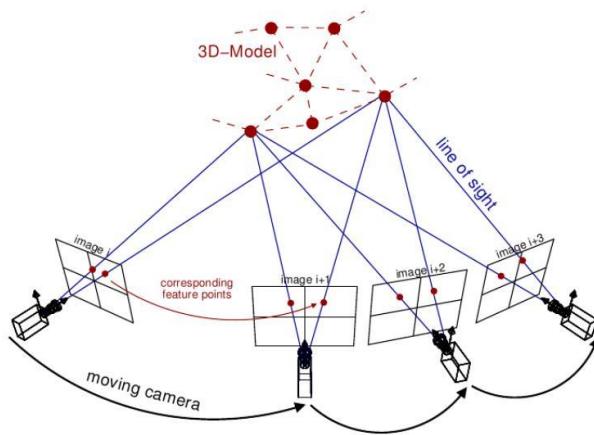


Figure 2-11: Représentation du processus SfM et de la triangulation des points d'intérêts qui apparaissent sur plusieurs images. Crédit : <http://www.theia-sfm.org>

Il est cependant nécessaire de référencer le modèle aux dimensions réelles. En imagerie aérienne, les systèmes de positionnement GPS à bord des systèmes aériens permettent d'obtenir cette référence. Il est également possible, si on désire seulement mettre le nuage de point à échelle réelle, d'utiliser plusieurs cibles linéaires comme des règles ou la distance entre deux points est connue. Cette technique beaucoup plus simple sera utilisée dans cette thèse puisqu'une position absolue sur la Terre (GPS) n'est pas nécessaire.

3 Méthode générale de la thèse

Le travail présenté permet de répondre à l'objectif global de la thèse qui est de quantifier les propriétés du couvert nivales de l'Arctique afin d'améliorer le suivi à l'aide de la télédétection PMW, mais aussi de mieux comprendre les processus affectant la variabilité. Quantifier cette variabilité est nécessaire pour ce domaine, mais aussi d'autres applications liées à la cryosphère. Le chapitre 4 étudie les processus affectant la variabilité de la hauteur de neige localement en prédisant la hauteur de neige à l'aide de paramètres spatiales (Objectif 1, Figure 3-1). Il permet de mettre la table au chapitre 5 qui incorpore la variabilité du manteau neigeux en simulation de PMW à l'échelle satellitaire (Objectif 2, Figure 3-1). Le chapitre 6 permet de paramétriser le sol gelé arctique en simulation de PMW (Objectif 3, Figure 3-1).

Les données récoltées et utilisées dans la thèse proviennent de deux sites en Arctique canadien. Cambridge Bay (CB) est le premier et principal site d'étude et se situe sur l'île de Victoria au Nunavut. Le deuxième site est à Trail Valley Creek (TVC) dans les Territoires du Nord-Ouest. Ces deux sites ont des caractéristiques classiques de l'Arctique et seront utilisés pour décrire la neige et le sol de la toundra.

Le chapitre 4 présente une méthode de prédiction de hauteur de neige à haute résolution spatiale à Cambridge Bay, Nunavut utilisant l'algorithme d'intelligence artificielle RF. Cette technique a été testée avec des données Lidar dans les alpes françaises (Revuelto *et al.*, 2020). Elle permet une prédiction spatiale à haute résolution avec des paramètres topographiques. Cette méthode est modifiée dans ce chapitre pour une application en arctique puisque les processus gouvernant la distribution de la hauteur de neige en arctique et milieu alpin sont différents. L'objectif du papier est donc de combler au manquer d'informations disponibles à haute résolution spatiale du couvert nival, mais aussi mieux s'informer sur le processus gouvernant l'épaisseur du manteau neigeux arctique. Les paramètres topographiques (TPI et Sx) utilisés dans l'article de Revuelto *et al.* (2020) en plus d'un paramètre de végétation sont testés pour une application arctique. De plus, cet article évalue l'interaction entre le couvert de neige et les différents écosystèmes de la région. La méthode présentée est très intéressante pour des applications en arctique où le manque de données in situ et la résolution grossière des produits PMW ne permet pas l'analyse des processus à petite échelle.

Ce genre de prédition de hauteur de neige est intéressante pour des zones de recherche multidisciplinaire où plusieurs autres domaines peuvent bénéficier d'une prédition des zones d'accumulation du couvert de neige. Cette section répond donc au manque de données haute résolution de la neige pour des applications connexes à la cryosphère.

Le chapitre 5 a pour principal objectif d'incorporer la variabilité de la neige arctique dans les simulations de transfert radiatif. Pour inverser les mesures d'ÉEN par satellite, une hauteur moyenne à l'intérieur des pixels est assumée pour permettre l'inversion et estimer une quantité de neige. Cependant, il est connu qu'une forte variabilité soit présente à l'échelle locale (ou intrapixel) des produits micro-ondes satellitaire. En utilisant une base de données de plusieurs années, cet article tente de quantifier la variabilité des propriétés nivales à l'aide de mesures terrain en l'ajoutant au modèle SMRT et évaluer l'impact sur la température de brillance simulé. L'influence de cet ajout ainsi que les paramètres pour la définir sont évalués en comparant au capteur Special Sensor Microwave Imager/Sounder (SSMIS) satellitaire en fréquence 19 et 37 GHz. Cette étude regroupe plusieurs années (2015-2019) de données sur les deux sites d'étude. Le jeu de donnée inclue des puits de neige classiques en plus de mesure de densité et de surface spécifique de la neige (SSA), des cartes de hauteur de neige acquises par drone et des mesures ponctuelles de hauteur de neige. L'utilisation de mesure satellitaire provenant du capteur SSMIS nécessite une correction atmosphérique. Les paramètres atmosphériques nécessaires ont été estimés avec les coefficients du Tableau 2-1 et la variable pwat provenant des 29 couches de l'atmosphère provenant du modèle de réanalyse régional Nord-Américain (NARR).

Le chapitre 6 utilise des mesures radiométriques terrestres pour évaluer les différents modèles de sol compris dans SMRT. La rugosité et la permittivité du sol est difficile à estimer pour les simulations en PMW. Ce papier propose une méthode pour mesurer la rugosité du sol pour ensuite optimiser la permittivité du sol l'aide de mesures radiométriques au sol. Des mesures de rugosité provenant d'une technique de photogrammétrie sont présentées et permettent de paramétriser la rugosité. Une caméra digitale est utilisée pour obtenir des images 2D de la surface après avoir retiré la neige. L'algorithme SfM basé sur la photogrammétrie permet de produire un nuage de points en 3 dimensions. Trois cibles de longueur connue (50 cm) sont utilisées pour afin de mettre

à l'échelle le modèle 3D. Les deux paramètres de rugosité; σ_H et l_c ont été estimé à l'aide des nuages de points et ont ensuite été utilisé pour des simulations PMW du sol gelé. Au total, 55 sites ont permis comparer des mesures radiométriques au sol et des simulations de trois différents modèles : QNH, Weg99 et Géo optique. La permittivité qui minimise la différence entre les simulations est présenté par modèle. Les mesures radiométriques sont corrigées en tenant compte de $T_B \text{ atm} \downarrow$ avec la relation linéaire par fréquence (Tableau 2-1) et le pwat de NARR.

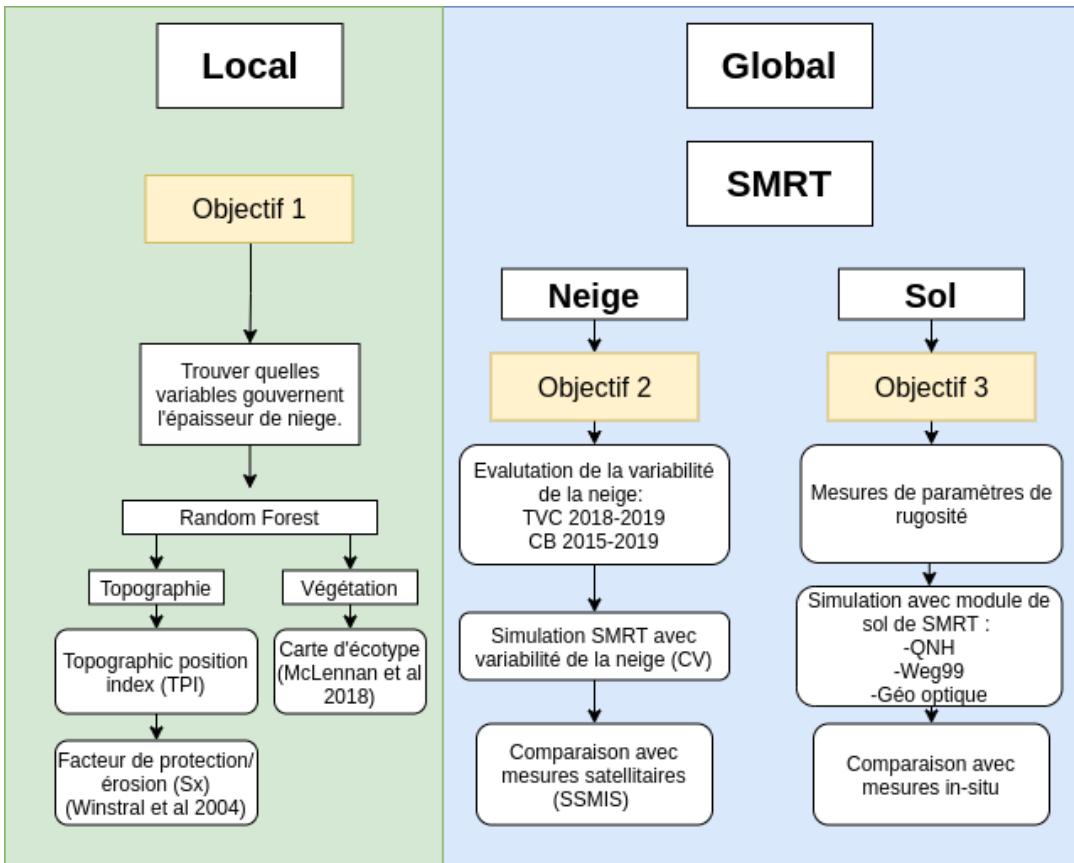


Figure 3-1: Organigramme de la thèse.

4 High-resolution snow depth prediction using Random Forest algorithm: a case study in the Greiner Watershed, Nunavut with an ecosystem map

Auteurs: Julien Meloche, Alexandre Langlois, Nick Rutter, Donald McLennan, Alain Royer, Paul Billecocq, Serguei Ponomarenko.

Référence complète:

Meloche, J., Langlois, A., Rutter, N., Royer, McLennan, D., Billecocq, P., et Ponomarenko, S. 2022. High-resolution snow depth prediction using Random Forest algorithm with topographic parameters: a case study in the Greiner Watershed, Nunavut. *Hydrological Processes*. 36(3) <https://doi.org/10.1002/hyp.14546>

Résumé :

L'augmentation des températures de surface en Arctique affecte les écosystèmes en réduisant la couverture et la durée d'enneigement du couvert de neige. Le suivi de ces écosystèmes nécessite une information détaillée au résolution (< 100 m) qui influence les habitats des écosystèmes et le dégel du pergélisol. Puisque la neige arctique est influencée par la végétation, une carte d'écotype à 10 m de résolution a été ajouté à un modèle de prédiction Random Forest développé en milieu alpin et appliqué ici pour la première fois sur un paysage arctique. Les paramètres topographiques utilisé par RF sont le TPI et le Sx, qui sont estimés à l'aide du MNT, Arctic DEM disponible gratuitement à 2 m de résolution. Les écotypes avec une hauteur de végétation plus élevée possédaient un couvert nival plus profond à cause de l'effet d'interception de la végétation et appartenait à un régime d'humidité du sol plus humide. En utilisant l'importance de chaque attribut, la hauteur de neige a été prédit à partir de paramètres topographiques et écosystémique avec une RMSE = 8 cm (23%) ($R^2 = 0.79$) à 10 m de résolution pour un bassin versant de l'arctique canadien (500 km²), au Nunavut, Canada.

High-resolution snow depth prediction using Random Forest algorithm with topographic parameters: a case study in the Greiner Watershed, Nunavut

Julien Meloche^{1,2}, Alexandre Langlois^{1,2}, Nick Rutter³, Donald McLennan⁴, Alain Royer^{1,2}, Paul Billecocq^{1,2}, Serguei Ponomarenko⁵

¹Département de géomatique appliquée, Université de Sherbrooke, Sherbrooke, J1K 2R1, Canada

²Centre d'études nordiques, Québec, Canada

³Department of Geography and Environmental Sciences, Northumbria University, Newcastle upon Tyne, NE1 8QH, UK

⁴Arctic Research Foundation, Ontario, N2L 6C2, Canada

⁵Polar Knowledge Canada, Canadian High Arctic Research Station, 1 Uvajuq Road, Cambridge Bay, NU, X0B0C0, Canada

Correspondence to: Julien Meloche (julien.meloche@usherbrooke.ca)

Abstract.

Increased surface temperatures (0.7°C per decade) in the Arctic affects polar ecosystems by reducing the extent and duration of annual snow cover. Monitoring of these important ecosystems needs detailed information on snow cover properties at resolutions (< 100 m) that influence ecological habitats and permafrost thaw. A machine learning method using topographic parameters with the Random Forest (RF) algorithm previously developed in alpine environments was applied over an arctic landscape for the first time. The topographic parameters used in the RF algorithm were Topographic Position Index (TPI) and up-wind slope index (Sx), which were estimated from the freely available Arctic DEM at 2 m resolution. Addition of an ecotype parameter (proxy for vegetation height) showed minimal predictive improvement. Using RF, snow depth distributions were predicted from topographic parameters with a root mean square error = 8 cm (23%) ($R^2 = 0.79$) at 10 m resolution for an arctic watershed (1 500 km²) in western Nunavut, Canada.

4.1 Introduction

Arctic environments are experiencing warmer air temperatures (Notz and Stroeve, 2016; Richter-Menge et al., 2017) where the rate of warming over the last 20 years is 2-3 times higher than elsewhere on the planet (Serreze and Barry, 2011; Cohen et al., 2020). This accelerated warming, also referred as Arctic amplification, affects surface state variables such as snow and permafrost (Serreze and Barry, 2011; Bokhorst et al., 2016; Derksen et al., 2019; Meredith et al., 2019) which in turn modifies soil properties, microbiological activities, and moisture availability for plant communities, all potentially driving shrub expansion (Marsh et al., 2010; Domine et al., 2016). The arctic shrub expansion in turn induces changes in snowpack properties (height, density and microstructure) with implications for ground-thermal regime (Myers-Smith et al., 2020; Royer et al., 2021). Changing snow conditions will also influence foraging conditions for arctic ungulate species (Bilodeau et al., 2013; Dolant et al., 2018) given the observed densification of the snowpack arising from an increased occurrence of winter extreme events such as rain-on-snow and winter storms (Dolant et al., 2016; Langlois et al., 2017).

The influence of snow cover on tundra ecosystems is strong and influences soil moisture, habitat suitability (McLennan et al., 2018) and protection from desiccating winter winds and freezing temperatures (Sturm et al., 2001). Furthermore, the low thermal conductivity of snow insulates ground surface temperature to modify freeze-thaw cycles, deepen the active layer and alter soil moisture and growing conditions for vegetation (Myers-Smith et al., 2011). To better quantify and predict the upcoming changes governed by all these processes, detailed and spatially explicit information on snow conditions is needed (Ponomarenko et al., 2019; Levasseur et al., 2021) and yet high resolution products for snow are not widely available for the Arctic. Snow cover properties are influenced by vegetation, soil moisture, temperature gradient and strong wind (Essery and Pomeroy, 2004; Davesne et al., 2021). In turn, these snow properties (density, microstructure and thermal conductivity) govern heat exchange between the atmosphere and the soil (Royer et al., 2021). Consequently, snow cover is crucial in our understanding of local processes in permafrost, hydrology and ecosystem modelling.

Previous studies have measured snow depth distribution in the Arctic (Liston and Sturm, 1998; Sturm et al., 2008; Sturm and Wagner, 2010) and improved our empirical understanding of the processes governing the spatial variability of snow properties. Two dominant snow processes controlling snow depth in arctic regions are wind redistribution (Parr et al., 2020) and vegetation trapping (Sturm et al., 2001; Domine et al., 2016; Busseau et al., 2017). Vegetation increases ground surface roughness and reduces wind speed to facilitate accumulation of snow, while topography and wind create accumulation and erosion zones depending on wind direction and speed, slope and micro-topography (Winstral et al., 2013). Although these processes are conceptually well understood, simulation of snow redistribution at meter scales remains challenging. Statistical modelling of snow depth using linear regression with terrain parameters as predictors has been developed in alpine regions (Grünewald et al., 2013; Pulwicki et al., 2018) and proven to be a simple and effective method estimating snow depth. However, the high degree of correlation between topographic parameters restricts the prediction capabilities when using a linear regression approach. Revuelto et al. (2020) used machine learning to predict snow depth at 1m resolution in an alpine area using the Random Forest algorithm, with terrain parameters as predictors. The method showed good performance on model validation ($R^2= 0.82-0.94$). Random Forest works well with nonlinear relationships and interaction among predictors (Kibria et al., 2020).

The main objective of this paper is to predict spatially distributed snow depth at high resolution (10 m) by testing the RF methodology of Revuelto et al. (2020) for arctic environments using the Arctic DEM available for the entire pan arctic. Since vegetation plays a key role in arctic snow redistribution, ecosystem type was evaluated as a feature using an ecotype map (Ponomarenko et al., 2019) to incorporate a proxy for vegetation height (snow trapping). First, snow-vegetation interactions were evaluated by comparing snow depth measurements from 2015-2019 within ecotypes. Second, the influence of topography and vegetation governing snow depth distribution in the Arctic was evaluated. Finally, snow depth predictions using RF at 10 m resolution were evaluated.

4.2 Method

4.2.1 Study site and ecosystems

The Greiner Lake watershed ($69^{\circ}13' N$, $104^{\circ}53' W$) is located on eastern Victoria Island in western Nunavut, Canada, and is adjacent to the community of Cambridge Bay (CB). The calcareous, low relief landscape is characterized by dwarf shrub tundra on well drained upland areas, with productive sedge fens in depressions. A predominately northwest wind direction was measured by meteorological station data from Environment and Climate Change Canada (Station ID: CB-53512) at the Cambridge Bay airport located about 10 km to the south. A high resolution (10 m) ecosystem map of the study site, shown in Figure 4-1 (Ponomarenko et al., 2019), contains 17 ecosite types, which were identified using an unsupervised classification of Sentinel-2 multispectral imagery to delineate ecosystem units. Ecosystem units were verified and classified based on a standardized ecosystem classification unit (McLennan et al., 2018). The ecosystem classification, based on the Canadian Arctic-Subarctic Biogeoclimatic Ecosystem Classification (CASBEC), assesses plant community, soil moisture and nutrient regimes using a standardized approach organized by soil moisture and nutrient characteristics, and incorporates key abiotic processes of each ecosystem unit (McLennan et al., 2018). Soil moisture regimes used in Figure 4-2 were associated to ecotypes based on CASBEC. The map from Ponomarenko et al. (2019) was used to incorporate ecotype information as a proxy for vegetation height. The area is characterized by tussock sedge, dwarf-shrub, moss and graminoid tundra (Figure 4-1), based on the Circumpolar Arctic Vegetation Map (CAVM) project (Raynolds et al., 2019). The snowpack corresponds to arctic tundra type (Royer et al., 2021) with an average depth between 30-40 cm, a basal layer of depth hoar and wind slab on top. The study site well represents arctic tundra processes, some areas of thicker vegetation for sub-arctic processes and some drier areas for polar desert.

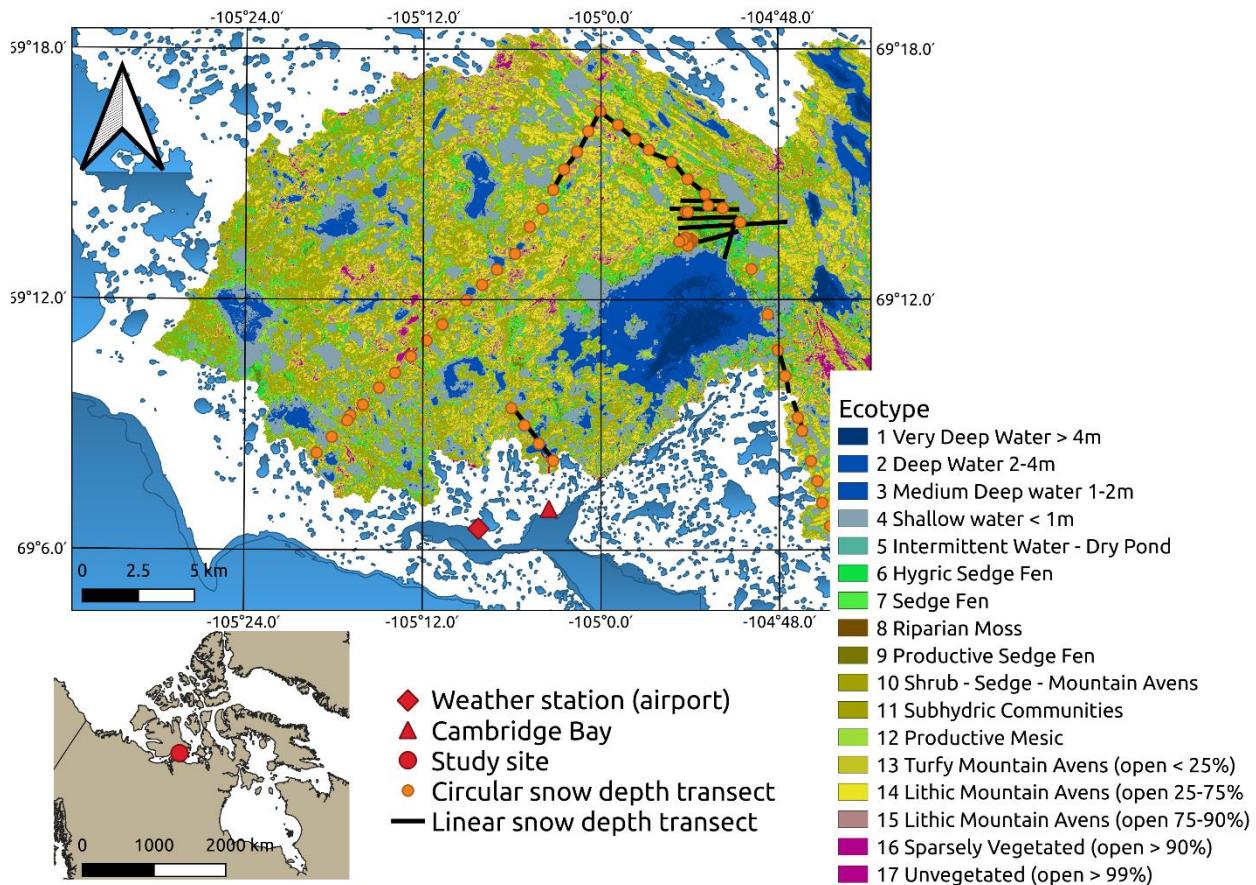


Figure 4-1 : Study site of the Greiner watershed, Victoria Island, Nunavut with ecomap from Ponomarenko et al. (2019). Snow depth data (circular and linear transect) selected randomly across the entire dataset for training and validation. Grid of WGS84 lat/long is shown.

4.2.2 Data

4.2.2.1 Snow depth measurements

Geolocated snow depth measurements (Table 4-1) were made using a magnaprobe (Sturm and Holmgren, 2018), which is equipped with a standard GPS unit (accuracy 2.5 m). The snow depth accuracy is assumed to be 5 cm for this study because of soft vegetation; it can vary from 0 to > 5 cm depending on the substrate (Sturm and Holmgren, 2018). The device was used to conduct spatial surveys from linear and circular transects (Figure 4-1), made near maximum annual snow accumulation. Circular transects of at least 30 snow depth measurements (approximately 30 - 50 m in diameter) provide spatially representative values. Linear snow depth transects between circular transects were added when possible. All ecotypes contained at least $n > 225$, and the number of samples per ecotype was a representation of the spatial extent in the field. Most of the

dominant ecotypes (Mountain Avens, Sedge fen and Shrub) had $n \approx 2000 - 3000$ samples. Each year, a different region of the Greiner watershed was measured to build up an overall assessment of spatial variability of snow depth because the interannual spatial pattern within a tundra watershed is consistent (Sturm and Wagner, 2010; Ménard et al., 2014; Marsh et al., 2020)

Table 4-1 : Summary of magnaprobe snow depth survey near maximum annual snow accumulation used for training the RF algorithm. The mean (μ_{sd}) and standard deviation (σ_{sd}) of snow depth (m) from each year are presented. Temperature of accumulation period is from October to January and ablation period from May to July. NA indicates that at least one month of temperature data was unavailable.

Year	Date of measurement	Points	Accumulation period temperature (°C)			Ablation period temperature (°C)		
			μ_{sd}	σ_{sd}	max	min	mean	max
2019	May 8	981	0.34	0.18	-7.5	-35.5	-23.1	11.7
2018	04-May	577	0.27	0.16	-7.8	-30.9	-21.3	NA
2017	May 1-14,	3407	0.41	0.15	NA	NA	NA	13.2
2016	April 2-10,	2916	0.34	0.18	-7.1	-31.7	-21.3	14.4
2015	April 12-24,	9602	0.42	0.17	-6.4	-34	-22.1	12.7
Total		17 483	0.35	0.17				

4.2.2.2 Random Forest (RF) algorithm

The Random Forest (RF) regressor algorithm builds a collection of decision trees and outputs the arithmetic average of each tree's prediction. Each tree is trained on a random subsample of the overall training set and with a random subsample of the predictors drawn among: Sx, TPI, ecotype, yearly mean snow depth and slope angle. As a result, RF can be trained with correlated variables, even though correlation can lower the importance of one of the predictors (Strobl et al., 2008). The data set was first divided into 50% training and 50% validation to evaluate RF performance, and then evaluated over the range of 10% to 90% of the data dedicated to training the model. The algorithm is trained with snow depth and corresponding predictors (continuous or discrete values) to make prediction based on weighted decision trees ensemble. Each snow depth measurement was associated with corresponding topographic parameters and ecotype using a spatial buffer of 10 m. For the final raster-based prediction, each raster of predictor had the same spatial extent and

pixel size. Snow depth prediction was done by applying the RF algorithm pixel by pixel across the area. The spatial predictors and snow depth output can be represented as a data cube and a single snow depth prediction with all predictors within a column. RF was chosen over Support Vector Machine (SVM) and Neural Network (NN) because it performs well with correlated variables and automatically control nonlinear relationship and interaction among predictor (Kibria et al., 2020).

RF expresses how predictions are made based on feature importance, which ranges from 0 to 1 (Strobl et al., 2007). There are two main algorithms for computing feature importance: Gini importance and permutation importance. Gini importance estimates feature importance based on the impurity reduction and the Gini gain splitting criterion (Strobl et al., 2007). The permutation method randomly permutes a feature (predictor) which has the same overall effect of removing a feature to evaluate the performance without the feature (Strobl et al., 2008). Both methods have a reported bias with correlated variables. Two variables will split their importance with each other so that one of the variables will have a lower feature importance. The Gini importance performs better with correlated variables but has issues with variation in number of categories of the feature (Revuelto et al., 2020; Strobl et al., 2008, 2007). Since we have both categorical variables and correlated variables, the permutation method was used in this paper because it is the most advanced way of estimating the importance (Strobl et al., 2007). However, we noticed little difference between both methods with our data.

4.2.2.3 Predictors for snow depth

To obtain predictors (features) for the RF algorithm, topographic variables were derived from the ArcticDEM, which is a digital surface model with a 2 m-resolution (Porter et al., 2021) created from stereo high-resolution optical imagery over the entire arctic domain. Using ArcticDEM, standard parameters such as elevation and slope were extracted for the feature analysis. Additional parameters were also calculated and include: 1) the Topographic Position Index (TPI) (Weiss, 2000) to evaluate pixel elevation with respect to surrounding pixels within a defined radius, and 2) the up-wind slope index (Sx) (Winstral et al., 2002) to estimate the predisposition of a pixel to erosion or accumulation of snow depending on wind direction and slope. TPI accounts for wind redistribution over flat areas, and Sx for steeper areas (alpine regime). A TPI using a 150 m radius

was used to analyze local effects, and a second TPI at 5 km was used to compensate for large elevational differences, and to act as a normalized elevation across the watershed. S_x was used with a radius of 100 m and a direction of 315° (dominant wind). In their study, Revuelto et al., (2020) used the snow depth measured at a local weather station to account for temporal variation of the mean, thereby linking mean snow depths at the point scale to the spatial distribution of snow depth across an alpine area. We applied a similar idea by adding the mean of the corresponding survey (Table 4-1) as a feature to each point i.e., all points collected in 2015 labeled with the fixed mean of 2015, repeated yearly. To account for vegetation interaction in RF, ecotypes from Figure 1 were used as another feature.

4.3 Results

4.3.1 Ecotypes and snow depth

In Figure 4-2, the average snow depth for each ecotype was correlated with the soil moisture regime from the edatopic grid presented in Figure 3 of McLennan et al. (2018) comparing snow cover and soil moisture regimes used in the CASBEC classification. Vegetated ecotypes with taller vegetation (30 cm height - Sedge Fen and Shrub-Sedge-Mountain avens) were correlated with higher snow depth averages given the trapping effect (Domine et al., 2016) and which may also reduce sublimation (Liston et al., 2002). Hygric and hydric soil moisture regimes, associated with higher vegetation and moisture had deeper snow depths than the mean.

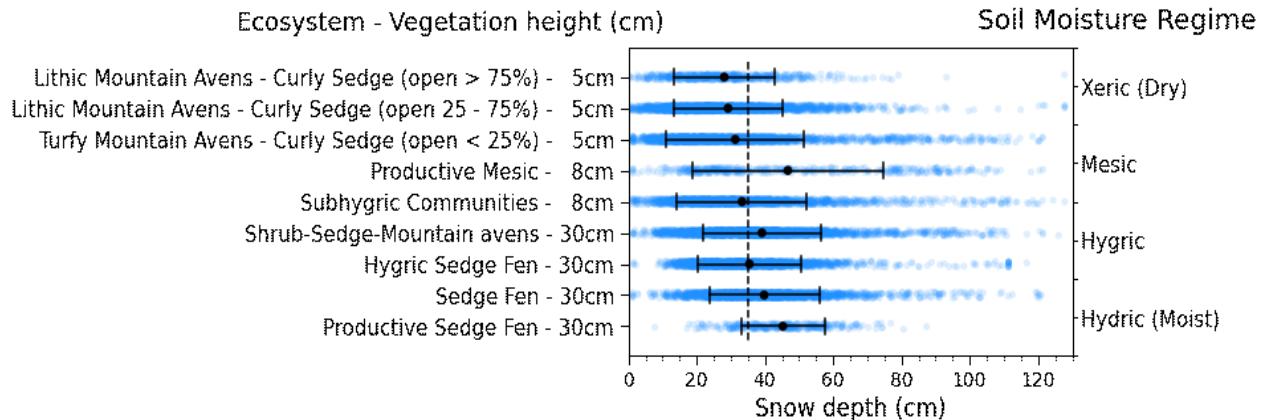


Figure 4-2: Mean and standard deviation of snow depth with principal ecotypes (Ponomarenko et al. 2019), vegetation height and soil moisture regime. The overall average (across all classes) snow depth is shown by the black dotted line. Vegetation height was estimated based on the type of vegetation in the ecotype. Soil moisture regime is based on the CASBEC classification (McLennan et al. 2018).

Mean snow depth in each ecotype was evaluated using a one-way Analysis of Variance (ANOVA) test which estimated that at least one of the ecotypes mean snow depth is significantly different than others ($p\text{-value} < 0.05$). Furthermore, a pairwise Tukey test highlighted which ecotypes were different from one another where ecotypes with similar means caused rejection of the null hypothesis. The null hypothesis states that snow depth means are significantly different. Results suggest that most ecotypes pairs (32 of 36) had significantly different means and both statistical tests indicated correlations between ecotypes and snow depth. The wide range of observations for each ecotype are probably the result of misclassification errors where the 10 m resolution of the mapping will often incorporate more than one ecotype.

4.3.2 RF algorithm evaluation

The RF algorithm predicted snow depth with an RMSE of 8 cm (23%) and an absolute error of 6 cm (Figure 4-3). Both the explained variance and R^2 score were 0.79 yielding high accuracies, similar to what was found by Revuelto et al. (2020). Figure 4-3(b) suggests that the model performs well over a wide range of Arctic snow depths given that residuals are uniformly scattered over the depth range of 0 – 0.8 m. Figure 4-3(c) shows that good precision ($R^2 > 0.7$) and accuracy RMSE < 10 cm are reached even with a low percentage (10%) training sample.

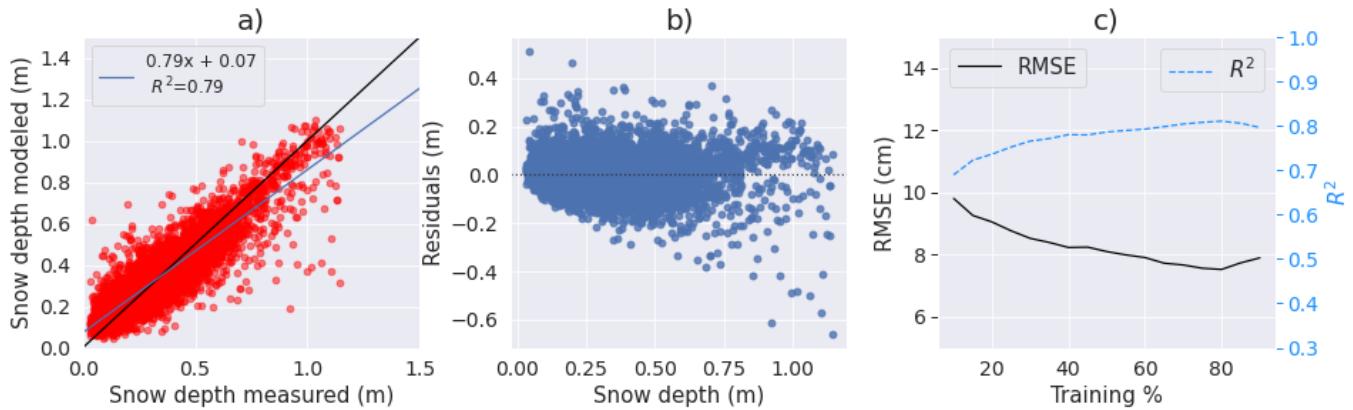


Figure 4-3: a) Measured and modelled snow depth from RF predictions. b) Residuals with measured values from the RF prediction.

Using the RF algorithm with snow depths and features defined above, variables derived from permutation importance for RF prediction can be estimated. The most important features for snow depth prediction (Figure 4-4 a) were wind-topographic parameters (TPI, Sx). As the Greiner watershed has a relatively low relief environment, TPI (150m) was the most significant variable for prediction. The annual mean snow depth had a high importance (0.3) since precipitation amount differed from year to year.

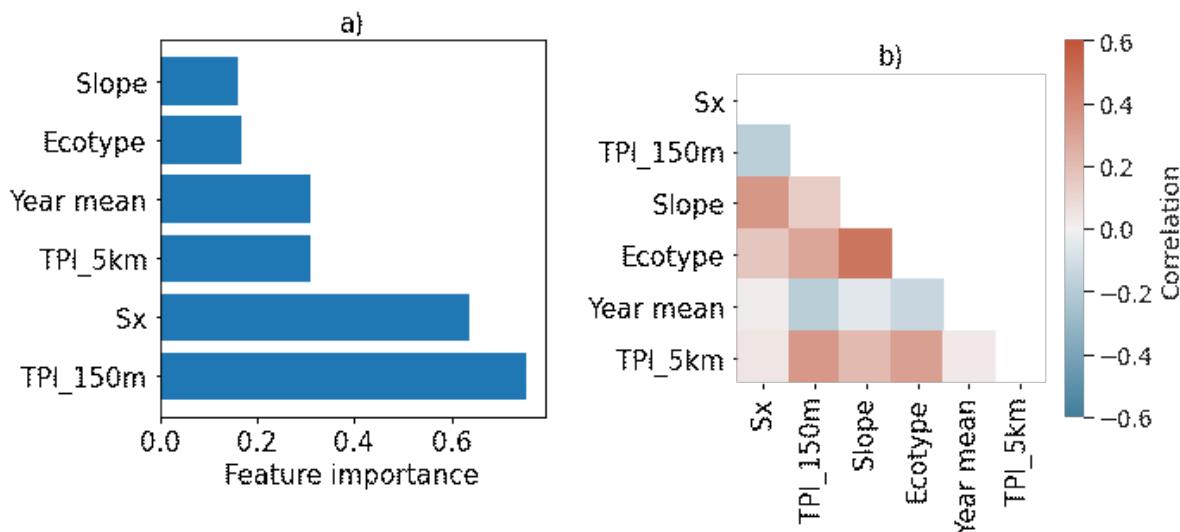


Figure 4-4: a) Feature importance in RF snow depth prediction of explanatory variables and b) Correlation matrix between variables calculated with the Pearson coefficient. "Year mean" corresponds to the mean winter snow depth.

Both TPI (150m and 5km) variables have an important positive correlation (0.3) with each other (Figure 4-4 b). Also, slope and Sx also had an expected positive correlation (0.3) given that Sx is a directional up-wind slope index. Even if RF performs well with correlated variables, two correlated variables will split their importance with each other so that one of the variables will have a lower feature importance. Consequently, ecotype is well correlated with all topographic parameters (section 3.1 and > 0.3 , Figure 4-4 b) and explains why a low feature importance was found. Annual mean had little correlation (≈ 0 , Figure 4-4 b) with other parameters.

Ecotypes were removed from the predicting variables, which accounted for a reduction of 0.01 in R^2 and 0.2 cm in RMSE. Ecotypes were found to have a small weight in feature importance of the RF algorithm compared to topographic parameters because they were correlated with each other (Figure 4-4). Topographic information (Sx and TPI) from the Arctic DEM can then predict snow depth alone. Since TPI and ecotype were highly correlated, the influence of ecotype on prediction was minimal. In Figure 4-5, predictions were tested by removing both TPI parameters. The performance was reduced to $R^2 = 0.65$ and RMSE = 10 cm but the ecotype variable becomes much more important in the prediction (from 0.1 to 0.7).

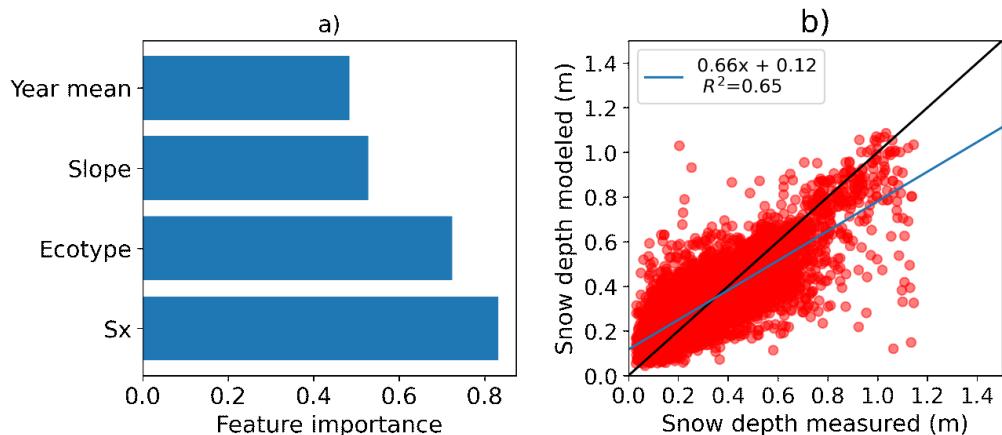


Figure 4-5 : Feature importance of prediction without the variable TPI. The RMSE of snow depth is 10 cm

4.3.3 Spatial prediction of snow depth across Greiner Watershed

Snow depth was predicted for the entire watershed. Water pixels were masked out since the RF algorithm was trained on land only using topographic variables and ecotypes. The predicted snow depth raster was generated pixel by pixel using the RF algorithm (no interpolation applied to final raster). Rasters of each predictor variable with the same spatial extent and resolution (10 m) were needed so the output can be predicted for each pixel. The influence of the directional Sx parameter at 315° (northwest wind) is clearly visible on the southeast aspect (Figure 4-6), where a snow depth > 0.75 m was predicted. Snow depth patterns appear highly dependent on local topography measured by TPI at 150 m according to local valleys and ridges.

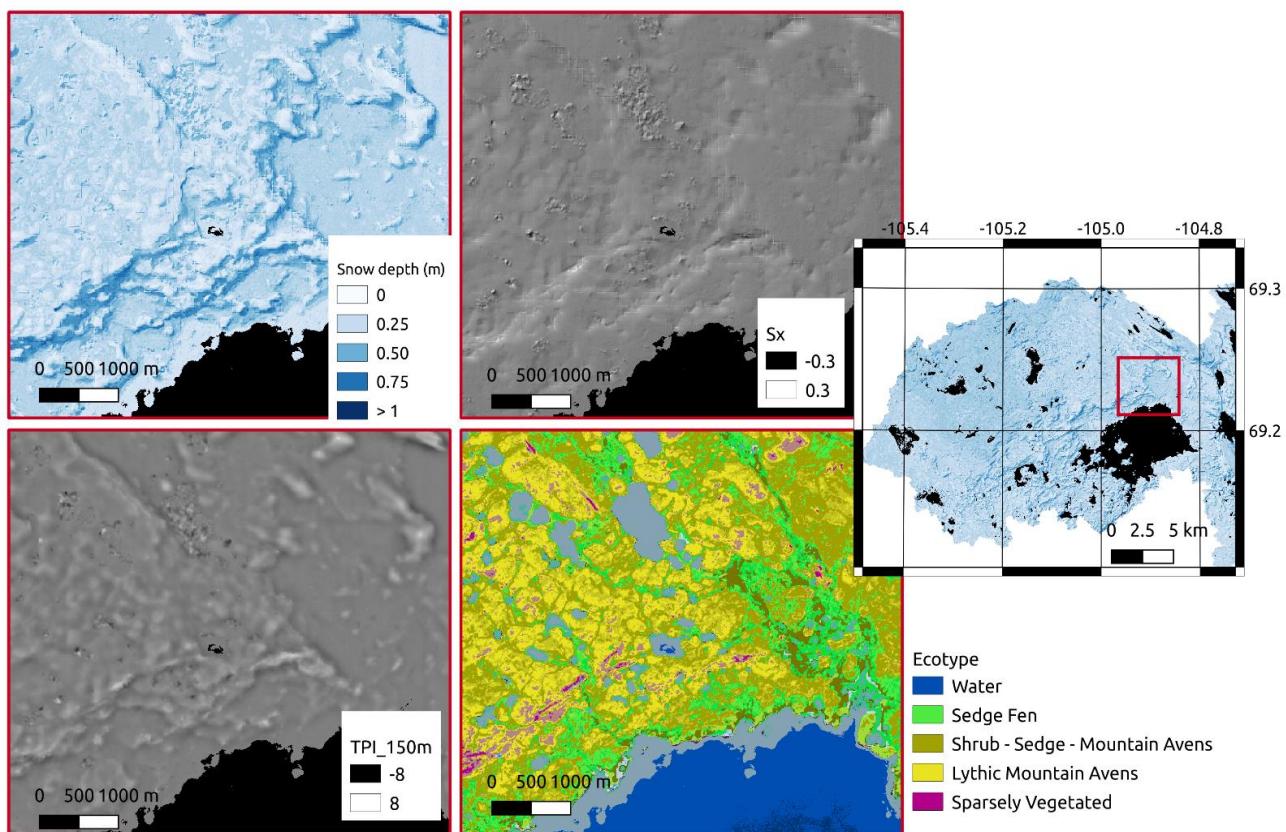


Figure 4-6: Snow depth prediction using the main variables of the RF algorithm (Sx, TPI and ecotype). Only a small subset of ecotypes is shown in the legend although all ecotypes (see Figure 4-1) are displayed on the map and were used in the prediction.

4.4 Discussion and Conclusion

This study demonstrates the applicability of RF to provide snow predictions using a high-resolution ecosystem map and topographic information. The RF prediction had high accuracy ($\text{RMSE} = 8 \text{ cm}$, $R^2 = 0.79$) and was useful to learn more about tundra snow distribution processes. The algorithm showed that topographic parameters such as TPI at 150 m and Sx ($R = 100 \text{ m}$ and Wind = N-W) were the dominant features in the prediction, which was also suggested by Revuelto et al. (2020). The mean snow depth per year was used to normalize each year and allow the algorithm to be used for future predictions in the watershed with a mean depth fixed by a weather station or a physical snow model like SNOWPACK (Bartelt and Lehning, 2002). Spatial variation in feature importance across the watershed was not evaluated but we expect features to be uniform since processes for tundra environment will still be mostly represented by TPI (Wainwright et al., 2017; Davesne et al., 2021) and the Sx parameter with a potential small change in wind direction or search radius. Due to a lack of data, the algorithm could not be evaluated on an independent dataset in the area. The trained algorithm presented in this article should not be used outside the Greiner watershed since it is sensitive to trained data and cannot be used outside the range of response variables (Revuelto et al., 2020). Deep NN could help make the prediction more general but would require an intensive training dataset. Future work could involve training the algorithm on multiple Arctic sites by incorporating community-based science of snow depth measurements as well as large scale snow depth maps from RPAS or airborne observations (Nolan et al., 2015; Walker et al., 2020).

The strong correlation with small scale topography (TPI) (10 – 1000 m) and snow depth in flat areas of the Arctic was known (Wainwright et al., 2017; Davesne et al., 2021). This parameter located landscape depressions favorable for snow accumulation without any wind direction which is particularly relevant for flat areas where only wind speed and surface roughness affect transported snow (Liston and Sturm, 1998). The Sx parameter also had a high importance, this parameter was designed for sloping areas (Winstral et al., 2002) where wind direction creates favorable conditions for up wind transport depending on slope and aspect. Snow accumulation on south-eastern aspects was common in the modeled area confirming the use of Sx at 315°, due to the usual northwest wind from winter storms. Topographic variables (TPI_{150m} , TPI_{5km} and slope)

used in RF were correlated (> 0.3) with ecotypes (Figure 4-4 b) and soil moisture since more productive ecotypes adapted to higher moisture regimes were located in valleys, ephemeral ponds and shallow water. Drier ecosystems were mostly located on ridges (Ponomarenko et al., 2019).

It was found (Figure 4-2) that the soil moisture regime was linked to snow depth because depth was significantly deeper for ecotypes in hygric and hydric soil moisture regimes. This relationship has hydrological implications; snow melt and water will accumulate at the surface because soil with high moisture content reduces infiltration due to frozen ice in the ground (Granger et al., 1984). This relates to the basal layer of the arctic snowpack (depth hoar) since soil moisture has been shown to promote depth hoar formation (Davesne et al., 2021).

Additionally, based on a one-way ANOVA and Tukey pairwise test, most of the ecotypes showed significantly different mean snow depths indicating that ecotypes were correlated with snow depth. Vegetation trapping from ecotypes with taller vegetation was reflected in deeper snow depths (Figure 4-2), similar to other arctic regions (Sturm et al., 2001; Domine et al., 2016; Royer et al., 2021). The importance of ecotype was reduced due to the correlation between vegetation and topography. Removing TPI parameters made ecotype relevant in the prediction. Vegetation buried by the weight of snow (Ménard et al., 2014) will reduce the capacity for redistributed snow to accumulate in these areas and may additionally reduce the impact of vegetation on snow redistribution from early winter. It is important to distinguish the snow trapping effects of taller vegetation (Sturm et al., 2001; Marsh et al., 2010) from site soil moisture regime that is linked to the topographic parameter at a local scale. Water provided by spring snowmelt can be the main runoff event of the year (Marsh and Pomeroy, 1996; Pohl and Marsh, 2006).

The main result from this study is that topographic parameters, Sx and TPI, have a strong correlation with snow depth, which can be applied to other models or studies where snow depth is needed. One example could be predicting the coefficient of variation of snow depth for climate modelling (Nitta et al., 2014) or microwave remote sensing of SWE (Meloche et al., 2022). One disadvantage of a RF model such as presented in this study is that training data can be restrictive

and rely on empirical relations. Machine learning models will never replace generalist-physical models, but they can effectively map the computation in parameter space (topography) of certain effects (in this case snow accumulation) and could be used to replicate patterns at a certain scale. One possible avenue to make the RF model more general is to use remote sensing products, such as Sentinel-1 in order to incorporate C band data at 10 m resolution as another feature in the RF modelling. Microwave active sensors with similar resolution (C or X band) are sensitive to vegetation (Duguay et al., 2015) and snow depth (Lievens et al., 2022).

Snow depth was predicted at 10 m resolution for the entire Greiner watershed using the freely available Arctic DEM. This method fulfilled part of the need for high resolution snow depth information and can be repeated easily with magnaprobe data or potentially Remotely Piloted Aircraft System (RPAS) snow depth cartography. The snow depth prediction in section 4.3.3 can be useful for other applications such as permafrost modelling in Cambridge Bay, which requires the high resolution (less than 100m) spatial information on snow depth that this map can provide. The algorithm can be trained and applied to other areas that require snow depth input at high resolution. SWE products at these larger scales are already benefiting from machine learning approaches (Xue and Forman, 2015; Bair et al., 2018; Xiao et al., 2018) to predict snow over the same area, and this method can do the same using the Arctic DEM anywhere in the Arctic. The RF method provides important insight on snow processes and snow-ecosystem interactions (trapping and metamorphism) and showed useful results that can provide the snow information necessary to conduct studies in related fields in the Arctic like permafrost, hydrology, or ecosystem modelling.

Acknowledgements

The authors would like to thank the entire Groupe de Recherche Interdisciplinaire en Milieu Polaire research team from Université de Sherbrooke and CHARS staff team for field work assistance from 2015 to 2019 in Cambridge Bay.

Financial support

This research was made possible thanks to the financial support of the Natural Sciences and Engineering Research Council of Canada (NSERC), Polar Knowledge Canada, the Canadian

Foundation for Innovation (CFI), Environment and Climate Change Canada (ECCC), Fonds de recherche du Québec – Nature et technologies (FRQNT), Northern Scientific Training Program (NSTP) and research funding from Northumbria University, UK.

Data availability

The snow depth map presented in section 3.3 is available in raster (.tiff) format at 10 m resolution will be available: <https://grimp.ca/data/>

Code (Jupyter Notebook) and training data are also available:

https://github.com/JulienMeloche/RF_snowdepth

References

- Bair, E.H., Calfa, A.A., Rittger, K., Dozier, J., 2018. Using machine learning for real-time estimates of snow water equivalent in the watersheds of Afghanistan. *Cryosphere*. <https://doi.org/10.5194/tc-12-1579-2018>
- Bartelt, P., Lehning, M., 2002. A physical SNOWPACK model for the Swiss avalanche warning. *Cold Reg. Sci. Technol.* 35, 123–145. [https://doi.org/10.1016/S0165-232X\(02\)00074-5](https://doi.org/10.1016/S0165-232X(02)00074-5)
- Belgiu, M., Drăgu, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bilodeau, F., Gauthier, G., Berteaux, D., 2013. Effect of snow cover on the vulnerability of lemmings to mammalian predators in the Canadian Arctic. *J. Mammal.* 94, 813–819. <https://doi.org/10.1644/12-MAMM-A-260.1>
- Bokhorst, S., Pedersen, S.H., Brucker, L., Anisimov, O., Bjerke, J.W., Brown, R.D., Ehrich, D., Essery, R.L.H., Heilig, A., Ingvander, S., Johansson, C., Johansson, M., Jónsdóttir, I.S., Inga, N., Luoju, K., Macelloni, G., Mariash, H., McLennan, D., Rosqvist, G.N., Sato, A., Savela, H., Schneebeli, M., Sokolov, A., Sokratov, S.A., Terzago, S., Vikhamar-Schuler, D., Williamson, S., Qiu, Y., Callaghan, T. V, 2016. Changing Arctic snow cover: A review of recent developments and assessment of future needs for observations, modelling, and impacts. *Ambio* 45, 516–537. <https://doi.org/10.1007/s13280-016-0770-0>
- Busseau, B.C., Royer, A., Roy, A., Langlois, A., Domine, F., 2017. Analysis of snow-vegetation interactions in the low Arctic-Subarctic transition zone (northeastern Canada). *Phys. Geogr.* 38, 159–175. <https://doi.org/10.1080/02723646.2017.1283477>
- Cohen, J., Zhang, X., Francis, J., Jung, T., Kwok, R., Overland, J., Ballinger, T.J., Bhatt, U.S., Chen, H.W., Coumou, D., Feldstein, S., Gu, H., Handorf, D., Henderson, G., Ionita, M., Kretschmer, M., Laliberte, F., Lee, S., Linderholm, H.W., Maslowski, W., Peings, Y., Pfeiffer, K., Rigor, I., Semmler, T., Stroeve, J., Taylor, P.C., Vavrus, S., Vihma, T., Wang, S., Wendisch, M., Wu, Y., Yoon, J., 2020. Divergent consensuses on Arctic amplification influence on midlatitude severe winter weather. *Nat. Clim. Chang.* 10, 20–29. <https://doi.org/10.1038/s41558-019-0662-y>
- Davesne, G., Domine, F., Fortier, D., 2021. Effects of meteorology and soil moisture on the spatio-temporal evolution of the depth hoar layer in the polar desert snowpack. *J. Glaciol.* 1–16. <https://doi.org/10.1017/jog.2021.105>
- Derkzen, C., Burgess, D., Duguay, C., Howell, S., Mudryk, L., Smith, S., Thackeray, C., Kirchmeier-Young, M., 2019. Changes in Snow, Ice, and Permafrost Across Canada. *Canada's Chang. Clim. Rep.* 194–260.
- Dolant, C., Langlois, A., Montpetit, B., Brucker, L., Roy, A., Royer, A., 2016. Development of a rain-on-snow detection algorithm using passive microwave radiometry. *Hydrol. Process.* 30, 3184–3196. <https://doi.org/10.1002/hyp.10828>

- Dolant, C., Montpetit, B., Langlois, A., Brucker, L., Zolina, O., Johnson, C.A., Royer, A., Smith, P., 2018. Assessment of the Barren Ground Caribou Die-off During Winter 2015–2016 Using Passive Microwave Observations. *Geophys. Res. Lett.* **45**, 4908–4916. <https://doi.org/10.1029/2017GL076752>
- Domine, F., Barrere, M., Morin, S., 2016. The growth of shrubs on high Arctic tundra at Bylot Island: Impact on snow physical properties and permafrost thermal regime. *Biogeosciences* **13**, 6471–6486. <https://doi.org/10.5194/bg-13-6471-2016>
- Duguay Y, Bernier M, Lévesque E, Tremblay B. 2015. Potential of C and X band SAR for shrub growth monitoring in sub-arctic environments. *Remote Sensing* **7** (7): 9410–9430 DOI: 10.3390/rs70709410
- Essery R, Pomeroy J. 2004. Vegetation and topographic control of wind-blown snow distributions in distributed and aggregated simulations for an arctic tundra basin. *Journal of Hydrometeorology* **5** (5): 735–744 DOI: 10.1175/1525-7541(2004)005<0735:VATCOW>2.0.CO;2
- Granger RJ, Gray DM, Dyck GE. 1984. Snowmelt infiltration to frozen Prairie soils. *Canadian Journal of Earth Sciences* **21** (6): 669–677 DOI: 10.1139/e84-073
- Grünewald, T., Stötter, J., Pomeroy, J.W., Dadic, R., Moreno Baños, I., Marturià, J., Spross, M., Hopkinson, C., Burlando, P., Lehning, M., 2013. Statistical modelling of the snow depth distribution in open alpine terrain. *Hydrol. Earth Syst. Sci.* **17**, 3005–3021. <https://doi.org/10.5194/hess-17-3005-2013>
- Kibria H, Abdullah S, Bustamam A. 2020. Comparison of random forest and support vector machine for prediction of cognitive impairment in Parkinson's disease. In *AIP Conference Proceedings* 020093. DOI: 10.1063/5.0030332
- Langlois, A., Johnson, C.A., Montpetit, B., Royer, A., Blukacz-Richards, E.A., Neave, E., Dolant, C., Roy, A., Arhonditsis, G., Kim, D.K., Kaluskar, S., Brucker, L., 2017. Detection of rain-on-snow (ROS) events and ice layer formation using passive microwave radiometry: A context for Peary caribou habitat in the Canadian Arctic. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2016.11.006>
- Levasseur, S., Brown, K., Langlois, A., McLennan, D., 2021. Measurement of physical properties and stable isotope composition of snow. *Atmosphere-Ocean. Atmos.*
- Lievens H, Brangers I, Marshall H-P, Jonas T, Olefs M, de Lannoy G. 2022. Sentinel-1 snow depth retrieval at sub-kilometer resolution over the European Alps. *The Cryosphere* **16** (1): 159–177 DOI: 10.5194/tc-16-159-2022
- Liston, G.E., Mcfadden, J.P., Sturm, M., Pielke, R.A., 2002. Modelled changes in arctic tundra snow, energy and moisture fluxes due to increased shrubs. *Glob. Chang. Biol.* <https://doi.org/10.1046/j.1354-1013.2001.00416.x>
- Liston, G.E., Sturm, M., 1998. A snow-transport model for complex terrain. *J. Glaciol.* <https://doi.org/10.1017/S0022143000002021>

Marsh CB, Pomeroy JW, Spiteri RJ, Wheater HS. 2020. A Finite Volume Blowing Snow Model for Use With Variable Resolution Meshes. *Water Resources Research* **56** (2) DOI: 10.1029/2019WR025307

Marsh, P., Bartlett, P., MacKay, M., Pohl, S., Lantz, T., 2010. Snowmelt energetics at a shrub tundra site in the western Canadian Arctic. *Hydrol. Process.* 24, 3603–3620.
<https://doi.org/10.1002/hyp.7786>

Marsh, P., Pomeroy, J.W., 1996. Meltwater fluxes at an arctic forest-tundra site. *Hydrol. Process.* 10, 1383–1400. <https://doi.org/10.1002/>

McLennan, D.S., MacKenzie, W.H., Meidinger, D., Wagner, J., Arko, C., 2018. A Standardized Ecosystem Classification for the Coordination and Design of Long-term Terrestrial Ecosystem Monitoring in Arctic-Subarctic Biomes. *Arctic* 71, 1–15.
<https://doi.org/10.14430/arctic4621>

Meloche J, Langlois A, Rutter N, Royer A, King J, Walker B, Marsh P, Wilcox EJ. 2022. Characterizing tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals. *The Cryosphere* **16** (1): 87–101 DOI: 10.5194/tc-16-87-2022

Ménard CB, Essery R, Pomeroy J. 2014. Modelled sensitivity of the snow regime to topography, shrub fraction and shrub height. *Hydrology and Earth System Sciences* **18** (6): 2375–2392 DOI: 10.5194/hess-18-2375-2014

Meredith, M., Sommerkorn, M., Cassotta, S., Derksen, C., Ekaykin, A., Hollowed, A., Kofinas, G., Mackintosh, A., Melbourne-Thomas, J., Muelbert, M.M., Ottersen, G., Preitchard, H., Schuur, E.A.G., 2019. Polar regions. In H.-O Pörtner, et al. (Eds.). IPCC Spec. Rep. Ocean Cryosph. a Chang. Clim. 203–320.

Myers-Smith, I.H., Forbes, B.C., Wilmking, M., Hallinger, M., Lantz, T., Blok, D., Tape, K.D., Macias-Fauria, M., Sass-Klaassen, U., Lévesque, E., Boudreau, S., Ropars, P., Hermanutz, L., Trant, A., Collier, L.S., Weijers, S., Rozema, J., Rayback, S.A., Schmidt, N.M., Schaepman-Strub, G., Wipf, S., Rixen, C., Ménard, C.B., Venn, S., Goetz, S., Andreu-Hayles, L., Elmendorf, S., Ravolainen, V., Welker, J., Grogan, P., Epstein, H.E., Hik, D.S., 2011. Shrub expansion in tundra ecosystems: Dynamics, impacts and research priorities. *Environ. Res. Lett.* 6. <https://doi.org/10.1088/1748-9326/6/4/045509>

Myers-Smith, I.H., Kerby, J.T., Phoenix, G.K., Bjerke, J.W., Epstein, H.E., Assmann, J.J., John, C., Andreu-Hayles, L., Angers-Blondin, S., Beck, P.S.A., Berner, L.T., Bhatt, U.S., Bjorkman, A.D., Blok, D., Bryn, A., Christiansen, C.T., Cornelissen, J.H.C., Cunliffe, A.M., Elmendorf, S.C., Forbes, B.C., Goetz, S.J., Hollister, R.D., de Jong, R., Loranty, M.M., Macias-Fauria, M., Maseyk, K., Normand, S., Olofsson, J., Parker, T.C., Parmentier, F.J.W., Post, E., Schaepman-Strub, G., Stordal, F., Sullivan, P.F., Thomas, H.J.D., Tømmervik, H., Treharne, R., Tweedie, C.E., Walker, D.A., Wilmking, M., Wipf, S., 2020. Complexity revealed in the greening of the Arctic, *Nature Climate Change*.
<https://doi.org/10.1038/s41558-019-0688-1>

- Nitta T, Yoshimura K, Takata K, O’ishi R, Sueyoshi T, Kanae S, Oki T, Abe-Ouchi A, Liston GE. 2014. Representing variability in subgrid snow cover and snow depth in a global land model: Offline validation. *Journal of Climate* 27 (9): 3318–3330 DOI: 10.1175/JCLI-D-13-00310.1
- Notz, D., Stroeve, J., 2016. Observed Arctic sea-ice loss directly follows anthropogenic CO₂ emission. *Science* (80). 354, 747–750. <https://doi.org/10.1126/science.aag2345>
- Parr, C., Sturm, M., Larsen, C., 2020. Snowdrift Landscape Patterns: An Arctic Investigation. *Water Resour. Res.* 56. <https://doi.org/10.1029/2020WR027823>
- Pohl, S., Marsh, P., 2006. Modelling the spatial-temporary variability of spring snowmelt in an arctic catchment. *Hydrol. Process.* 20, 1773–1792. <https://doi.org/10.1002/hyp.5955>
- Ponomarenko, S., McLennan, D., Pouliot, D., Wagner, J., 2019. High Resolution Mapping of Tundra Ecosystems on Victoria Island, Nunavut – Application of a Standardized Terrestrial Ecosystem Classification. *Can. J. Remote Sens.* 45, 551–571.
<https://doi.org/10.1080/07038992.2019.1682980>
- Porter C, Morin P, Howat I, Noh M-J, Bates B, Peterman K, Keesey S, Schlenk M, Gardiner J, Tomko K, et al. 2021. ArcticDEM – Polar Geospatial Center. *Harvard Dataverse*: V1 DOI: 10.7910/DVN/OHHUKH
- Pulwicki, A., Flowers, G.E., Radic, V., Bingham, D., 2018. Estimating winter balance and its uncertainty from direct measurements of snow depth and density on alpine glaciers. *J. Glaciol.* 64, 781–795. <https://doi.org/10.1017/jog.2018.68>
- Raynolds, M.K., Walker, D.A., Balser, A., Bay, C., Campbell, M., Cherosov, M.M., Daniëls, F.J.A., Eidesen, P.B., Ermokhina, K.A., Frost, G. V., Jedrzejek, B., Jorgenson, M.T., Kennedy, B.E., Kholod, S.S., Lavrinenko, I.A., Lavrinenko, O. V., Magnússon, B., Matveyeva, N. V., Metúsalemsson, S., Nilsen, L., Olthof, I., Pospelov, I.N., Pospelova, E.B., Pouliot, D., Razzhivin, V., Schaepman-Strub, G., Šibík, J., Telyatnikov, M.Y., Troeva, E., 2019. A raster version of the Circumpolar Arctic Vegetation Map (CAVM). *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2019.111297>
- Revuelto, J., Billecocq, P., Tuzet, F., Cluzet, B., Lamare, M., Larue, F., Dumont, M., 2020. Random forests as a tool to understand the snow depth distribution and its evolution in mountain areas. *Hydrol. Process.* hyp.13951. <https://doi.org/10.1002/hyp.13951>
- Richter-Menge, J., Overland, J.E., Mathis, J.T., Osborne, E., 2017. Arctic Report Card 2017 1–96.
- Royer, A., Domine, F., Roy, A., Langlois, A., Marchand, N., Davesne, G., 2021. New northern snowpack classification linked to vegetation cover on a latitudinal mega-transect across northeastern Canada. *Écoscience* 00, 1–18. <https://doi.org/10.1080/11956860.2021.1898775>
- Serreze, M.C., Barry, R.G., 2011. Processes and impacts of Arctic amplification: A research synthesis. *Glob. Planet. Change* 77, 85–96. <https://doi.org/10.1016/j.gloplacha.2011.03.004>
- Strobl, C., Boulesteix, A.L., Kneib, T., Augustin, T., Zeileis, A., 2008. Conditional variable

- importance for random forests. BMC Bioinformatics 9, 1–11. <https://doi.org/10.1186/1471-2105-9-307>
- Strobl, C., Boulesteix, A.L., Zeileis, A., Hothorn, T., 2007. Bias in random forest variable importance measures: Illustrations, sources and a solution. BMC Bioinformatics 8. <https://doi.org/10.1186/1471-2105-8-25>
- Sturm, M., Derksen, C., Liston, G., Silis, A., Solie, D., Holmgren, J., Huntington, H., 2008. A Reconnaissance Snow Survey across Northwest Territories and Nunavut, Canada, April 2007.
- Sturm, M., Holmgren, J., 2018. An Automatic Snow Depth Probe for Field Validation Campaigns. Water Resour. Res. 54, 9695–9701. <https://doi.org/10.1029/2018WR023559>
- Sturm, M., McFadden, J.P., Liston, G.E., Stuart Chapin, F., Racine, C.H., Holmgren, J., 2001. Snow-shrub interactions in Arctic Tundra: A hypothesis with climatic implications. J. Clim. [https://doi.org/10.1175/1520-0442\(2001\)014<0336:SSIIAT>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<0336:SSIIAT>2.0.CO;2)
- Sturm, M., Wagner, A.M., 2010. Using repeated patterns in snow distribution modeling: An Arctic example. Water Resour. Res. 46, 1–15. <https://doi.org/10.1029/2010WR009434>
- Wainwright, H.M., Liljedahl, A.K., Dafflon, B., Ulrich, C., Peterson, J.E., Gusmeroli, A., Hubbard, S.S., 2017. Mapping snow depth within a tundra ecosystem using multiscale observations and Bayesian methods. Cryosph. 11, 857–875. <https://doi.org/10.5194/tc-11-857-2017>
- Walker B, Wilcox EJ, Marsh P. 2020. Accuracy assessment of late winter snow depth mapping for tundra environments using Structure-from-Motion photogrammetry. *Arctic Science* 17 (November): 1–17 DOI: 10.1139/as-2020-0006
- Weiss, A.D., 2000. Topographic Position and Landforms analysis. Poster Present. ESRI User Conf. San Diego, CA 64, 227–245.
- Winstral, A., Elder, K., Davis, R.E., 2002. Spatial Snow Modeling of Wind-Redistributed Snow Using Terrain-Based Parameters. J. Hydrometeorol. 3, 524–538. [https://doi.org/10.1175/1525-7541\(2002\)003<0524:SSMOWR>2.0.CO;2](https://doi.org/10.1175/1525-7541(2002)003<0524:SSMOWR>2.0.CO;2)
- Winstral, A., Marks, D., Gurney, R., 2013. Simulating wind-affected snow accumulations at catchment to basin scales. Adv. Water Resour. 55, 64–79. <https://doi.org/10.1016/j.advwatres.2012.08.011>
- Xiao, X., Zhang, T., Zhong, X., Shao, W., Li, X., 2018. Support vector regression snow-depth retrieval algorithm using passive microwave remote sensing data Remote Sensing of Environment Support vector regression snow-depth retrieval algorithm using passive microwave remote sensing data. Remote Sens. Environ. 210, 48–64. <https://doi.org/10.1016/j.rse.2018.03.008>
- Xue, Y., Forman, B.A., 2015. Comparison of passive microwave brightness temperature prediction sensitivities over snow-covered land in North America using machine learning algorithms and the Advanced Microwave Scanning Radiometer. Remote Sens. Environ.

<https://doi.org/10.1016/j.rse.2015.09.009>

5 Characterizing Tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals

Auteurs: Julien Meloche, Alexandre Langlois, Nick Rutter, Alain Royer, Josh King, Branden Walker, Philip Marsh, Evan J. Wilcox.

Référence complète:

Meloche, J., Langlois, A., Rutter, N., Royer, King, J., Walker, B., Marsh, P., and Wilcox, E.
2022. Characterizing Tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals. *The Cryosphere*, 16, 87–101. <https://doi.org/10.5194/tc-16-87-2022>

Résumé:

La topographie et la végétation en Arctique jouent un rôle important dans le contrôle de la variabilité spatiale intrapixel du manteau neigeux, mais n'est pas considérée dans les algorithmes d'estimation de l'ÉEN par PMW. Simuler la variabilité spatiale des propriétés de la neige est aussi problématique lors de la réduction d'échelle de modèles climatiques et de neige. Dans cette étude, la variabilité observée des propriétés du manteau neigeux (hauteur, densité et microstructure) a été simplifiée à 2 couches avec des valeurs moyennes et distribution provenant de deux jeux de données de la toundra arctique pour que cette variabilité soit incorporée dans l'estimation de l'ÉEN par satellite. La variabilité spatiale de la hauteur de neige a été paramétrisée avec une distribution log normale avec une moyenne (μ_{sd}) et un coefficient de variation (CV_{sd}). La variabilité de la hauteur de neige (CV_{sd}) a été estimée l'aide de carte de hauteur provenant d'imagerie drone et augmente en fonction de la zone mesurée. Les distributions de la surface spécifique de neige (SSA) et de la densité ont été dérivées pour les couches de plaque à vent (WS) et de givre de profondeur (DH). La fraction moyenne de givre de profondeur à Trail Valley Creek était légèrement supérieure à celle mesurée à Cambridge Bay (CB), TVC étant à une latitude inférieure en région subarctique avec une présence d'arbustes plus denses contrairement à CB qui est considéré comme une toundra gramoïde. Une régression du DHF à l'aide de processus gaussien permet de prédire le DHF à partir de hauteur de neige. Des simulations de température de brillance avec le modèle SMRT incorporent une variation de hauteur de neige et DHF ont été évaluées avec des mesures du capteur SSMIS. La variation de la hauteur de neige (CV_{sd}) est proposée comme paramètre effectif pour

tenir compte de la variabilité intrapixel en émission micro-ondes, améliorant les simulations de 8K. Les simulations SMRT utilisant un CV_{sd} de 0.9 est comparable aux observations de CV_{sd} des zones $> 3 \text{ km}^2$, qui est comparable à la résolution du capteur de la grille EASE 2.0 (3.125 km) à 37 GHz.

Characterizing Tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals

Julien Meloche^{1,2}, Alexandre Langlois^{1,2}, Nick Rutter³, Alain Royer^{1,2}, Josh King⁴, Branden Walker⁵, Philip Marsh⁵, Evan J. Wilcox⁵

¹Centre d'Applications et de Recherche en Télédétection, Université de Sherbrooke, Sherbrooke, J1K 2R1, Canada

²Centre d'études Nordiques, Université Laval, Québec, G1V 0A6, Canada

³Department of Geography and Environmental Sciences, Northumbria University, Newcastle upon Tyne, NE1 8ST, UK

⁴Environment and Climate Change Canada, Climate Research Division, Toronto, M3H 5T4, Canada

⁵Cold Regions Research Centre, Wilfrid Laurier University, Waterloo, N2L 3C5, Canada

Corresponding author: Julien Meloche (julien.meloche@usherbrooke.ca)

Abstract.

Topography and vegetation play a major role in sub-pixel variability of Arctic snowpack properties, but are not considered in current passive microwave (PMW) satellite SWE retrievals. Simulation of sub-pixel variability of snow properties is also problematic when downscaling snow and climate models. In this study, we simplified observed variability of snowpack properties (depth, density, microstructure) in a two-layer model with mean values and distributions of two multi-year tundra dataset so they could be incorporated in SWE retrieval schemes. Spatial variation of snow depth was parametrized by a log-normal distribution with mean (μ_{sd}) values and coefficients of variation (CV_{sd}). Snow depth variability (CV_{sd}) was found to increase as a function of the area measured by a Remotely Piloted Aircraft System (RPAS). Distributions of snow specific surface area (SSA) and density were found for the wind slab (WS) and depth hoar (DH) layers. The mean depth hoar fraction (DHF) was found to be higher in Trail Valley Creek (TVC) than in Cambridge Bay (CB) where TVC is at a lower latitude with a sub-arctic shrub tundra compared to CB which is a graminoid tundra. DHF were fitted with a gaussian process and predicted from snow depth. Simulations of brightness temperatures using the Snow Microwave Radiative Transfer (SMRT) model incorporating snow depth and DHF variation were evaluated with measurements from the Special Sensor Microwave/Imager and Sounder (SSMIS) sensor. Variation in snow depth (CV_{sd}) is proposed as an effective parameter to account for sub-pixel variability in PMW emission, improving simulation by 8K. SMRT simulations using a CV_{sd} of 0.9 best matched CV_{sd} observations from spatial datasets for areas $> 3 \text{ km}^2$, which is comparable to the 3.125 km pixel size of the Equal-Area Scalable Earth (EASE) grid 2.0 enhanced resolution at 37 GHz.

Keywords: sub-pixel variability, microwave, snow water equivalent, tundra snow

5.1 Introduction

Snow cover is known to be highly variable at the local scale (10 – 1000 m) due to wind redistribution, sublimation (Liston and Sturm, 1998; Winstral et al., 2013) and vegetation trapping (Sturm et al., 2001). Physical properties of snow such as measurement of stratigraphy (Fierz et al., 2009) can be aggregated into layers, but their spatial distribution is highly variable given their dependence on total depth and surface roughness (Liljedahl et al., 2016; Rutter et al., 2014). Such variability leads to uncertainties in the retrievals of snow state variables such as snow water equivalent (SWE) using microwave remote sensing from local scales (King et al., 2018; Rutter et al., 2019) to global scales (Pulliainen et al., 2020). Improving our empirical understanding of the processes governing this variability would improve space-borne snow monitoring, especially in Arctic regions where ground measurements and weather station networks are sparse.

Measurement of SWE using passive microwave satellite data (Larue et al., 2018; Pulliainen, 2006) is possible using a radiative transfer model to simulate snow emission at various frequencies, from which an inversion of the model can produce global estimates of snow depth (Takala et al., 2011). More specifically, passive microwave brightness temperatures (T_B) are governed by radiometric properties of the layered snowpack. As such, each layer has its own absorption and scattering properties; the amount of scattering is proportional to snow total mass where the scattering and emission is frequency-dependent (Kelly et al., 2003). Scattering at higher frequencies such as 37GHz, will lead to lower T_B so differences between T_B at two frequencies (37-19 GHz) is related to snow mass (Chang et al., 1982). Arctic snowpack mainly consists of two distinct layers (wind slab and depth hoar), where each layer has unique scattering properties (Derksen et al., 2010). Complexity of the layered properties (density, temperature and microstructure) strongly influence radiative transfer modelling (King et al., 2015; Rutter et al., 2014). Furthermore, recent developments in radiative transfer modelling (SMRT: Picard et al., 2018, DMRT: Tsang et al., 2000 and MEMLS: Wiesmann and Mätzler, 1999), microstructure representation (Royer et al., 2017), and in situ measurement of snowpack properties (Gallet et al., 2009; Montpetit et al., 2012; Proksch et al., 2015) have provided significant agreement between models and in situ measurements. However, spatial distribution and heterogeneity of total snow depth and stratigraphy remains challenging to implement and is not considered for large scale monitoring of

SWE in tundra environments. Rutter et al. (2019) and Saberi et al. (2020), using three- and two-layer models respectively, demonstrated a relationship between the ratio of depth hoar and wind slab with respect to total depth, enabling the usage of proportion of these two layers with total snow depth. Working with a simplified layer representation of a snowpack with well-defined physical properties may adequately characterize snowpack for large scale SWE retrievals.

Two dominant processes governing snow depth variability in the Arctic are 1) wind redistribution with topography (Sturm and Wagner, 2010; Winstral et al., 2002) and 2) vegetation trapping (Domine et al., 2018; Sturm et al., 2001). Liston (2004) described snow depth heterogeneity using a log-normal distribution with a coefficient of variation of snow depth (CV_{sd}), the ratio between standard deviation (σ_{sd}) and the mean of snow depth (μ_{sd}), indicating the extent and spread of a distribution (i.e. high variability over thin snow will lead to high values of CV_{sd}). Also, Liston (2004) proposed 9 categories of CV_{sd} with values ranging from 0.9 to 0.06 for mid-latitude treeless mountains to ephemeral snow, where arctic tundra type was 0.4. Snow depth variability is based on a parametrization of μ_{sd} , CV_{sd} on the log-normal distribution scale parameters (λ, ζ). Gisnas et al. (2016) adapted that approach using scale parameters (α, β) of the gamma distribution. In all cases, CV_{sd} is used to describe subgrid variability (Clark et al., 2011), but its value remains challenging to quantify given that regional trends are linked to topography, vegetation and climate (Winstral and Marks, 2014). In this context, CV_{sd} is used to quantify spatial heterogeneity of snow in climate modelling, but so far has not been used in microwave SWE retrievals.

In SWE retrievals, snow depth is assumed to be uniform and the mean depth is used to optimize brightness temperature and derive SWE from depth and assumed density (Kelly, 2009). There is potential for CV_{sd} to be used as an effective parameter to estimate sub-pixel variability in brightness temperature. Bayesian frameworks are used in inversion schemes for SWE retrievals (Durand and Liu, 2012; Pan et al., 2017; Saberi et al., 2020) using *a priori* information (density, microstructure and temperature) from regional snowpack characteristics and inversion of radiative transfer models (Saberi et al., 2020). An iterative approach based on Bayesian theory is used (Takala et al., 2011) to match observed brightness temperature with modelled brightness temperature by iterating *a priori* information of the snowpack in order to derive snow depth and

SWE. Saberi et al. (2020) conducted a case study for snow depth retrievals using a two layer model from airborne microwave observations using a Bayesian framework (or Markov Chain Monte Carlo) over tundra snow. However, high uncertainty (21.8 cm) in retrieved snow depth (via T_B) resulted, which suggested the use of a term involving variation in snow depth and microstructure within the footprint instead of a uniform snow depth.

To address this research gap, we used a multi-year snow dataset from two Arctic locations to quantify sub-pixel variability of snow depth and microstructure and used CV_{sd} as an effective parameter that controls snow sub-pixel variability. Firstly, we evaluate tundra snow depth spatial variability using probability density functions (log-normal and gamma) and its parameters, μ_{sd} and CV_{sd} . Secondly, we present from in-situ observations distinct snow microstructure and density values of both tundra main layers (depth hoar and wind slab), mean ratios of layer thickness and the depth hoar fraction (DHF) relative to snow depth. Finally, we perform a Gaussian process fit to estimate DHF from snow depth and used probability density functions of snow depth to add variation of snow depth and microstructure within the footprint. Then we compare mean pixel snow properties simulations with simulations of sub-pixel variation in snow properties to evaluate biases between measured T_B from a satellite sensor at 37 GHz, and T_B simulated by inversion of a radiative transfer model.

5.2 Methods

5.2.1 Study site

Data were collected in two regions of the Canadian Arctic, with different topography and vegetation yielding different snow depth distributions. Trail Valley Creek (TVC) research watershed, Northwest Territories ($68^{\circ}44' N$, $133^{\circ}33' W$), located at the southern edge of arctic shrub-tundra, is dominated by herbaceous tundra and dwarf shrubs and characterized by gently rolling hills with steep slopes. Greiner Lake watershed, Cambridge Bay (CB), Nunavut ($69^{\circ}13' N$, $104^{\circ}53' W$), located within arctic tundra, is characterized by dwarf shrub and calcareous tills on upland sites with gently rolling hills and small ponds and lakes. TVC is considered to have more sub-arctic attributes with predominant vegetation than CB given its proximity to the Northern edge of the boreal forest. Topographic maps (Figure 5-1; ArcticDEM), show slightly higher variation

in elevation at TVC with plateau and steep slopes compared to CB which is dominated by ponds and small variation in topography.

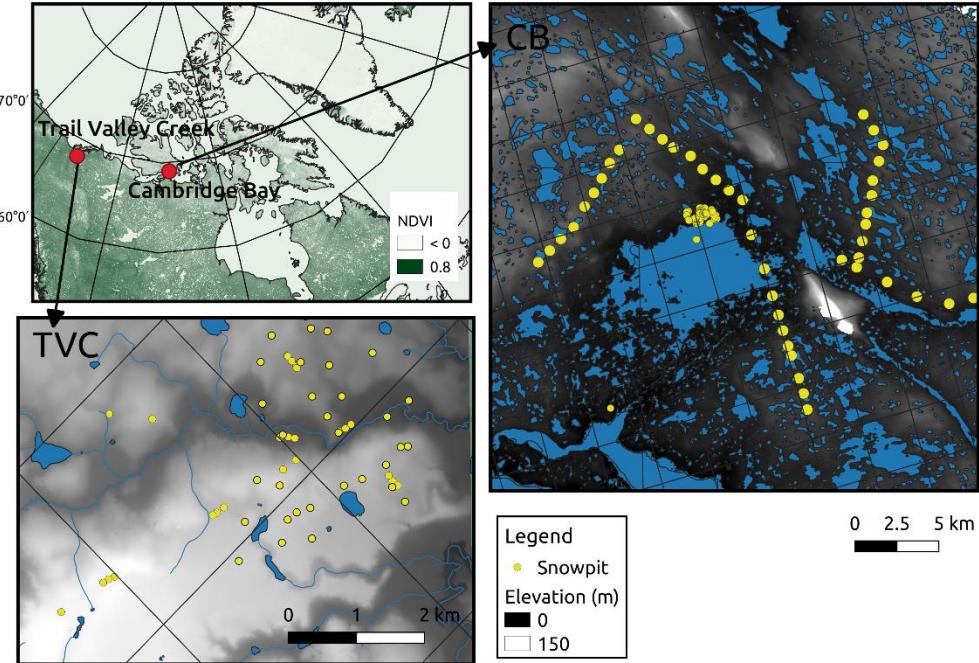


Figure 5-1: Locations of study areas in the Canadian Arctic, Cambridge Bay and Trail Valley Creek site. Grid shown is the enhanced 3.125 km EASE grid 2.0 used for satellite data. The ArcticDEM is a 2 m-resolution (Morin et al., 2016) derived from stereo high-resolution visible imagery for the entire Arctic domain, freely available.

5.2.2 Data

Snow pits (315) at each site (TVC: 68, CB: 248) provided information on snow layering, vertical profiles of geophysical properties (includes temperature, grain type classification, hardness, density, microstructure, and depth). Measurements of visual stratigraphy and grain type classification was conducted following Fierz et al. (2009). Density was measured using 100 cm³ density cutters and digital scales. Snow specific surface area (SSA) was measured using an InfraRed Integrating Sphere (IRIS) (Montpetit et al., 2012) in Cambridge Bay, and an A2 Photonic Sensors IceCube in TVC, both based on 1300 nm laser reflectometry (Gallet et al., 2009). Snow depth measurements, linear transects and circular transect around snow pits, used a magnaprobe from SnowHydro LLC (Sturm and Holmgren, 2018), which is equipped with a standard GPS unit. Measured snow depth distributions were used to identify subsequent pit locations (on site) from a

predefined transect across CB watershed in order to ensure the snow pit locations were representative of wider spatial variability (Table 5-1). For TVC, pit locations were chosen based on previous snow depth distribution (2016), slope and elevation. Multiple snow depth maps at 1m resolution from Remotely Piloted Aircraft System (RPAS) surveys derived from photogrammetry conducted in March 2018 (Walker et al., 2020) were used to estimate snow depth distribution in TVC with total spatial coverage of 5.3 km². An airborne Lidar dataset of TVC snow depths (93 km² at 10 m resolution) collected by an aircraft in April 2013 (Rutter et al., 2019) was also used. Monte Carlo simulations of both the μ_{sd} and CV_{sd} were performed on each snow depth map. Simulations randomly selected pixels as the center of a circular mask with a random radius. The mask was used to select all pixels within the circle so the statistical parameters (μ_{sd} and CV_{sd}) could be calculated. Also, a small RPAS map was available for CB with spatial coverage of 0.2 km² at 1 m resolution. Maps of normalized difference vegetation index (NDVI) were created from Sentinel-2 (10 m resolution) images from late summer (2019-09-01 for TVC and 2019-09-08 for CB).

Table 5-1: Summary of number of snow depth measurements (Magnaprobe and RPAS) and snow pit sites per year. The availability of SSA and density measurements across sites and years are also noted (x). See Table 5-2 for full dates.

Site	Date	Depth Measurement	Snowpit	SSA	Density
TVC	March 15 -25, 2019	8541	32	x	x
	March 15 -23, 2018	7190	36	x	x
TVC18-RPAS	March 12- April 22, 2018	Pixels : 6 325 365 Resolution: 1 m			
TVC13-Lidar	April, 2013	Pixels : 969 168 Resolution: 10 m			
CB18-RPAS	April 15, 2018	Pixels : 72 902 Resolution: 1 m			
CB	April 15-29, 2019	982	64	x	x
	April 12-24, 2018	-	50	x	x
	May 1-8, 2017	4045	51		x
	April 2-10, 2016	3403	35		x
	April 9-16, 2015	12 282	48		x

5.2.3 Measured brightness temperatures and Snow Microwave Radiative Transfer (SMRT)

Microwave T_B were used to evaluate simulations from SMRT at 37 GHz and 19 GHz from the Special Sensor Microwave/Imager and Sounder (SSMIS) sensor, with the Equal-Area Scalable Earth (EASE) 2.0 grid resampled at 3.125 km (6.25 km for 19 GHz) resolution (Brodzik et al., 2018), for both TVC and CB regions. T_B were estimated by averaging all pixels within snow pit area (CB: 24 pixels, TVC: 8 pixels for 37 GHz). Each pixel with at least one snow pit inside was used. Since all snow pits were aggregated to obtain mean value and distribution of snow properties for SMRT, averaged T_B covering the snow pits area was used.

The area was also filtered to remove any contribution from sea or deep lakes, as pixels with liquid water exhibit large biases even if the signal at 37 GHz is mostly sensitive to snow (Derksen et al., 2012). For CB, an area with the same spatial coverage but a slightly different location was used since the snow pit area was within 25 km (full resolution of SSMIS) from the ocean. T_B were temporally averaged to match times of field measurements, representing peak winter snow accumulation (Table 5-2). Also, T_B were corrected for atmospheric contributions using the linear relation with precipitable water from the 29 atmospheric NARR layers (Vargel et al., 2020; Roy et al., 2013).

A multi-layered snowpack radiative transfer model (SMRT, Picard et al., 2018) as used to simulate snow emission at 37 and 19 GHz. Model inputs are snow temperature, density and microstructure of each snow layer. Correlation length of snow microstructure in each layer was estimated from mean density and SSA measurements of each layer when available (wind slab: WS and depth hoar: DH) using Debye's equation scaled by a factor ($\kappa_{37} = 1.39, \kappa_{19} = 1.71$) for arctic snow as suggested by Eq. (3b) and (4) in Vargel et al. (2020) with the Improved Born Approximation (IBA-Exp) configuration. Soil emission was simulated using the Wegmüller and Mätzler (1999) model with permittivity and roughness values from a field study of frozen soil emission based in CB (Meloche et al., 2020). The soil parameters from CB (Meloche et al., 2020) closely match values from a study in TVC (King et al., 2018) and were used for both sites simulation. The lakes in CB shown in Figure 5-1 were not considered in the soil emission contribution because most of the

water was frozen ($\epsilon' \approx 4\text{-}6$) (Mironov et al., 2010), which had a similar permittivity to frozen soil ($\epsilon' \approx 2\text{-}4$) (Mavrovic et al., 2021) than liquid water ($\epsilon' > 25$).

The basal layer temperature was set to the mean soil-DH interface measurements from snow pits of each site. The temperature of the WS layer was estimated from the North American Regional Reanalysis (NARR) air surface temperature, which closely matched snow pit surface layer temperature. NARR air surface temperatures were used because it provides a global estimate that matches spatial coverage of the EASE grid, which is continuous (spatially and temporally) compared to the sparse snow pit observations.

Table 5-2: Summary of mean basal and air surface temperatures for SMRT simulations, precipitable water (PWAT) used for atmospheric correction and measured (corrected) T_B at both polarization vertical (V) and horizontal (H) by the SSMIS sensor (platform F18).

Sites	T_{base} (K)	$T_{surface}$ NARR (K)	PWAT (mm)	T_B 37H (K)	T_B 37V (K)
CB (April 15-29, 2019)	257	261.5	3.61	195.3	211.0
CB (April 12-24, 2018)	257	260.1	3.72	179.3	195.7
CB (May 1-8, 2017)	263	261.3	3.33	187.1	205.0
CB (April 2-10, 2016)	256	258.8	2.80	190.1	215.4
CB (April 9-16, 2015)	254	256.2	2.34	193.0	215.9
TVC (March 15 -25, 2019)	266	261.8	7.04	177.0	199.5
TVC (March 15 -23, 2018)	264	261.8	4.21	176.6	197.6

5.2.4 Gaussian Processes

Gaussian Processes (GP) are a non-parametric Bayesian method used in regression models. These processes are effective and flexible tools to fit complex functions with small training datasets (Quiñonero-Candela and Rasmussen, 2005). Gaussian processes provide uncertainties on predictions, using training data and prior distributions to produce posterior distributions for predictions. Mean ($m(x)$) and covariance ($k(x, x')$) functions from the multi-variate Gaussian distribution are used to fit data (x: snow depth, y: ratio of layers). The $m(x)$ function describes the expected value of the distribution and the $k(x, x')$ describes the shape of the correlation between data points (x_i). Different mean and covariance kernels can be chosen to fit the data. From Bayes

rule in Eq. (5.1) where y (ratio of layer) and X (snow depth) are observed data and f the GP function, posterior predictions of ratios of layers can be produced. Posterior predictions were calculated using the standard method of Markov Chain Monte Carlo (MCMC) sampling using PyMC3 (Salvatier et al., 2016).

$$\text{Posterior} = \frac{\text{Likelihood} \cdot \text{Prior}}{\text{Marginal likelihood}} = p(f|y, X) = \frac{p(y|X, f) \cdot p(f)}{p(y|X)} \quad (5.1)$$

$$f(x) \approx \text{GP}(m(x), k(x, x'), \phi(x)) \quad (5.2)$$

Equation 5.2 defined f as a function of $m(x), k(x, x')$. A mean function $m(x)$, following an inverse logic function (ϕ) (Eq. 5.3), was chosen due to the close fit with observations. The covariance function $k(x, x')$ is a Gaussian white noise covariance function and is defined with noise (σ) and the Kronecker delta function ($\delta_{x,x'}$) (Eq. 5.4), to best fit the observations. By using a scaling function (ϕ), the covariance function (uniform noise in this case) can be modified as a function of x . The scaling function used is also an inverse logic function (ϕ) that takes the same form as Eq. (5.3). Finally, a deterministic transformation is applied to the prior (GP) to constrain values to a ratio (0,1). The likelihood of DHF observation is defined by a Beta distribution (0,1).

$$m(x) = \phi(x) = c + b \left[\frac{e^{a(x-x_0)}}{1 + e^{a(x-x_0)}} \right] \quad (5.3)$$

$$k(x, x') = \sigma^2 \delta_{x,x'} \phi(x) \quad (5.4)$$

5.3 Results

5.3.1 Snow depth distribution

Distributions of snow depth are needed when integrating over large areas to calculate sub grid snow variability for distributed models (Clark et al., 2011; Liston, 2004). The μ_{sd} and the CV_{sd} of snow depth are used as parameters in probability density functions to estimate the shape of the log-normal and gamma distributions. To find which distribution best fits the depth observations,

we tested the log-normal and gamma distributions using the Kolmogorov-Smirnov two sample test with snow depth observations (shown in blue in Figure 5-2). The statistical fits for each distribution are shown in Table 5-3. For both the log-normal and gamma distributions the null hypothesis is validated at the 5% significance level from p-value > 0.05 (i.e. the two samples were drawn from the same distribution), which agrees with previous assessments of Arctic snow (Clark et al., 2011; Gisnas et al., 2016).

Table 5-3: Kolmogorov-Smirnov (KS) test for 2 samples of probability distribution function (PDF).

Site	PDF	KS stats	p-value
TVC	log-normal	0.029	0.41
	gamma	0.039	0.11
CB	log-normal	0.024	0.63
	gamma	0.017	0.95

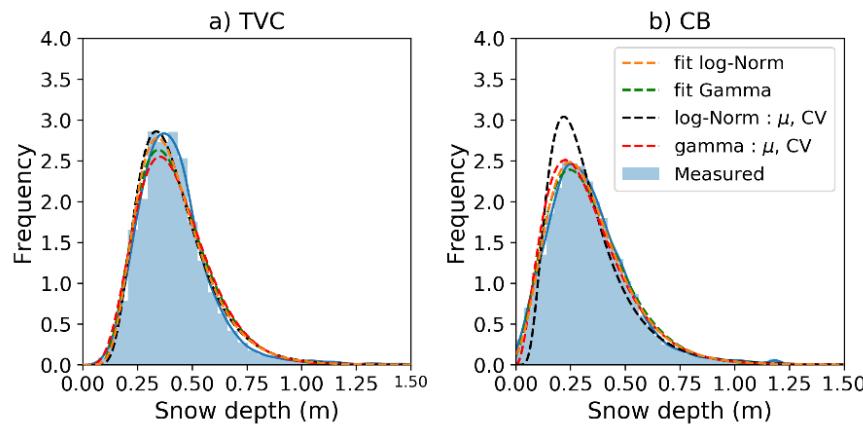


Figure 5-2: Log-normal and gamma distribution fit to the measured snow depths.

Distributions with parameterization using measured μ_{sd} and CV_{sd} (Figure 5-2) differ from the best fit with regular parameters, especially compared with log-normal distribution in CB (black dashed line in Figure 5-2b). Liston (2004) reported CV_{sd} of 0.4 for Arctic tundra snow, which is in close agreement with the values of 0.43 for TVC and 0.56 for CB. These values were also obtained from spatially distributed snow depth measurements around snow pits. For comparison, maps of snow depth from RPAS for TVC ($n = 6\ 325\ 365$ with total spatial coverage of $5.3\ km^2$) showed a much

larger $CV_{sd} = 0.78$ than magnaprobe data ($n=15\ 731$) with $CV_{sd} = 0.43$ (Table 5-4). A RPAS dataset was also available for CB but with a much smaller spatial coverage ($0.2\ km^2$) showing a CV_{sd} of 0.49. In Figure 5-4, we investigated the relationship between spatial coverage of sampling and the CV_{sd} parameter. Datasets include RPAS-derived data at TVC (TVC18-RPAS) containing 6 areas with various size from 1- 3 km^2 , CB18-RPAS map of $0.2\ km^2$ and the larger Lidar-derived snow map in TVC (TVC13-Lidar). Figure 5-3a shows snow accumulation of TVC13-Lidar and TVC18-RPAS with snow drift visible in dark blue and Sub-grid of $1km^2$ showed areas with high CV_{sd} (Figure 5-3b) containing more drift. For both areas, 500 Monte Carlo simulations were performed by randomly selecting sub-regions within each domain (Figure 5-4) so the mean and variability as a function of coverage could be investigated. Simulations showed sub-sampling of μ_{sd} and CV_{sd} converged to the values of the full area. The mean of each area was similar in value with less variation in the simulations compared to CV_{sd} . A difference of 0.2 between the full CV_{sd} of the RPAS ($5\ km^2$) and Lidar ($93\ km^2$) maps (Figure 5-4) was found. Also included in Figure 5-4 are in-situ CV_{sd} estimate with variable high-density sampling (magnaprobe) over different spatial extents at Daring Lake, NWT (Derksen et al., 2009; Rees et al., 2014), Puvirnituq, QC (Derksen et al., 2010) and at Eureka, NU (Saberi et al., 2017). The two points at the limit coverage scale correspond to areas of respectively $625\ km^2$ ($CV_{sd} = 1$; Daring Lake site; C. Derksen personal communication) and $198\ km^2$ ($CV_{sd} = 0.89$, Eureka site; Saberi et al., 2007).

Table 5-4: Statistical parameters of snow depth distributions.

Site	n	μ (m)	σ (m)	CV_{sd}
TVC19	8 541	0.44	0.14	0.33
TVC18	7 190	0.39	0.21	0.54
TVC	15 731	0.42	0.19	0.43
TVC18-RPAS	6 325 365	0.46	0.36	0.78
TVC13-Lidar	969 168	0.40	0.23	0.58
CB19	982	0.42	0.17	0.40
CB18	577	0.34	0.18	0.53
CB18-RPAS	7290	0.39	0.19	0.49
CB17	4 045	0.42	0.19	0.46
CB16	3 403	0.28	0.16	0.61
CB15	12 282	0.32	0.18	0.57
CB	20 712	0.36	0.18	0.52

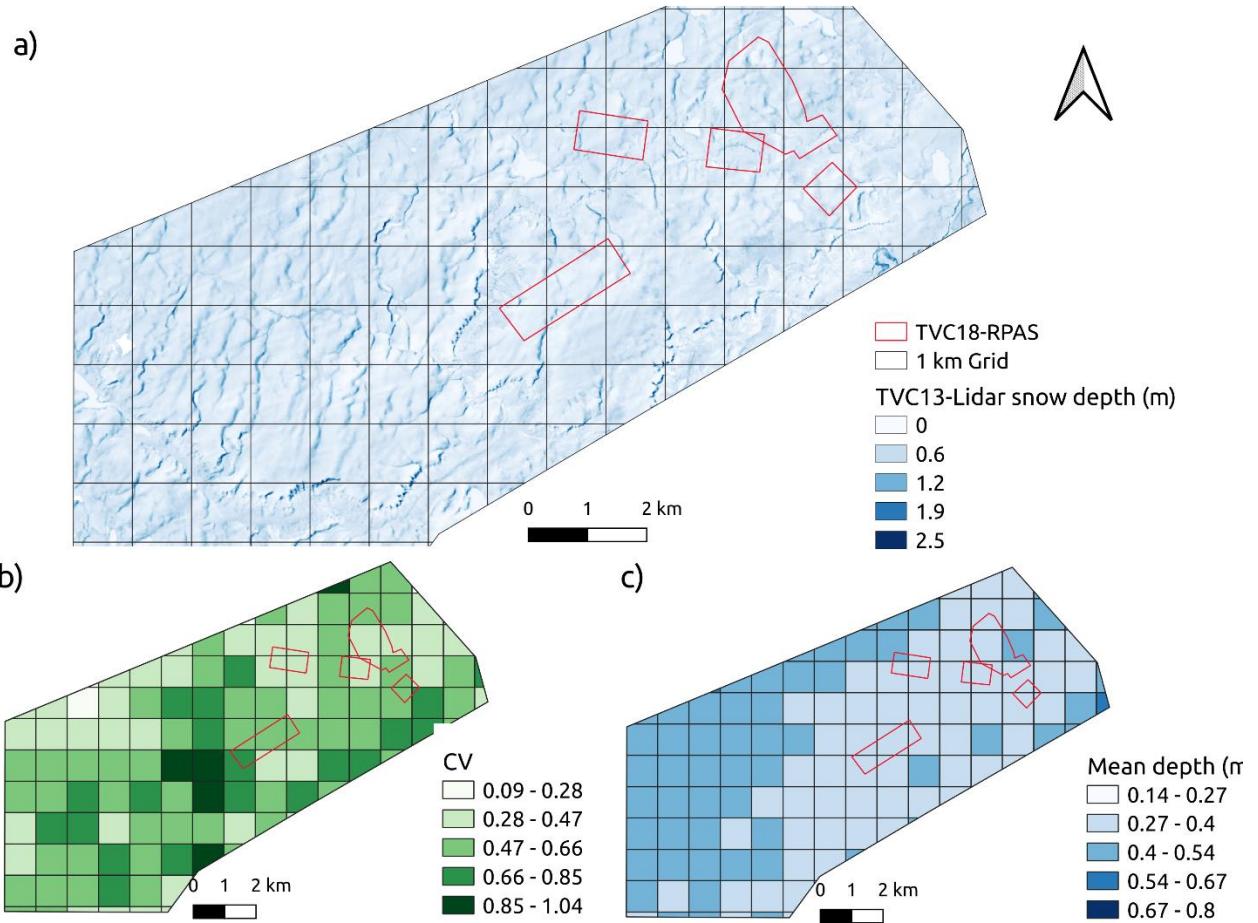


Figure 5-3: RPAS and Lidar dataset of snow depth at TVC (TVC13-Lidar and TVC18-RPAS). TVC13-Lidar is the largest dataset covering 93 km². TVC18-RPAS is a smaller dataset within the area of TVC13-Lidar. In a) is shown the snow depth map at 10 m resolution from 2013. b) shows a sub grid of 1 km with CV_{sd} for each cell; c) same as b) but for μ_{sd} .

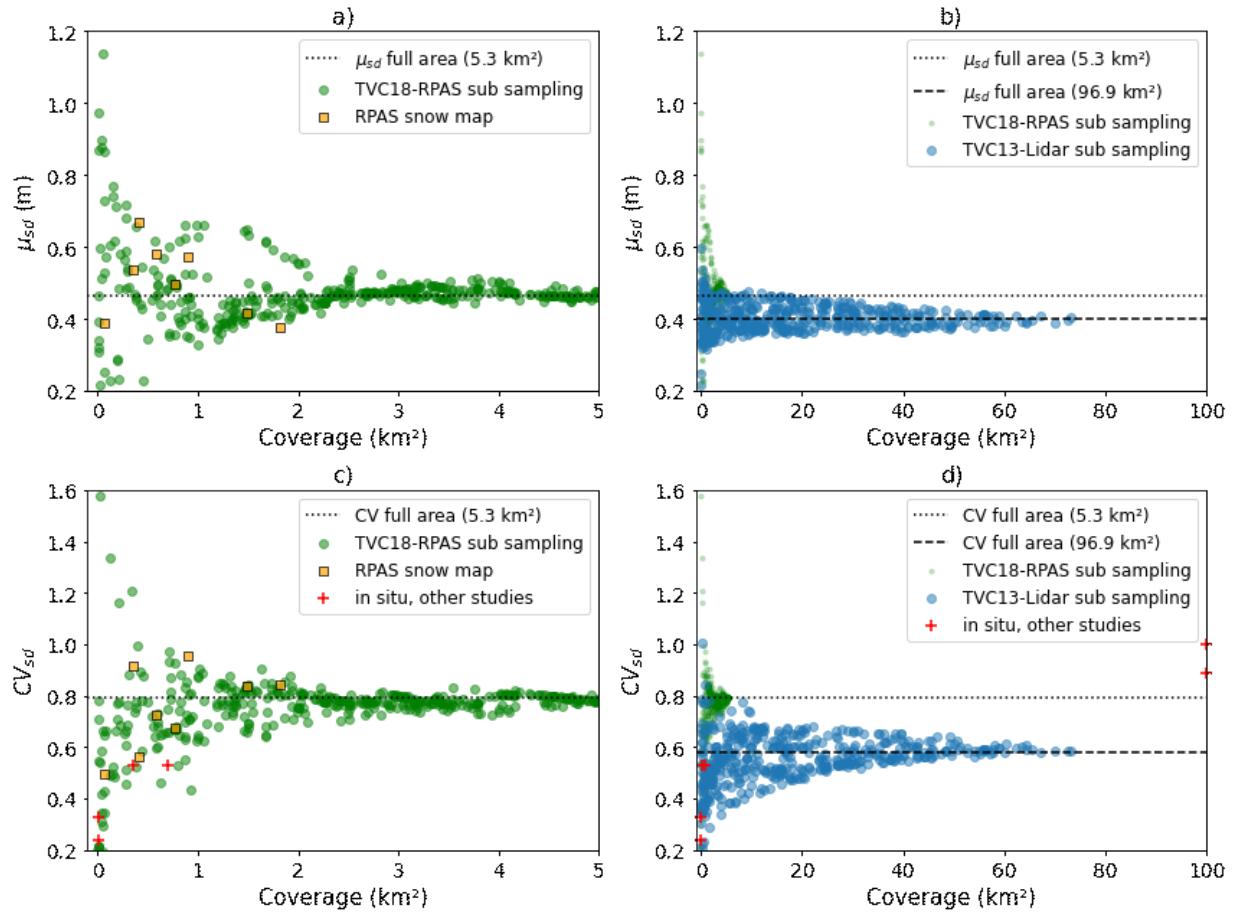


Figure 5-4: Snow depth mean (μ_{sd}) (a and b) and variability (CV_{sd}) (c and d) as a function of coverage for sampling area: a) and c) small area, b) and d) large area. Monte Carlo simulations were done using the two datasets in TVC. CB18-RPAS was also added in a) because of the similar coverage. The μ_{sd} and CV_{sd} of both full areas are shown by the black dotted and dashed line.

5.3.2 Analysis of SSA and density per layer

After combining measurements from all snow pits at TVC and CB ($n = 315$) the mean proportion of DH layer thickness was 46% and WS was 54%. The goal was to classify DH as large grain snow (large facets, depth hoar cups and chains), then all other snow layers above the DH as wind slab (WS). Some layers were more difficult to classify as they contained mixed crystals or were a transitional slab-to-hoar layer (also referred to as indurated hoar) (Sturm et al., 2008). Slab that contained small faceted crystals (< 2 mm) were classified as WS. Indurated hoar, a wind slab metamorphosed into depth hoar, was classified into DH with a typical density $\sim 300 \text{ kg} \cdot \text{m}^{-3}$. Because of this reason, the peak of each distribution appeared close to each other in Figure 5-5 c) and d). For retrieval of snow properties using satellite remote sensing, a 2 layer model using WS

and DH can be used to simplify much of the layer complexity found in arctic snowpacks (Rutter et al., 2019; Saberi et al., 2017). A small amount of surface fresh snow (SS) was present in some pits but was not included in this calculation as this type of snow was a short-lived layer, combining fresh precipitation that rapidly transformed into rounded grains due to destructive metamorphism and defragmentation by wind. Distributions of SSA are more distinct between layers than density (Figure 5-5 a and b), c.f. Rutter et al. (2019). Figure 5-5 c) and d) show that the mean values for density of WS ($335 \text{ kg} \cdot \text{m}^{-3}$) and DH ($266 \text{ kg} \cdot \text{m}^{-3}$) were closer together. SSA distributions also showed a gap between both mean values (WS: $19.7 \text{ m}^2 \text{kg}^{-1}$ and DH: $11.1 \text{ m}^2 \text{kg}^{-1}$) (Figure 5-5, Table 5-5). Even if snow properties can show high heterogeneity at local scales, simple distributions approximate this variability well. Temporal (year) and spatial (regional between site) variation is low and snow properties (density and SSA) can be approximated by a distribution for each distinct layer, WS and DH as in Figure 5-5. Therefore, snow properties were simplified in distributions for each layer (WS and DH) representing tundra snow.

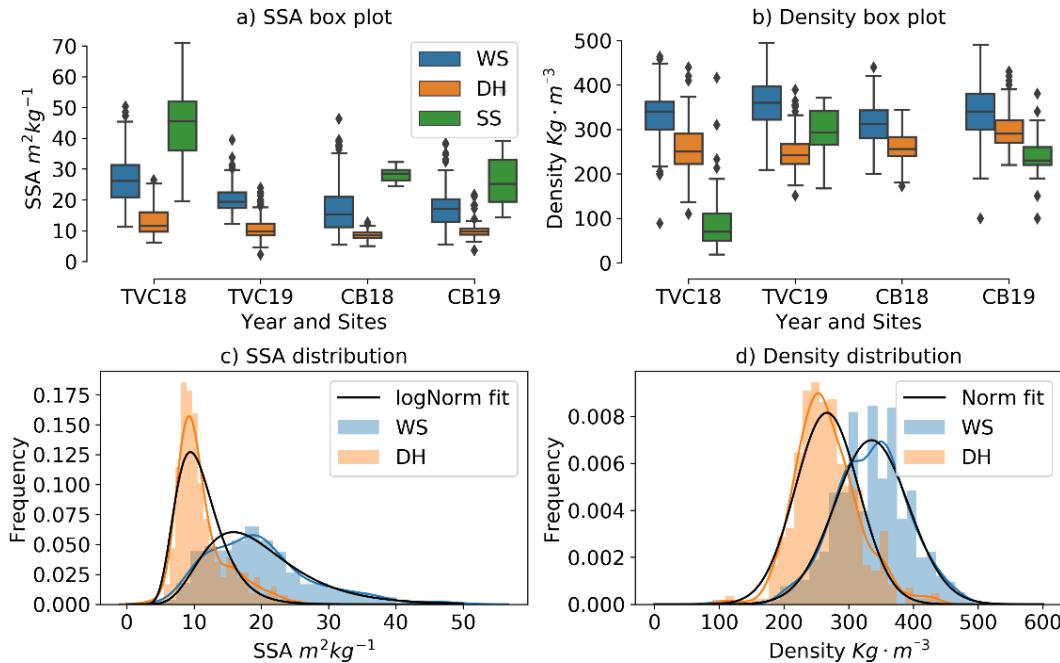


Figure 5-5: SSA and density variability of Surface Snow (SS), Wind Slab (WS) and Depth Hoar (DH) for the two studied sites (TVC and CB) and different dates (see Table 5-5). In c) the best log-normal fit distribution is shown in black; d) same as c) but for the normal fit distribution. In c) and d), the kernel density estimates (KDE) of the histogram of each layer are also shown (in color).

Table 5-5: Parameters for best fitting distribution of SSA and density for layers of DH and WS.

Snow property	Best fit PDF	μ		σ
		DH	WS	
SSA ($m^2 kg^{-1}$)	log-normal	11.1	3.8	
		19.7	7.8	
Density ($kg m^{-3}$)	normal	μ	σ	
		DH 266.3	48.9	
		WS 335.2	57.1	

Parr et al. (2020) found a key threshold of $\mu_{sd} + 1\sigma_{sd}$ to define snow drifts in tundra environments. This threshold $> 0.6 - 0.8$ m, based on data presented in Table 5-4, is an important metric in Figure 5-6 since above this depth, the variability and the mean DHF is greatly reduced as the snowpack is dominated by wind slab for larger depth (drift). As defined in Parr et al. (2020), the transported snow from wind accumulates at these particular locations (drift) where it was scoured from wind affected area yielding lower depth with high DHF.

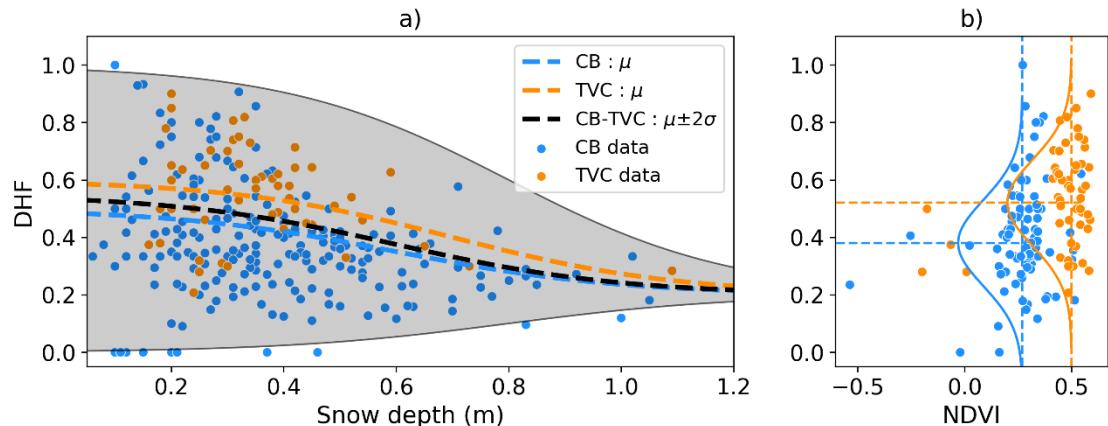


Figure 5-6: a) Depth hoar fraction (DHF) as a function of total depth for snow pit data from 2015-2019 in Cambridge Bay and 2018-2019 for Trail Valley Creek. Both datasets were separated in equal bins (10 cm) to estimate the mean value shown with dashed line. The black line represents the mean for both site with the 95% interval. b) DHF is shown as a function of NDVI from the snowpit area with the mean DHF and NDVI per sites shown by dashed lines and the gaussian distributions of DHF by the solid lines.

Vegetation also strongly influences variability of DHF in shallower snowpacks, where arctic shrubs and tussocks promote depth hoar formation (Domine et al., 2016; Royer et al., 2021; Sturm et al., 2001). However, there is no clear link between DHF and NDVI (a proxy for vegetation type) at local scales (Figure 5-6b). Since shrubs provide shelter to snow up to their own height (Gouttevin et al., 2018), vegetation height rather than type would be required. However, at the regional scale, differences were evident between both regions, where mean NDVI and DHF are greater at TVC (NDVI = 0.5, DHF = 0.54) than CB (NDVI = 0.27, DHF = 0.38). This finding is in agreement with Royer et al. (2021) over a northeastern latitudinal gradient, showing that sites with shrubs and tussocks have a greater DHF than those without.

5.3.3 DHF predictions using snow depth with Gaussian Processes

The impact on microwave scattering of variability of layer microstructures with snow depth was previously accounted for in Saberi et al. (2020) by defining two categories, a high scattering thin snow layer (high DHF) and a thicker self-emitting layer (low DHF). Instead, using GP, DHF were fitted and predicted based on snow depth values (Figure 5-7). In order to use GP, the mean function $m(x)$, following an inverse logic function (ϕ_1 : Eq. 3), was chosen with parameters: $a = -5$, $x_0 = 0.6$, $b = 0.35$ and $c = 0.2$ to best match the mean line observation for both sites in Figure 5-6. The mean function set the mean value across the snow depth range. The correlation function was set to a uniform noise, but this noise was reduced from depth > 40 cm by using a scaling function (ϕ_2 : $a=-5$, $x_0 = 0.6$, $b = 1.5$ and $c = 0.25$). An inverse logic function (ϕ_1, ϕ_2) was used twice in the fitting 1) for the mean value and 2) to reduce the variability (noise) as snow depth increased. The snow pit dataset ($n = 315$, Figure 5-6) was used to build posterior predictions using MCMC sampling.

For prediction of DHF, any number of snow depths can feed into the posterior prediction or GP fit. Snow depths were generated from a log-normal distribution with parameters (μ_{sd} , CV_{sd}) from previous section in Table 5-4. Posterior predictions of DHF were similar to observed data (Figure 5-7) and followed closely posterior probability representation in red (GP fit). Again, higher variability in DHF was reproduced for depths < 0.5 m, which was then reduced for depths > 0.5 m following the red posterior prediction representation in Figure 5-7.

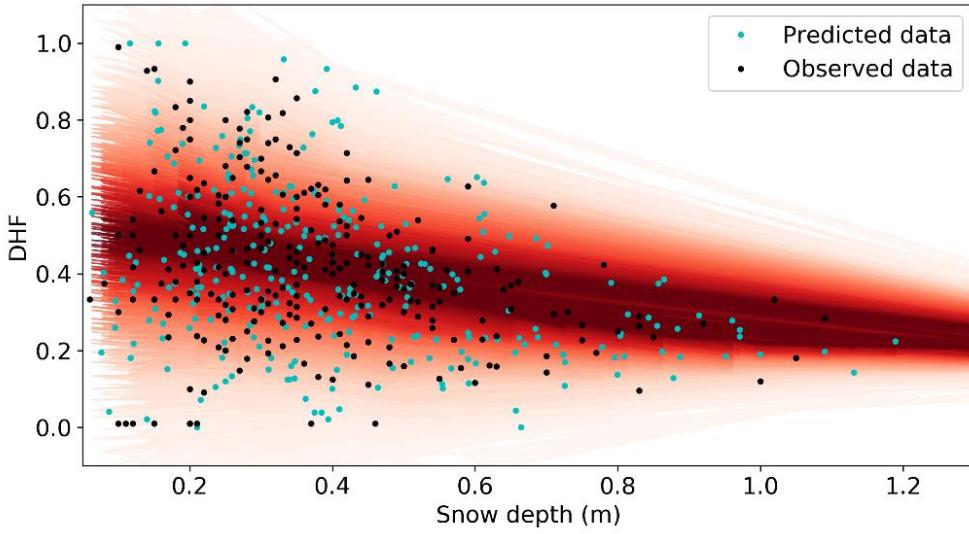


Figure 5-7: Prediction on DHF (cyan) using a GP fit trained on observed data (black). Snow depth were samples from a log-normal distribution with parameters from Table 5-4: Statistical parameters of snow depth distributions.. The GP fit is illustrated in red where darker red represents high posterior probability that follows the mean function.

5.3.4 SMRT simulation of sub-grid variability within sensor footprint

SMRT simulations using measured snowpack properties were compared with the satellite measurements of T_B . Two simulations were evaluated using: 1) mean measured depth, each layer's density and SSA, and DHF, and 2) a log-normal distribution of snow depth and the GP fit (predicted DHF). We hypothesized that the EASE 2.0 grid pixel can be separated into n smaller sub-grid pixels. Sub-grid pixels ($n = 500$) represent the observed snow variability, where n snow depths will follow a log-normal distribution with parameters μ_{sd} and CV_{sd} . The ratio of each layer is predicted using the GP fit with depth as input from the log-normal distribution. Mean SSA (DH: $11 \text{ m}^2\text{kg}^{-1}$, WS: $20 \text{ m}^2\text{kg}^{-1}$) and density (DH: 266 kg m^{-3} , WS: 335 kg m^{-3}) per layer were determined from measurements (Figure 5-5).

For one standard EASE-grid pixel, a distribution of sub-grid T_B were simulated to reproduce a realistic distribution of T_B within the radiometer footprint. This variability was derived from spatially distributed observations from snow pits and snow depths observation. Snow depths followed a log-normal distribution with the mean measured depth (μ_{sd}) of each region (Table 5-4)

and a depth variability (CV_{sd}) that was evaluated from a range of 0.1 to 1. The GP mean function from Figure 5-7 was used to predict the DHF for each region. When using $CV_{sd} = 0.7$, the simulated distribution showed a wide sub-pixel variability (± 40 K) with a mean value of $T_{B37V} = 194.7$ K (blue line in Figure 5-8a), very close to the satellite-measured T_{B37V} of 196.5 K (green dotted line in Figure 5-8a). In this case, the T_B value simulated from the mean measured snow depth and mean DHF was slightly lower (190.7 K, i.e., a bias of 5.8 K) (black dotted line in Figure 5-8a). To represent the signal measured by the sensor, the mean of the simulated T_B was chosen and it was assumed that the sub-pixels effect combined linearly at this scale. Because the simulated T_{B37V} distribution was not exactly a normal distribution, it appeared that the mean T_B of this distribution increased when CV_{sd} increased (Figure 5-8b). This meant that snow depth variability (CV_{sd}) must be accounted for when estimating the average T_B at 37 GHz, in addition to the mean snow depth values. The influence of the GP simulation on the mean simulated T_{B37V} was approximately 10 K (Figure 5-8b) as CV_{sd} varies from 0.1 to 1. The addition of snow variability in simulation (Figure 5-8c and d) of 19 GHz has negligible effect on T_{B19} and shows a constant simulation across the CV_{sd} range of 0.1 to 1. Simulation of T_{B19} shows higher biases at horizontal polarization than vertical polarization.

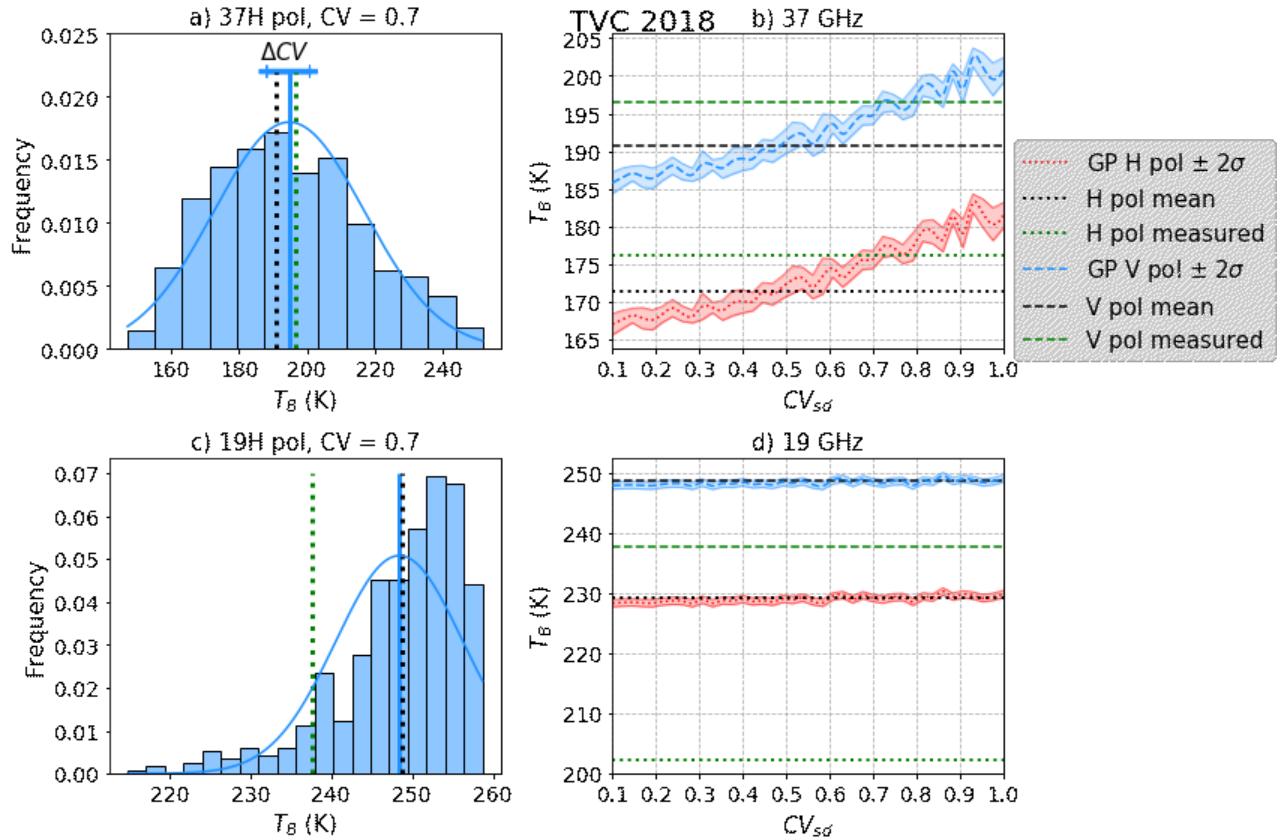


Figure 5-8: Brightness temperature variability simulation a) and c) distribution of simulated T_B within a pixel, where vertical lines represent the mean of this distribution for V pol (blue), measured by satellite (green) and T_B value simulated from the mean measured snow depth and mean DHF (black). In b) and d), the mean of the simulated T_B for H pol (red) and V pol (blue) as a function of CV_{sd} with mean values (dotted black lines). The CV_{sd} that minimized biases is located at the red/blue-green intersection. Shaded blue and red areas correspond to a 2σ range representing uncertainty inherent from our Bayesian simulations in estimating the mean of simulated T_B for the pixel.

GP simulation reduced biases by 5 K with a higher optimized CV_{sd} (intersection of red/blue - green line, Figure 5-8b). A similar pattern was observed for CB (not shown here) but the measured T_B at CB was much higher than the GP simulation resulting in large bias for CB (~20 K) compared to TVC (Table 5-6). Both sites suggested a larger CV_{sd} , which agreed with a CV_{sd} for larger spatial coverage measured in Figure 5-4. Observed large biases at CB vary over the years from 5 K to 29 K. The total RMSE of both sites and years linearly decreased as a function of CV_{sd} (Figure 5-9). Total RMSE is minimized with higher CV_{sd} (0.8-0.9) typical of large sampling scale (over 4 km²) as shown in Figure 5-4.

Table 5-6: Bias between SMRT simulated and measured Tb from SSMIS sensor at each site.

SMRT simulation type	Year	Bias (K)				RMSE (K)	
		CB		TVC			
		H pol	V pol	H pol	V pol	H pol	V pol
mean depth and DHF	2019	28.2	25.9	6.9	10.3	17.8	19.1
	2018	8.0	5.3	5.1	6.8		
	2017	19.9	18.9	-	-		
	2016	16.9	23.2	-	-		
	2015	24.7	29.1	-	-		
GP simulation CV = 0.9	2019	18.6	15.7	-4.4	-1.2	9.7	10.4
	2018	-3.7	-6.2	-4.9	-3.2		
	2017	10.4	9.3	-	-		
	2016	7.1	13.5	-	-		
	2015	10.0	13.9	-	-		

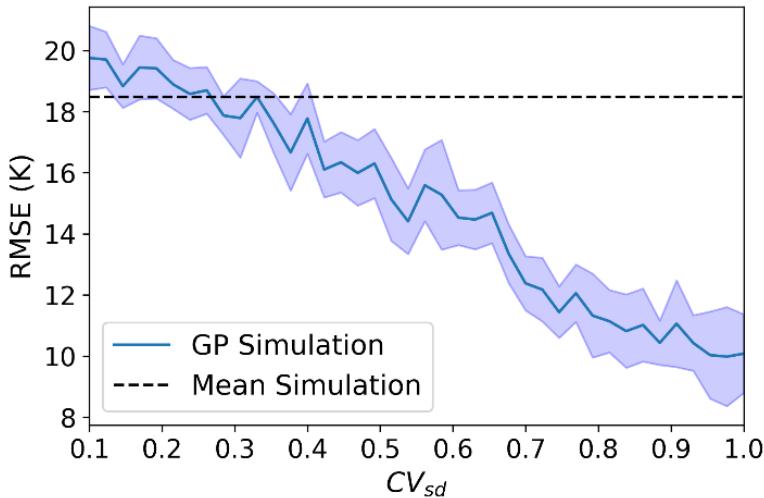


Figure 5-9: Overall RMSE (year and site) with the mean simulation (dashed black line) and the GP simulation in blue as a function of the coefficient of variation of snow depth.

5.4 Discussion

We show that as spatial coverage increased, the CV_{sd} parameter converged to the full area values (Figure 5-4). Monte Carlo simulations of snow depth distribution and coverage show high variation in CV_{sd} (from 0.1 to 2) for areas $< 10 \text{ km}^2$. Snow accumulation varied at the meso scale

(100 m to 10 km) due to topography and vegetation (Pomeroy et al., 2002) by varying wind-flow direction (Liston and Sturm, 1998). At the meso scale, variability in CV_{sd} was high due to topographic differences; plateau, slope and valley create favorable conditions from wind flow direction to promote snowdrift, scour and sublimation processes (Parr et al., 2020; Rutter et al., 2019). Vegetation facilitates snow holding capacities by decreasing wind speed near the ground within and downwind of shrub (Marsh et al., 2010; Sturm et al., 2001). Some areas include both extreme drifts and thin snow, resulting in high CV_{sd} (dark green areas in Figure 5-3b) which are commonly found in TVC (Walker et al., 2020). CV_{sd} was lower for areas without drifts (light green areas in Figure 5-3b). In areas $> 10 \text{ km}^2$ (Figure 5-4d), variation in CV_{sd} was reduced and yielded higher values > 0.6 .

Convergence to higher CV_{sd} as spatial coverage increased matched the PMW optimized values found in this study using GP simulation (0.8 – 1.0). Our analysis in Figure 5-4d showed that CV_{sd} of TVC13-Lidar converged to 0.6 at 93 km^2 , but two in situ points from other studies at 625 km^2 had higher CV_{sd} (0.9-1) due to larger coverage or different site characteristics. This indicates that a CV_{sd} between 0.6-1.0 is more suitable to represent snow depth variability in SWE retrievals for PMW SWE products at 25 km for the EASE GRID 2.0 and 625 km^2 for GlobSnow 3.0 (Pulliainen et al., 2020). For active sensors (resolution $< 1 \text{ km}$), the high variability in CV_{sd} under 1 km^2 due to high variation in snow depth (Figure 5-4b) can affect back scattering since active sensor at Ku band is also sensitive to volume scattering (King et al., 2018). The need for prediction of μ_{sd} and CV_{sd} based on topography could become essential at these scales not only for microwave remote sensing but also to improve snow modelling or land data assimilation (Kim et al., 2021).

Spatial complexities of Arctic snowpacks can be adequately characterized with distributions of snow depth (Figure 5-2) and simplified by considering density and SSA of two main layers (Figure 5-5). Such simplifications could be potentially useful for satellite SWE retrievals across Arctic tundra regions. Since Bayesian SWE optimization needs a strong first guess from regional *a priori* information, multiple distributions of snow depth, density and SSA presented here can be used for tundra type snow in MCMC sampling (Pan et al., 2017; Saberi et al., 2020). Additionally, a similar approach to our GP simulation can be added so the CV_{sd} parameter can also be used as *a priori*

information with a distribution from 0.8 to 1, since it improved T_B RMSE by ~ 8 K (Figure 5-9). This approach improved T_B simulation compared to using only mean values of snowpack properties by adding variability within the footprint. The CV_{sd} parameter (describing variation in snow depth) has a considerable effect on brightness temperature (10 K) when used as an effective parameter to account for sub-pixel variability of snow depth. The amount of scatterers (snow grain and structure) within the radiometer's footprint is adjusted via the DHF predicted from snow depth (CV_{sd}). The relationship found in Figure 5-6 used to predict DHF (Figure 5-7) could also be used deterministically with the mean function (ϕ_1) or with a linear relation of DHF decreasing from 50% to 20%. However, the Bayesian gaussian process was used because SWE retrievals are currently implemented in a Bayesian framework (Takala et al., 2011).

Considering that the difference between 19 and 37 GHz is used in SWE retrievals (Takala et al., 2011), using the CV_{sd} to account for variability of scatterers only affected simulation of 37 GHz with weak effect on 19 GHz (Figure 5-8). If standard deviation of snow increases (more drift) then relatively fewer large scatterers from depth hoar are present within the footprint due to a low DHF generally observed in large drifts. The net result is then an increase in T_B at 37 GHz resulting from an increase in CV_{sd} (Figure 5-8).

This idea of modulating the amount of scatterers based of DHF prediction and a distribution of snow depth (μ_{sd} and CV_{sd}) can be extended to future active Ku-band mission (Garnaud et al., 2019; King et al., 2018) as it known that microwave spatial variability affects backscatter signal (King et al., 2015) and SWE retrievals (Vander Jagt et al., 2013). The CV_{sd} parameter is proposed as an effective parameter to account for variability inside the grid cell, while the mean depth (μ_{sd}) is assimilated by in situ measurements at weather stations in data assimilation schemes (Takala et al., 2011), or by physical snow model (Larue et al., 2018). The CV_{sd} could be optimized or predicted using relationships with spatial coverage (Figure 5-4) and statistical topographic regression (Grünewald et al., 2013). Future works would need dataset covering large area where μ_{sd} and CV_{sd} could be investigated with topography in smaller sub areas.

5.5 Conclusion

This study evaluated the use of parameters controlling Arctic snow depth distributions to improve passive microwave SWE retrievals by characterizing tundra snow sub-pixel variability. In shrub and graminoid tundra environments, mean values of snow depths ($\mu_{sd} = 0.33\text{-}0.44$ m) and coefficient of variations ($CV_{sd} = 0.4\text{-}0.8$) were similar to those previously reported in Arctic tundra (Derksen et al., 2014; Liston, 2004; Sturm et al., 2008). Monte Carlo simulations were applied to investigate μ_{sd} and CV_{sd} as a function of spatial coverage. An increase in CV_{sd} matched increased spatial coverage of snow depth sampling, indicating that a higher CV_{sd} (0.6-0.9) is more suited to estimate snow depth variation at the 3.125 km resolution EASE-Grid 2.0. Also, simulations show high variation in CV_{sd} (> 0.9) for areas $< 10 \text{ km}^2$ suggesting a need for topography-based prediction of μ_{sd} and CV_{sd} at this scale. The CV_{sd} is shown to be an effective parameter to account for snow depth variability in simulation of snow T_B . A two-layer snowpack model (depth hoar and surface wind slab), which simplifies snowpack properties into distributions, was used to initialize the SMRT model via a GP fit of the DHF related to snow depth. DHF is fitted to snow depth using a Bayesian Gaussian Process, which accounts for variation in snow scattering using CV_{sd} . SMRT simulation was used successfully to simulate satellite T_B , but there is still substantial uncertainties in the simulated values which are likely linked to microstructural properties not captured by SSA (Krol and Löwe, 2016). SMRT simulations of T_B were reduced by 8 K after optimizing CV_{sd} to higher values (0.8-1.0), thereby matching CV_{sd} of spatially distributed snow depth from TVC18 – RPAS accounting for variation in snow properties inside the footprint of satellite sensor. The CV_{sd} parameter is proposed as an effective parameter to account for variability inside the footprint to minimize the difference between microwave measurements and simulations in SWE retrievals algorithm. This would be beneficial to the data assimilation scheme of the European Space Agency: GlobSnow product (Takala et al., 2011) and to model large scale climate trend of tundra snow (Mortimer et al., 2020; Pulliainen et al., 2020).

Data and codes availability

Data and code for the gaussian process fit and GP simulation are available:

https://github.com/JulienMeloche/Gaussian_process_smrt_simulation.

RPAS map and magnaprobe from TVC are available:

<https://doi.org/10.5683/SP2/PWSKKG>.

Author contributions

JM: Formal analysis, Investigation and writing - original draft preparation, AL: Writing – review & editing, Supervision, Investigation, Funding acquisition and Resources, NR: Writing – review & editing, Supervision, Investigation, AR: Writing – review & editing, Supervision, Investigation, JK: Writing – review & editing, Data acquisition, BW: Writing – review & editing, Data acquisition, PM: Data acquisition, EW: Data acquisition

Acknowledgements

The authors would like to thank the entire GRIMP research team from Université de Sherbrooke and CHARS staff team for field work assistance from 2015-2019 in Cambridge Bay. We thank Phil Marsh (Wilfrid Laurier University), Chris Derksen and Peter Toose (Environment and Climate Change Canada) for logistics and field work at Trail Valley Creek Research Station. We also thank Victoria Dutch from Northumbria University for her help with dataset management of TVC.

Financial support

This research was made possible thanks to the financial support of the Natural Sciences and Engineering Research Council of Canada (NSERC), Polar Knowledge Canada, the Canadian Foundation for Innovation (CFI), Environment and Climate Change Canada (ECCC), Fonds de recherche du Québec – Nature et technologies (FRQNT), Northern Scientific Training Program (NSTP) and research funding from Northumbria University, UK.

Competing Interests

The authors declare that they have no conflict of interest.

References

- Brodzik, M.J., Long, D.G., Hardman, M.A., 2018. Best practices in crafting the calibrated, Enhanced-Resolution passive-microwave EASE-Grid 2.0 brightness temperature Earth System Data Record. *Remote Sens. Environ.* 10. <https://doi.org/10.3390/rs10111793>
- Chang, A.T.C., Foster, J.L., Hall, D.K., Rango, A., Hartline, B.K., 1982. Snow water equivalent estimation by microwave radiometry. *Cold Reg. Sci. Technol.* [https://doi.org/10.1016/0165-232X\(82\)90019-2](https://doi.org/10.1016/0165-232X(82)90019-2)
- Clark, M.P., Hendrikx, J., Slater, A.G., Kavetski, D., Anderson, B., Cullen, N.J., Kerr, T., Örn Hreinsson, E., Woods, R.A., 2011. Representing spatial variability of snow water equivalent in hydrologic and land-surface models: A review. *Water Resour. Res.* 47. <https://doi.org/10.1029/2011WR010745>
- Derksen, C., Lemmetyinen, J., Toose, P., Silis, A., Pulliainen, J., Sturm, M., 2014. Physical properties of Arctic versus subarctic snow: Implications for high latitude passive microwave snow water equivalent retrievals. *J. Geophys. Res. Atmos.* 119, 7254–7270. <https://doi.org/10.1002/2013JD021264>
- Derksen, C., Sturm, M., Liston, G.E., Holmgren, J., Huntington, H., Silis, A., Solie, D., 2009. Northwest Territories and Nunavut snow characteristics from a subarctic traverse: Implications for passive microwave remote sensing. *J. Hydrometeorol.* 10, 448–463. <https://doi.org/10.1175/2008JHM1074.1>
- Derksen, C., Toose, P., Lemmetyinen, J., Pulliainen, J., Langlois, A., Rutter, N., Fuller, M.C., 2012. Evaluation of passive microwave brightness temperature simulations and snow water equivalent retrievals through a winter season. *Remote Sens. Environ.* 117, 236–248. <https://doi.org/10.1016/j.rse.2011.09.021>
- Derksen, C., Toose, P., Rees, A., Wang, L., English, M., Walker, A., Sturm, M., 2010. Development of a tundra-specific snow water equivalent retrieval algorithm for satellite passive microwave data. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2010.02.019>
- Domine, F., Barrere, M., Morin, S., 2016. The growth of shrubs on high Arctic tundra at Bylot Island: Impact on snow physical properties and permafrost thermal regime. *Biogeosciences* 13, 6471–6486. <https://doi.org/10.5194/bg-13-6471-2016>
- Domine, F., Picard, G., Morin, S., Barrere, M., Madore, J.-B., Langlois, A., 2018. Major Issues in Simulating some Arctic Snowpack Properties Using Current Detailed Snow Physics Models. Consequences for the Thermal Regime and Water Budget of Permafrost. *J. Adv. Model. Earth Syst.* <https://doi.org/10.1029/2018MS001445>
- Durand, M., Liu, D., 2012. The need for prior information in characterizing snow water equivalent from microwave brightness temperatures. *Remote Sens. Environ.* 126, 248–257. <https://doi.org/10.1016/j.rse.2011.10.015>
- Fierz, C., Armstrong, R.L., Durand, Y., Etchevers, P., Greene, E., McClung, D.M., Nishimura, K., Satyawali, P.K., Sokratov, S. a., 2009. The international classification for seasonal snow

- on the ground. UNESCO, IHP–VII, Tech. Doc. Hydrol. No 83; IACS Contrib. No 1 80.
- Gallet, J.C., Domine, F., Zender, C.S., Picard, G., 2009. Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm. *Cryosphere* 3, 167–182. <https://doi.org/10.5194/tc-3-167-2009>
- Garnaud, C., Bélair, S., Carrera, M.L., Derksen, C., Bilodeau, B., Abrahamowicz, M., Gauthier, N., Vionnet, V., 2019. Quantifying Snow Mass Mission Concept Trade-Offs Using an Observing System Simulation Experiment. *J. Hydrometeorol.* 20, 155–173. <https://doi.org/10.1175/jhm-d-17-0241.1>
- Gisnas, K., Westermann, S., Vikhamar Schuler, T., Melvold, K., Etzelmüller, B., 2016. Small-scale variation of snow in a regional permafrost model. *Cryosphere* 10, 1201–1215. <https://doi.org/10.5194/tc-10-1201-2016>
- Gouttevin, I., Langer, M., Löwe, H., Boike, J., Proksch, M., Schneebeli, M., 2018. Observation and modelling of snow at a polygonal tundra permafrost site: Spatial variability and thermal implications. *Cryosphere* 12, 3693–3717. <https://doi.org/10.5194/tc-12-3693-2018>
- Grünewald, T., Stötter, J., Pomeroy, J.W., Dadic, R., Moreno Baños, I., Marturià, J., Spross, M., Hopkinson, C., Burlando, P., Lehning, M., 2013. Statistical modelling of the snow depth distribution in open alpine terrain. *Hydrol. Earth Syst. Sci.* 17, 3005–3021. <https://doi.org/10.5194/hess-17-3005-2013>
- Kelly, R., 2009. The AMSR-E Snow Depth Algorithm : Description and Initial Results. *J. Remote Sens. Soc. Japan* 29, 307–317. <https://doi.org/10.11440/rssj.29.307>
- Kelly, R.E., Chang, A.T., Tsang, L., Foster, J.L., 2003. A prototype AMSR-E global snow area and snow depth algorithm. *IEEE Trans. Geosci. Remote Sens.* <https://doi.org/10.1109/TGRS.2003.809118>
- Kim, R.S., Kumar, S., Vuyovich, C., Houser, P., Lundquist, J., Mudryk, L., Durand, M., Barros, A., Kim, E.J., Forman, B.A., Gutmann, E.D., Wrzesien, M.L., Garnaud, C., Sandells, M., Marshall, H.-P., Cristea, N., Pflug, J.M., Johnston, J., Cao, Y., Mocko, D., Wang, S., 2021. Snow Ensemble Uncertainty Project (SEUP): quantification of snow water equivalent uncertainty across North America via ensemble land surface modeling. *Cryosph.* 15, 771–791. <https://doi.org/10.5194/tc-15-771-2021>
- King, J., Derksen, C., Toose, P., Langlois, A., Larsen, C., Lemmetyinen, J., Marsh, P., Montpetit, B., Roy, A., Rutter, N., Sturm, M., 2018. The influence of snow microstructure on dual-frequency radar measurements in a tundra environment. *Remote Sens. Environ.* 215, 242–254. <https://doi.org/10.1016/j.rse.2018.05.028>
- King, J., Kelly, R., Kasurak, A., Duguay, C., Gunn, G., Rutter, N., Watts, T., Derksen, C., 2015. Spatio-temporal influence of tundra snow properties on Ku-band (17.2 GHz) backscatter. *J. Glaciol.* 61, 267–279. <https://doi.org/10.3189/2015JoG14J020>
- Krol, Q., Löwe, H., 2016. Relating optical and microwave grain metrics of snow: The relevance of grain shape. *Cryosphere* 10, 2847–2863. <https://doi.org/10.5194/tc-10-2847-2016>

- Larue, F., Royer, A., De Sève, D., Roy, A., Cosme, E., 2018. Assimilation of passive microwave AMSR-2 satellite observations in a snowpack evolution model over northeastern Canada. *Hydrol. Earth Syst. Sci.* 22, 5711–5734. <https://doi.org/10.5194/hess-22-5711-2018>
- Liljedahl, A.K., Boike, J., Daanen, R.P., Fedorov, A.N., Frost, G. V., Grosse, G., Hinzman, L.D., Iijima, Y., Jorgenson, J.C., Matveyeva, N., Necsoiu, M., Reynolds, M.K., Romanovsky, V.E., Schulla, J., Tape, K.D., Walker, D.A., Wilson, C.J., Yabuki, H., Zona, D., 2016. Pan-Arctic ice-wedge degradation in warming permafrost and its influence on tundra hydrology. *Nat. Geosci.* <https://doi.org/10.1038/ngeo2674>
- Liston, G.E., 2004. Representing subgrid snow cover heterogeneities in regional and global models. *J. Clim.* 17, 1381–1397. [https://doi.org/10.1175/1520-0442\(2004\)017<1381:RSSCHI>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<1381:RSSCHI>2.0.CO;2)
- Liston, G.E., Sturm, M., 1998. A snow-transport model for complex terrain. *J. Glaciol.* <https://doi.org/10.1017/S0022143000002021>
- Mavrovic, A., Pardo Lara, R., Berg, A., Demontoux, F., Royer, A., Roy, A., 2021. Soil dielectric characterization during freeze-Thaw transitions using L-band coaxial and soil moisture probes. *Hydrol. Earth Syst. Sci.* 25, 1117–1131. <https://doi.org/10.5194/hess-25-1117-2021>
- Meloche, J., Royer, A., Langlois, A., Rutter, N., Sasseville, V., 2020. Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry. *Int. J. Digit. Earth* 0, 1–17. <https://doi.org/10.1080/17538947.2020.1836049>
- Mironov, V.L., De Roo, R.D., Savin, I. V., 2010. Temperature-dependable microwave dielectric model for an arctic soil. *IEEE Trans. Geosci. Remote Sens.* 48, 2544–2556. <https://doi.org/10.1109/TGRS.2010.2040034>
- Montpetit, B., Royer, A., Langlois, A., Cliché, P., Roy, A., Champollion, N., Picard, G., Domine, F., Obbard, R., 2012. New shortwave infrared albedo measurements for snow specific surface area retrieval. *J. Glaciol.* 58, 941–952. <https://doi.org/10.3189/2012JoG11J248>
- Mortimer, C., Mudryk, L., Derksen, C., Luoju, K., Brown, R., Kelly, R., Tedesco, M., 2020. Evaluation of long-term Northern Hemisphere snow water equivalent products. *Cryosphere* 14, 1579–1594. <https://doi.org/10.5194/tc-14-1579-2020>
- Pan, J., Durand, M.T., Vander Jagt, B.J., Liu, D., 2017. Application of a Markov Chain Monte Carlo algorithm for snow water equivalent retrieval from passive microwave measurements. *Remote Sens. Environ.* 192, 150–165. <https://doi.org/10.1016/j.rse.2017.02.006>
- Parr, C., Sturm, M., Larsen, C., 2020. Snowdrift Landscape Patterns: An Arctic Investigation. *Water Resour. Res.* 56. <https://doi.org/10.1029/2020WR027823>
- Picard, G., Sandells, M., Löwe, H., 2018. SMRT: An active-passive microwave radiative transfer model for snow with multiple microstructure and scattering formulations (v1.0). *Geosci. Model Dev.* 11, 2763–2788. <https://doi.org/10.5194/gmd-11-2763-2018>
- Pomeroy, J.W., Gray, D.M., Hedstrom, N.R., Janowicz, J.R., 2002. Prediction of seasonal snow

- accumulation in cold climate forests. *Hydrol. Process.* 16, 3543–3558. <https://doi.org/10.1002/hyp.1228>
- Proksch, M., Löwe, H., Schneebeli, M., 2015. Density, specific surface area, and correlation length of snow measured by high-resolution penetrometry. *J. Geophys. Res. Earth Surf.* 120, 346–362. <https://doi.org/10.1002/2014JF003266>
- Pulliainen, J., 2006. Mapping of snow water equivalent and snow depth in boreal and sub-arctic zones by assimilating space-borne microwave radiometer data and ground-based observations. *Remote Sens. Environ.* 101, 257–269. <https://doi.org/10.1016/j.rse.2006.01.002>
- Pulliainen, J., Luojus, K., Derksen, C., Mudryk, L., Lemmetyinen, J., Salminen, M., Ikonen, J., Takala, M., Cohen, J., Smolander, T., Norberg, J., 2020. Patterns and trends of Northern Hemisphere snow mass from 1980 to 2018. *Nature* 581, 294–298. <https://doi.org/10.1038/s41586-020-2258-0>
- Quiñonero-Candela, J., Rasmussen, C.E., 2005. A unifying view of sparse approximate Gaussian process regression. *J. Mach. Learn. Res.*
- Rees, A., English, M., Derksen, C., Toose, P., Silis, A., 2014. Observations of late winter Canadian tundra snow cover properties. *Hydrol. Process.* 28, 3962–3977. <https://doi.org/10.1002/hyp.9931>
- Roy, A., Picard, G., Royer, A., Montpetit, B., Dupont, F., Langlois, A., Derksen, C., Champollion, N., 2013. Brightness Temperature Simulations of the Canadian Seasonal Snowpack Driven by Measurements of the Snow Specific Surface Area. *IEEE Trans. Geosci. Remote Sens.* 51, 4692–4704. <https://doi.org/10.1109/TGRS.2012.2235842>
- Royer, A., Domine, F., Roy, A., Langlois, A., Marchand, N., Davesne, G., 2021. New northern snowpack classification linked to vegetation cover on a latitudinal mega-transect across northeastern Canada. *Écoscience* 00, 1–18. <https://doi.org/10.1080/11956860.2021.1898775>
- Royer, A., Roy, A., Montpetit, B., Saint-Jean-Rondeau, O., Picard, G., Brucker, L., Langlois, A., 2017. Comparison of commonly-used microwave radiative transfer models for snow remote sensing. *Remote Sens. Environ.* 190, 247–259. <https://doi.org/10.1016/j.rse.2016.12.020>
- Rutter, N., Sandells, M., Derksen, C., Toose, P., Royer, A., Montpetit, B., Langlois, A., Lemmetyinen, J., Pulliainen, J., 2014. Snow stratigraphic heterogeneity within ground-based passive microwave radiometer footprints: Implications for emission modeling. *J. Geophys. Res. Earth Surf.* 119, 550–565. <https://doi.org/10.1002/2013JF003017>. Received
- Rutter, N., Sandells, M.J., Derksen, C., King, J., Toose, P., Wake, L., Watts, T., Essery, R., Roy, A., Royer, A., Marsh, P., Larsen, C., Sturm, M., 2019. Effect of snow microstructure variability on Ku-band radar snow water equivalent retrievals. *Cryosph.* 13, 3045–3059. <https://doi.org/10.5194/tc-13-3045-2019>
- Saberi, N., Kelly, R., Pan, J., Durand, M., Goh, J., Scott, K.A., 2020. The Use of a Monte Carlo Markov Chain Method for Snow-Depth Retrievals: A Case Study Based on Airborne

- Microwave Observations and Emission Modeling Experiments of Tundra Snow. IEEE Trans. Geosci. Remote Sens. 1–14. <https://doi.org/10.1109/TGRS.2020.3004594>
- Saberi, N., Kelly, R., Toose, P., Roy, A., Derksen, C., 2017. Modeling the observed microwave emission from shallow multi-layer Tundra Snow using DMRT-ML. Remote Sens. 9. <https://doi.org/10.3390/rs9121327>
- Salvatier, J., Wiecki, T. V., Fonnesbeck, C., 2016. Probabilistic programming in Python using PyMC3. PeerJ Comput. Sci. <https://doi.org/10.7717/peerj-cs.55>
- Sturm, M., Derksen, C., Liston, G., Silis, A., Solie, D., Holmgren, J., Huntington, H., 2008. A Reconnaissance Snow Survey across Northwest Territories and Nunavut, Canada, April 2007.
- Sturm, M., Holmgren, J., 2018. An Automatic Snow Depth Probe for Field Validation Campaigns. Water Resour. Res. 54, 9695–9701. <https://doi.org/10.1029/2018WR023559>
- Sturm, M., McFadden, J.P., Liston, G.E., Stuart Chapin, F., Racine, C.H., Holmgren, J., 2001. Snow-shrub interactions in Arctic Tundra: A hypothesis with climatic implications. J. Clim. [https://doi.org/10.1175/1520-0442\(2001\)014<0336:SSIIAT>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<0336:SSIIAT>2.0.CO;2)
- Sturm, M., Wagner, A.M., 2010. Using repeated patterns in snow distribution modeling: An Arctic example. Water Resour. Res. 46, 1–15. <https://doi.org/10.1029/2010WR009434>
- Takala, M., Luojus, K., Pulliainen, J., Derksen, C., Lemmetyinen, J., Kärnä, J.P., Koskinen, J., Bojkov, B., 2011. Estimating northern hemisphere snow water equivalent for climate research through assimilation of space-borne radiometer data and ground-based measurements. Remote Sens. Environ. <https://doi.org/10.1016/j.rse.2011.08.014>
- Tsang, L., Chen, C. Te, Chang, A.T.C., Guo, J., Ding, K.H., 2000. Dense media radiative transfer theory based on quasicrystalline approximation with applications to passive microwave remote sensing of snow. Radio Sci. <https://doi.org/10.1029/1999RS002270>
- Vander Jagt, B.J., Durand, M.T., Margulis, S.A., Kim, E.J., Molotch, N.P., 2013. The effect of spatial variability on the sensitivity of passive microwave measurements to snow water equivalent. Remote Sens. Environ. 136, 163–179. <https://doi.org/10.1016/j.rse.2013.05.002>
- Vargel, C., Royer, A., St-jean-rondeau, O., Picard, G., Roy, A., Sasseville, V., Langlois, A., 2020. Remote Sensing of Environment Arctic and subarctic snow microstructure analysis for microwave brightness temperature simulations. Remote Sens. Environ. 242, 111754. <https://doi.org/10.1016/j.rse.2020.111754>
- Walker, B., Wilcox, E.J., Marsh, P., 2020. Accuracy assessment of late winter snow depth mapping for tundra environments using Structure-from-Motion photogrammetry. Arct. Sci. 17, 1–17. <https://doi.org/10.1139/as-2020-0006>
- Wegmüller, U., Mätzler, C., 1999. Rough bare soil reflectivity model. IEEE Trans. Geosci. Remote Sens. 37, 1391–1395. <https://doi.org/10.1109/36.763303>
- Wiesmann, A., Mätzler, C., 1999. Microwave emission model of layered snowpacks. Remote

- Sens. Environ. [https://doi.org/10.1016/S0034-4257\(99\)00046-2](https://doi.org/10.1016/S0034-4257(99)00046-2)
- Winstral, A., Elder, K., Davis, R.E., 2002. Spatial Snow Modeling of Wind-Redistributed Snow Using Terrain-Based Parameters. *J. Hydrometeorol.* 3, 524–538.
[https://doi.org/10.1175/1525-7541\(2002\)003<0524:SSMOWR>2.0.CO;2](https://doi.org/10.1175/1525-7541(2002)003<0524:SSMOWR>2.0.CO;2)
- Winstral, A., Marks, D., 2014. Long-term snow distribution observations in a mountain catchment: Assessing variability, time stability, and the representativeness of an index site. *Water Resour. Res.* 50, 293–305. <https://doi.org/10.1002/2012WR013038>
- Winstral, A., Marks, D., Gurney, R., 2013. Simulating wind-affected snow accumulations at catchment to basin scales. *Adv. Water Resour.* 55, 64–79.
<https://doi.org/10.1016/j.advwatres.2012.08.011>

6 Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry

Auteurs: Julien Meloche, Alain Royer, Alexandre Langlois, Nick Rutter, Vincent Sasseville

Référence complète :

Meloche, J., Royer, A., Langlois, A., Rutter, N. et Sasseville, V. (2020) Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry. International Journal of Digital Earth, vol. 0, n°0, p. 1-17.

Résumé:

L'émission du sol arctique est un paramètre clé pour obtenir les propriétés de surface à partir de mesure de température de brillance (T_B). L'hiver en particulier, la permittivité du sol gelé et sa rugosité sont deux paramètres inconnus qui doivent être considérés. Nous présentons dans cet article que la rugosité 3D du sol après avoir retiré la neige, peut être mesuré à l'aide de l'algorithme de photogrammétrie SfM. L'article se concentre sur l'utilisation de SfM pour procurer des mesures précises de la rugosité et améliorer la paramétrisation de l'émission micro-ondes des sols gelés arctiques pour les applications de modélisation. Une validation l'aide de mesures radiométriques in-situ au sol a été faite aux fréquences 19 et 37 GHz en utilisant trois différents modèles d'émission du sol : le modèle (Weg99) de Wegmüller et Mätzler (1999), le modèle QNH (Wang et Choudhury, 1981) et la solution analytique de géométrie optique. Les T_B mesurées et simulées de différents sites rocheux et de toundra type dans le haut Arctique canadien montre le modèle Weg99, paramétrisé avec une rugosité SfM et une permittivité optimisée (ϵ), donne un RMSE de 3.1 K ($R^2 = 0.71$) pour toutes les fréquences et polarisations. L'approche SfM permet de mesurer la rugosité avec une précision de 0.1 mm à 55 sites de différents types de sol en utilisant une caméra digitale et des règles métalliques de dimensions connues.

Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry

J. Meloche ^{ab*}, A. Royer ^{ab}, A. Langlois ^{ab}, N. Rutter ^c, and V. Sasseville ^{ab}

^a*Département de Géomatique Appliquée, Université de Sherbrooke, Sherbrooke, Canada*

^b*Centre d'études nordiques, Québec, Canada*

^c*Department of Geography and Environmental Sciences, Northumbria University, Newcastle upon Tyne, UK*

This is a published article by Taylor & Francis in International Journal of Digital Earth on October 26, 2020, available at

<http://www.tandfonline.com/doi/full/10.1080/17538947.2020.1836049>

Special issue: Remote Sensing Experiments for Earth System Science

*Corresponding author: Julien Meloche

Abstract

Soil emissivity of Arctic regions is a key parameter for assessing surface properties from microwave brightness temperature (T_b) measurements. Particularly in winter, frozen soil permittivity and roughness are two poorly characterized unknowns that must be considered. Here, we show that after removing snow, the 3D soil roughness can be accurately inferred from in-situ photogrammetry using Structure from Motion (SfM). We focus on using SfM techniques to provide accurate roughness measurements and improve emissivity models parametrization of frozen arctic soil for microwave applications. Validation was performed from ground-based radiometric measurements at 19 and 37 GHz using three different soil emission models: the Wegmüller and Mätzler (1999) model (Weg99), the Wang and Choudhury (1981) model (QNH), and a geometrical optics model (Geo Optics). Measured and simulated brightness temperatures over different tundra and rock sites in the Canadian High Arctic show that Weg99, parametrized

with SfM-based roughness and optimized permittivity (ε), yielded a RMSE of 3.1 K ($R^2 = 0.71$) for all frequencies and polarizations. Our SfM based approach allowed us to measure roughness with 0.1 mm accuracy at 55 locations of different land cover type using a digital camera and metal plates of know dimensions.

Keywords: surface roughness; microwave remote sensing; frozen Arctic soil; SfM photogrammetry

6.1 Introduction

Most research on natural soil reflectivity focuses on soil moisture retrievals at L-band (reviewed by Wigneron et al., 2017) or higher frequencies (Njoku et al., 2003). Soil permittivity values are key parameters that allows retrieval of soil moisture using soil emissivity models such as those developed by Zhang et al. (2010) and Mironov et al. (2017). However, active and passive microwave dielectric sensitivity to soil moisture is strongly reduced by surface roughness that must be known or derived in the retrieval processing. During Arctic winter, surface parametrization is more difficult due to the presence of snow cover, and significant lingering uncertainties remain, specifically regarding required soil characteristics that are challenging to quantify in the Arctic.

Large scale monitoring of snow properties in the Canadian Arctic using both active and passive microwave has been conducted in the past (reviewed by Saberi et al., 2020 and Shi et al., 2016) using measurement inversions based on radiative transfer models (Picard et al. 2013; Royer et al. 2017). These models must consider contributions from both snow and ground to simulate total backscatter or emission, particularly over northern areas with shallow snow cover (Roy et al. 2013; Derksen et al. 2014; B. Montpetit et al. 2018). Several soil microwave models integrated into the Snow Microwave Radiative Transfer Model (SMRT) (Ghislain Picard, Sandells, and Löwe 2018) allow simulation of soil emissivity, but many uncertainties are associated with the permittivity and roughness of frozen ground (Montpetit et al. 2018). Models used for forward retrievals of soil parameters with satellite remote sensing are usually semi-empirical for the purposes of simplicity. For instance, the Soil Moisture Active and Passive mission (SMAP) retrieval algorithms use the QNH model, named for its parameters, Q, N, and H, to simulate surface reflectivity following Wang et al. (1983) and Wang and Choudhury (1981). More recently, the parameters in the QNH model were optimized by different studies (Wigneron et al. 2001; Lawrence et al. 2013; Montpetit et al. 2015). Of particular relevance, the roughness parameters needed for the QNH model consist of effective parameters that were found to have smaller values than the actual physical measurements (Tsang and Newton, 1982; Ulaby et al., 1982). Another semi-empirical model (Wegmüller and Mätzler, 1999), developed for a wider range of applications (1-100 GHz), was derived from the QNH model using a simpler Kirchhoff approximation (Mo, Schmugge, and Wang 1987). Montpetit et al. (2018) parametrized permittivity and roughness using the Wegmüller and

Mätzler (1999) semi-empirical model by optimizing surface-based radiometer multi-angle measurements of frozen soils in a subarctic environment in northern Québec, Canada, for higher frequencies (19 and 37 GHz) needed for snow application. Theoretical permittivity can also be calculated using the two models stated earlier: (Zhang et al., 2010 and Mironov et al., 2017).

Surface reflectivity can be solved analytically using the Kirchhoff approximation or the Small Perturbation Method (SPM) with its associated bi-static coefficient. However, this requires a more detailed knowledge of the surface to determine which regime of scattering is involved (e.g. rough surface with geometrical optics). Other analytical solutions like Integral Equation Model (IEM or AIEM) (Fung 1994) can be used to simulate surface reflectivity. Finally, numerical methods solving Maxwell's equation using the Finite Element Method (FEM) or Method of Moments (MoM) (Lawrence et al. 2011; Tsang et al. 2013, 2017) can be used to calculate the scattered electric field from a rough surface, but they are more complex and computationally intensive than the models described above.

Another issue in soil microwave modelling is how to measure the soil roughness and link it to microwave sensitivity. The most common parameter used to describe roughness is height standard deviation (σ_H), but it can also be described by horizontal correlation length (l_c). Soil roughness parameters can be measured directly using a needle profiler (Trudel et al. 2010) or indirectly with terrestrial laser approaches (Martinez-Agirre et al. 2019; Turner et al. 2014; Zheng et al. 2014), which allow more complex 3D analysis. Recent studies using Structure-from-Motion (SfM), a technique that couples photogrammetry with artificial intelligence, have shown promising results in producing 3D models for various geoscience applications (Bühler et al. 2017; Westoby et al. 2012; Lejot et al. 2007). This method was recently tested over agricultural fields to provide roughness parameters (Gharechelou, Tateishi, and Johnson 2018; Martinez-Agirre et al. 2019; Snapir, Hobbs, and Waine 2014). Martinez-Agirre et al. (2019) showed that SfM photogrammetry can accurately provide roughness measurement comparable to high precision terrestrial laser scanner for agricultural fields. Also, it is common to see successful comparison of SfM with LIDAR or laser scanner used as reference in various applications outside roughness estimates (Nolan, Larsen, and Sturm 2015; Westoby et al. 2012; Murtiyoso et al. 2017). While the

capabilities to measure “geometric roughness” was validated by these experiments, we focused more on “radiometric” roughness. We hypothesize here that SfM can deliver accurate roughness parameters to improve microwave radiative transfer models, which is the central focus of this paper.

This paper presents a comparison of three soil emissivity models using roughness parameters derived from SfM: QNH, Wegmüller and Mätzler (1999), hereafter noted Weg99, and the analytical solution of geometrical optics, hereafter noted Geo Optics. We first present an approach to measure surface roughness using photogrammetry (SfM) and then evaluate the use of SfM roughness measurements with different permittivity values and three radiative transfer models of frozen soil. Model results are then validated against in-situ radiometric measurements over different land cover types in Cambridge Bay, NT, Canada.

6.2 Background

The emissivity of a surface (e_p) can be calculated using reciprocity and energy conservation concepts (Eq. 6.1). The brightness temperature of soil ($T_{B_{soil}}$) (Eq. 6.2) is defined by the product of e_p and the effective temperature of the surface (T_{soil}^{eff}). For $T_{B_{soil}}$, the downward atmospheric contribution ($T_{B_{atmo}\downarrow}$) is taken into account for ground observations only following:

$$e_p = 1 - \Gamma_p \quad (6.1)$$

$$T_{B_{soil}}(f, p) = (1 - \Gamma_{f,p})T_{soil}^{eff} + \Gamma_{f,p}T_{B_{atmo}\downarrow} \quad (6.2)$$

where the p and f indices are respectively for polarization and frequency and Γ_p the reflectivity.

6.2.1 Permittivity model of Zhang et al. (2010)

Emissivity calculation requires known permittivity or dielectric constant of the medium. It can be calculated, for example, using the semi-empirical equation from Dobson et al. (1985). Zhang et al.

(2003;2010) adapted Dobson et al. (1985) equation for frozen soil by adding ice fraction in soil with a transition between liquid to solid water as a function of temperature. The inputs needed are frequency, soil moisture, temperature, dry bulk density and soil composition described by percentage of clay, silt and sand.

6.2.2 QNH

The QNH reflectivity model is a semi-empirical model (Wang et al., 1983; Wang and Choudhury, 1981) that uses Fresnel reflectivity with a polarization ratio and a roughness attenuation factor to simulate the reflectivity of random rough surface Γ_p (Eq. 6.3-4) for both horizontal and vertical polarizations,

$$\Gamma_H = [(1 - Q_R)\Gamma_H^{Fresnel}(\theta, \varepsilon) + Q_R\Gamma_V^{Fresnel}(\theta, \varepsilon)]e^{-H_R \cos^N H(\theta)} \quad (6.3)$$

$$\Gamma_V = [(1 - Q_R)\Gamma_V^{Fresnel}(\theta, \varepsilon) + Q_R\Gamma_H^{Fresnel}(\theta, \varepsilon)]e^{-H_R \cos^N V(\theta)} \quad (6.4)$$

Multiple studies have optimized the original values for the parameters of the QNH model, Q_R , N_H , N_V and H_R , and provided different formulations of H_R (J.-P. Wigneron, Laguerre, and Kerr 2001; Lawrence et al. 2013). For instance, Montpetit et al. (2015) found values of Q_R , N_H , N_V , H_R for the frequency range 1-90 GHz based on PORTOS-93 dataset (J.-P. Wigneron, Laguerre, and Kerr 2001) because QNH is mostly used for L-band (1.4 GHz) and not for higher frequencies (19 and 37 GHz). However, Montpetit et al. (2015) parameters were not used because high biases for H polarization in our simulations led us to use the value proposed by Wang et al. (1983). Therefore, we used the following: $N_H = N_V = 0$ and $Q_R = 0$ was changed to $Q_R = 0.9$ with the roughness parameter H_R from Eq. 6.5 proposed by Choudhury et al. (1979) where k is the wavenumber, provided best fit with our observations.

$$H_R = (2k\sigma_H)^2 \quad (6.5)$$

6.2.3 Weg99 model

The Weg99 model (Wegmüller and Mätzler, 1999) is semi-empirical and used over a wider range of applications in the 1-100 GHz frequency range. It mixes the functionality and simplicity of the

QNH model with a theoretical background from a parametrization based on Kirchhoff's approximation (Mo and Schmugge, 1987). Weg99 also uses Fresnel reflectivity of smooth surfaces and a polarization ratio (β_f) but a different roughness attenuation function based on the wavenumber (k), height standard deviation (σ_H) and incident angle (θ). Surface reflectivity in Weg99 is described by (Eq. 6.6) where the vertically polarized reflectivity is a function of the horizontal reflectivity (Eq. 6.7).

$$\Gamma_H = \Gamma_H^{Fresnel}(\theta, \varepsilon) e^{-(k\sigma_H)^{\sqrt{0.1\cos\theta}}} \quad (6.6)$$

$$\Gamma_V = \Gamma_H (\cos\theta)^{\beta_f} \quad (6.7)$$

Wegmüller and Mätzler (1999) originally proposed a single parameter $\beta_f = 0.655$ however, we followed the approach of Montpetit et al. (2018) who suggested using a β_f per frequency based on observations at 11, 19 and 37 GHz (see Table 6-1 for values). Eq. 6.6 and Eq. 6.7 are valid for $\theta \leq 60^\circ$, which is the case for this study.

6.2.4 Geo Optics solution

The analytical solution of emissivity at polarization q of a random rough surface can be solved by integrating the bi-static coefficient γ_{pq} over the upper hemisphere (Eq. 6.8) (Tsang, Kong, and Ding 2000), where the bi-static coefficient under the Geo Optics solution is described by Eq. (6.9) (Kong and Tsang, 2001). Geo optics solution is characterized by a very rough surface yielding the coherent scattering component to vanish. The rough surface is described using a Gaussian autocorrelation function with a mean square slope ($m = 2\sigma_H^2/l_c^2$) where σ_H and correlation length l_c can both be measured by SfM photogrammetry.

$$e_q(\theta_i, \phi_i) = 1 - \Gamma_q = 1 - \frac{1}{4\pi} \sum_{p=p,q} \int_0^{\frac{\pi}{2}} d\theta \sin\theta \int_0^{2\pi} d\phi \gamma_{pq}(\theta, \phi, \theta_i, \phi_i) \quad (6.8)$$

$$\gamma_{pq}(\hat{k}_i, \hat{k}_s) = \frac{|k_d|^4}{\cos\theta_i |\hat{k}_i \times \hat{k}_s|^4 k_{dz}^4 2m} e^{-\frac{k_{dx}^2 + k_{dy}^2}{2k_{dz}^2 m}} f_{pq} \quad (6.9)$$

A more detailed description of $f_{pq}, \hat{k}_i, \hat{k}_s, k_d, k_{dx}, k_{dy}, k_{dz}$ can be found in Kong and Tsang (2001) where the k vectors relate to the geometry (i: incident wave, s: scattered wave, d: vector difference between incident and scattered wave) and f_{pq} , also a geometric term, is dependent of \hat{k}_i, \hat{k}_s and the Fresnel coefficients of both polarization p and q which depend on the permittivity of the medium.

The conditions for Geo Optics are $k\sigma_H \gg 1$ and $kl_c \gg 1$. The IEM model is not used in this paper since the model conditions, $k\sigma_H < 3$ and $k^2\sigma_H l_c < \sqrt{\epsilon}$ where k is the wavenumber and ϵ the permittivity, are not met (Table 6-1). The Advanced Integral Equation Model (AIEM) is a modified version of IEM that was developed to increase the validity range of IEM (Chen et al. 2003). They showed that for a rough case ($k\sigma_H = 2.576$ and $kl_c = 8.356$), the emissivity modeled by AIEM and Geo optics converged to the Method of Moment (used as reference) while IEM still showed significant bias. Considering that in our case, the normalized roughness ($k\sigma_H = 6.4$ and $kl_c = 111.4$ at 19 GHz) is higher, we decided that only the analytical solution of geometrical optics for rough surfaces will be used.

Table 6-1. Summary of conditions needed for Geo Optics and IEM. Permittivity from Montpetit et al. (2018) was used for calculation.

Frequency (GHz)	Geo Optics		IEM	
	$k\sigma_H \gg 1$	$kl_c \gg 1$	$k\sigma_H < 3$	$k^2\sigma_H l_c < \sqrt{\epsilon}$
19	6.4	111.4	6.4	$709.4 > 1.73$
37	12.4	217.0	12.4	$2690.3 > 1.73$

6.3 Data and methods

6.3.1 Study site

Field measurements were collected during spring 2019 in Cambridge Bay, Nunavut, Canada ($69^{\circ} 13' 05.66''$ N/ $104^{\circ} 56' 47.90''$ W). The study site is located inside Greiner Lake watershed in the arctic tundra spanning across various ecotypes (Figure 6-1).

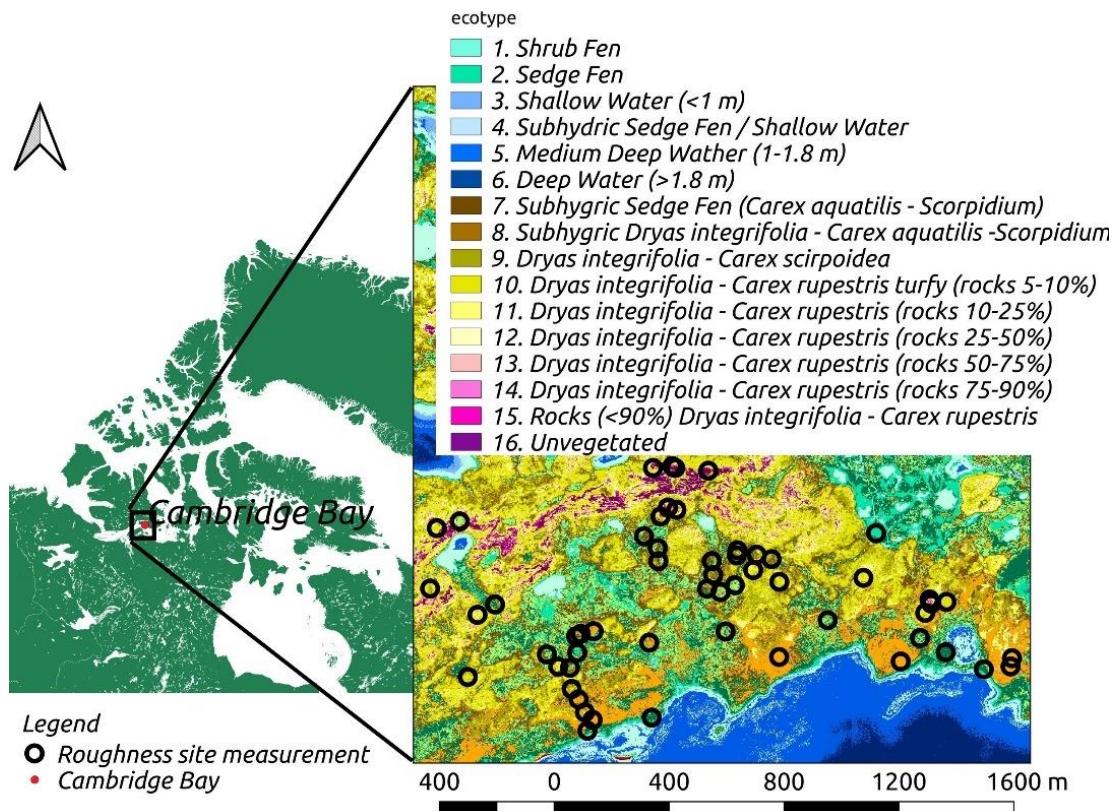


Figure 6-1. Study site in Greiner Lake watershed, Nunavut, Canada.

The ecotypes described in Figure 6-1 were determined using an ecosystem mapping approach (Ponomarenko et al. 2019) based on an ecosystem classification (McLennan et al. 2018). In total, 55 sites were used to create 3D point clouds for roughness measurements. These sites were classified in four different ecosystem types derived from the 15 classes displayed in Figure 6-1: 1) sedge/shrub, classes 1,2 and 7; 2) organic soil (rock < 10%), classes 8, 9 and 10; 3) organic soil (rock < 75%), classes 11, 12 and 13; 4) rock > 75%, classes 14 and 15. It should be noted that for

the sedge/shrub type, the roughness measurements were not of actual shrubs but rather of the area surrounding small vegetation.

6.3.2 Roughness measurements

At each site, after sweeping the snow off without damaging the surface, approximately 30 downward facing photographs of the ground were taken using a standard compact camera (Canon Powershot Elph 160 5.0 mm). All sites were batch processed with Agisoft Metashape software using the same parameters for point cloud filtering (Normalized criterion for filtering: Reprojection error = 0.2, Reconstruction Uncertainty = 10.0, Projection Accuracy = 10.0), producing 3D models yielding approximately 2-4 million points each (Figure 2). Once a 3D point cloud is produced from 2D pictures, there is no scale to real world dimension. The relative distance between every point is accurate but lacks an absolute relationship. Known dimensions are then used to scale the 3D model. Using the software, we can define on the images the plate's length so that these known dimensions can be used for optimization. Three metal plates of 50 cm each were used to scale the model where two were used for optimization of camera and position parameters and a third for validation yielding a precision of 0.1 mm by estimating the length of the third plates using optimization from first two plates. The plates need to be within as many pictures as possible without the radiometers field of view (FOV) becoming obstructed (after a radiometer measurement) so roughness can be measured. Light condition is also critical when doing photogrammetry, shadowing of half the surface could add uncertainty in reconstruction so constant illumination condition for every surface produced is desirable. Shadowing can be avoided while taking pictures by not going full circle around the sites, $\frac{3}{4}$ of a circle is sufficient for SfM to reconstruct the scene. This technique is fast and efficient in the field, producing reliable and precise measurements with only a standard digital camera and metal plates of known dimensions. These plates allow 3D models to be scaled without using a differential GPS unit with ground control points (GCP), e.g. Martinez-Agirre et al. (2019). The area covered for each 3D model ranged approximately from 0.25 to 0.6 m². Dimensions can be seen for one site on Figure 6-2.

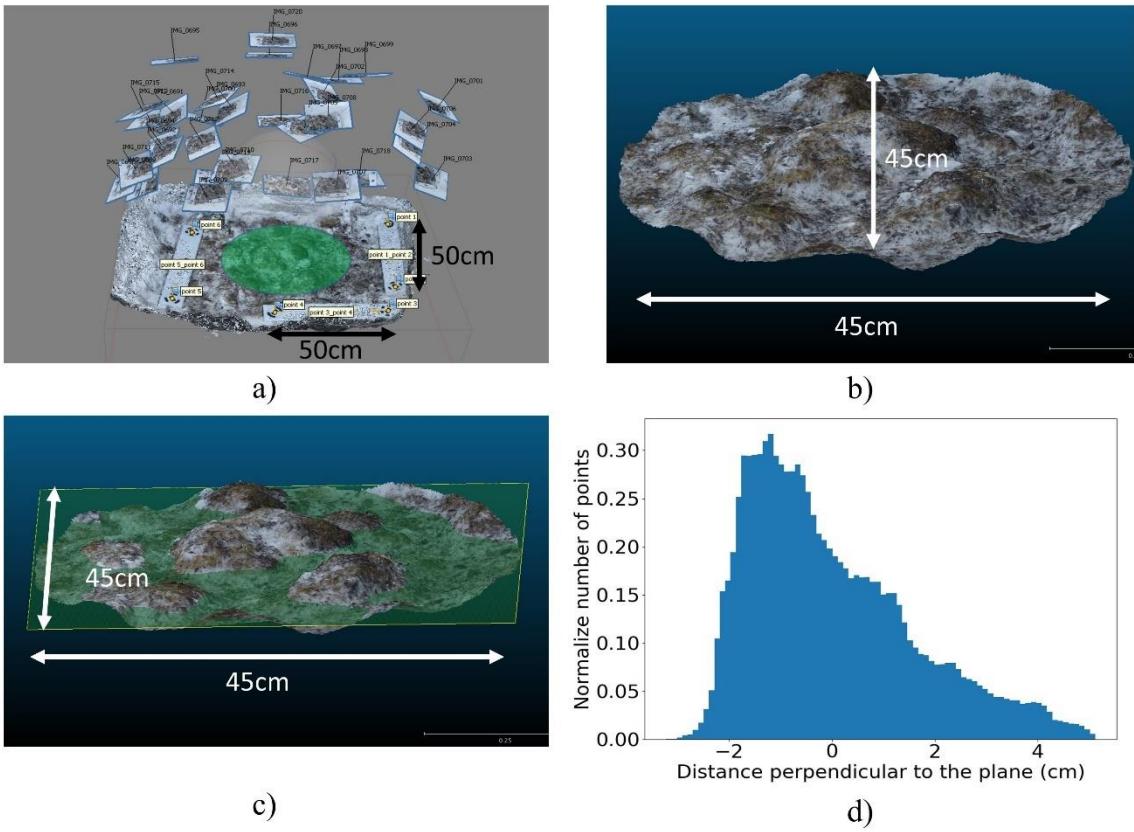


Figure 6-2. a) 3D point cloud creation, b) clipped 3D model to field of view of radiometer, c) fitted plane to 3D surface and d) histogram of perpendicular distances to plane, with $\sigma_H = 1.3 \text{ cm}$ and 2 787 233 points.

After the 3D reconstruction, the point cloud was clipped and a plane fitted by minimizing the mean perpendicular distance to zero. The height standard deviation was calculated with the perpendicular distance of every point to the plane and correlation length estimated using a variogram with x-y coordinates and height (z) from a randomly selected sub data set within point cloud (5000 points) where the fitted plane serves as the new x-y plane for the correlation in z. Several point clouds were tested (pairwise correlations calculations using up to 10 000 points) selected randomly from the entire point cloud. The correlation length converged on similar values irrespective of whether 5000 or 10 000 points were used. Therefore 5000 points was used for batch processing. Soil roughness is described at each site by the height standard deviation and correlation length. A fixed roughness parameter applicable to all sites was estimated with the mean of

roughness parameters for all 55 sites. First the roughness value per site is used and then the mean roughness was tested for all simulations.

6.3.3 Radiometric data

Brightness temperatures were measured at all sites (March and May 2019) with surface-based radiometers (SBR) at 19 and 37 GHz mounted on a mobile sled measuring both vertical and horizontal polarizations. Snow was removed so as to measure only soil brightness temperature, and effective surface temperatures were recorded within the soil surface (2-3 cm) shielded from the sun using a probe thermometer with an accuracy of $\pm 0.5^{\circ}\text{C}$ at five different locations within the field of view of the radiometers. Among the 55 roughness sites analyzed, 21 radiometric measurements at 55° from nadir were recorded and calibrated using cold and warm targets (Asmus and Grant, 1999) yielding an accuracy for radiometers of 2 K. Downward atmospheric contribution ($T_{B_{Atmo}\downarrow}$) was estimated for each frequency using the amount of precipitable water in the 29 atmospheric layers from the North America Regional Reanalysis model (NARR) (Roy et al. 2012) within 32×32 km pixels. All sites are within the same pixel, thus variations in atmospheric contribution by date only represent changes in the atmosphere (see Table 6-2). Angular emissivity was also simulated ($e_H = 1 - \Gamma_H$ and $e_V = 1 - \Gamma_V$ derived from Eq. 6.6 and 6.7) using the Weg99 model (for incident angles between 0 and 60°) to analyze angular dependency. Using averaged measurements of soil temperature and atmospheric contribution of all sites, the mean measured emissivity at 55° (from Eq. 6.1 and 6.2) was calculated with standard variation (± 0.009).

Table 6-2. Summary of radiometric observations and modeled downward atmospheric contributions.

Date	Number of sites	Mean Tsoil (°C)	Mean height std (cm)	Mean T_B (K)				$T_{B\atmo}\downarrow$ (K)	
				19H	19V	37H	37V	19	37
2019-04-30	1	-17	1.6	235.5	239.8	240.4	244.4	12.5	25.5
2019-05-02	7	-14.1	1.4	244.6	251.2	247.7	252.3	13.5	26.1
2019-05-03	2	-14.8	2.1	242.8	252.1	247.6	253.0	11.7	24.9
2019-05-10	6	-10.1	2.4	248.5	249.4	250.1	252.4	14.9	27.1
2019-05-11	4	-9.6	1.9	254.2	256.1	256.4	258.2	15.5	27.5

Montpetit et al. (2018), hereafter noted Mont18, parametrized frozen sub-arctic tundra soil using multi-angular microwave observations. Based on Weg99 model retrieval, the Mont18 effective parameters shown in Table 6-3 are from a different site but can serve as a comparison in this study given that they were found from passive observations at 19 and 37 GHz such as conducted in our experiment. King et al. (2018a) measured a permittivity of $4+0.5i$ also in a sub-Arctic environment in NWT, Canada. The retrieved permittivity values ($\varepsilon'_f - \varepsilon''_f i$) are in agreement with simulated permittivity using the soil radiative transfer model of Zhang et al., (2010) for frozen Arctic sites ($-15^{\circ}C < T < -10^{\circ}C$). The simulated values range from dry (wet) conditions: $3.13 - 0.0081i$ ($4.63 - 0.0067i$) and $3.11 - 0.0043i$ ($4.61 - 0.0036i$) respectively at 19 and 37 GHz (Table 6-3) with a sub-arctic soil composition (Clay = 9.66%, Sand = 50.73%, Silt = 39.61%). The values from Zhang et al. (2010) theoretical model (hereafter Zhang10) with a Volumetric Moisture Content (VMC) = 0.05 will be used as a reference value for the permittivity. The permittivity will then be optimized for all models to allow deviations from theoretical values to reflect the assumptions presented here.

Table 6-3. Parameters (Mont18) from optimization in Montpetit et al. (2018) with different soil moisture permittivity from model of Zhang et al., (2010). VMC stands for volumetric moisture content.

Frequency (GHz)		ε	β_f	σ_H (cm)
Montpetit et al. (2018) optimization				
19		3.42-0.005i	0.72	0.19
	Retrieved			
37		4.47-0.033i	0.42	
Zhang et al. (2010) model				
19	dry (VMC=0.05)	3.13-0.008i		
	wet (VMC=0.6)	4.63-0.007i		
37	dry (VMC=0.05)	3.11-0.004i		
	wet (VMC=0.6)	4.61-0.004i		

6.4 Results

6.4.1 Roughness measurements

Table 6-4 presents the results of all 55 sites, where both height standard deviation (σ_H) and correlation length (l_c) were measured for each ecotype. The average σ_H was 1.65 cm with l_c of 39.5 cm.

Table 6-4. Mean value of roughness parameters measured with SfM photogrammetry.

Ecotype	Number of sites		mean σ_H	std σ_H	mean l_c	std l_c
	Roughness	Radiometric	(cm)	(cm)	(cm)	(cm)
Sedge/shrub	6	3	1.57	0.29	29.4	12.5
Organic soil (rock < 10%)	25	8	1.91	0.59	37.9	25.1
Organic soil (rock < 75%)	14	7	1.46	0.72	52.2	38.6
Rock > 75%	8	2	1.50	0.95	33.0	16.5
Total	55	20	1.65	0.71	39.5	28.3

Measured σ_H greatly differs from Mont18 ($\sigma_{eff} = 0.19$ cm), which was derived from a microwave optimization approach using Weg99. Effective roughness optimized in Mont18 using Weg99 yielded lower roughness values than the actual physical measurement. This point is examined in the discussion.

6.4.2 Brightness temperature simulation

Three soil emission models were tested using different roughness parameters and permittivity values as inputs in Eq. (6.2). Model performances are shown in Figure 6-3 and summarized in Table 6-5. Simulated brightness temperatures from two semi-empirical models, QNH and Weg99, using dry permittivity from Zhang et al. (2010) model ($\varepsilon_{19}' = 3.13$ and $\varepsilon_{37}' = 3.11$, Table 6-3) and roughness derived from SfM, were compared to SBR measurements (Figure 6-3 a and b). The final model used was the Geo Optics (Figure 6-3c) analytical approach, which required two roughness parameters (σ_H and l_c) measured with SfM photogrammetry. Table 6-5 summarizes the root mean square errors (RMSE) and correlation (R^2) between observed and simulated brightness temperatures shown in Figure 6-3 for all three models and parameters used. Results are first presented for all sites and for all sites without rocks (excluding two sites with rock > 75%), as they exhibit particular clusters. At rock-free sites: Sedge/shrub and Organic soil (rock < 10% and rock < 75%), Weg99 with σ_H derived from SfM and permittivity from Zhang10 has one of the lowest

RMSE with 3.3 K and highest R^2 of 0.71. RMSE for horizontal polarization (H pol) were generally higher than for V pol (high model dependency to the polarization ratio).

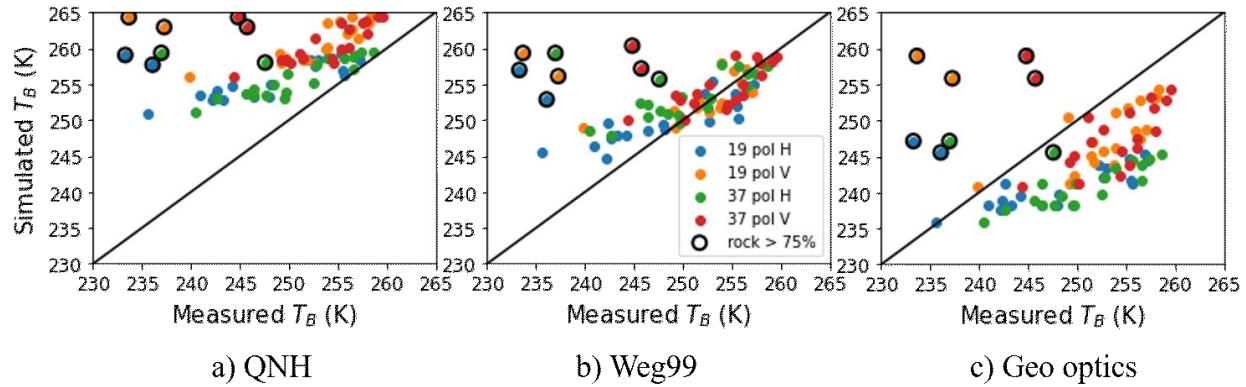


Figure 6-3. Simulations using Weg99, QNH and Geo optics models based on roughness estimates from SfM. Permittivity from Zhang10 was used. Polarization ratio (β_f) used for Weg99 are ($\beta_{f_{19}} = 0.72$, $\beta_{f_{37}} = 0.42$) (Table 6-3) and parameters for QNH defined in section 6.2.2.

Table 6-5. Simulation results using roughness parameters from SfM and permittivity from Zhang10 model (dry: VMC = 0.05).

Model	roughness	ε	RMSE (K)						R^2
			19H	19V	37H	37V	Total		
QNH	SfM	Zhang10	10.8	11.8	7.9	8.7	9.8	0.23	
Weg99	SfM	Zhang10	7.3	7.4	5.5	4.9	6.3	0.13	
Geo optics	SfM	Zhang10	9.2	9.3	10.1	7.9	9.1	0.07	
No rock									
QNH	SfM	Zhang10	8.2	8.0	5.9	6.9	7.2	0.68	
Weg99	SfM	Zhang10	4.2	2.8	3.7	2.6	3.3	0.71	
Geo optics	SfM	Zhang10	8.8	6.4	10.2	7.2	8.2	0.55	

To investigate permittivity further and see if optimized values for every model would converge, each model using parameters from Table 6-5 without rock sites, were optimized from (1-10) for ϵ' and are shown in Figure 6-4 and Table 6-6. While QNH was optimized to lower RMSE, the value had no physical meaning since the permittivities are too high for frozen soil as optimization did not reach a minimum ($\epsilon'_{19} = 10.0$, $\epsilon'_{37} = 10.0$). Weg99 and geo optics reached a minimum and indicating a low volumetric moisture content if we refer to Zhang et al. (2010) model values from Table 6-3. The Geo Optics model also shows a lower RMSE with 3.3 K when the permittivity is optimized ($\epsilon'_{19} = 2.4$, $\epsilon'_{37} = 2.3$). The permittivity is outside Zhang et al. (2010) moisture interval presented in Table 6-3 however, there is uncertainty linked to the composition of soil type chosen.

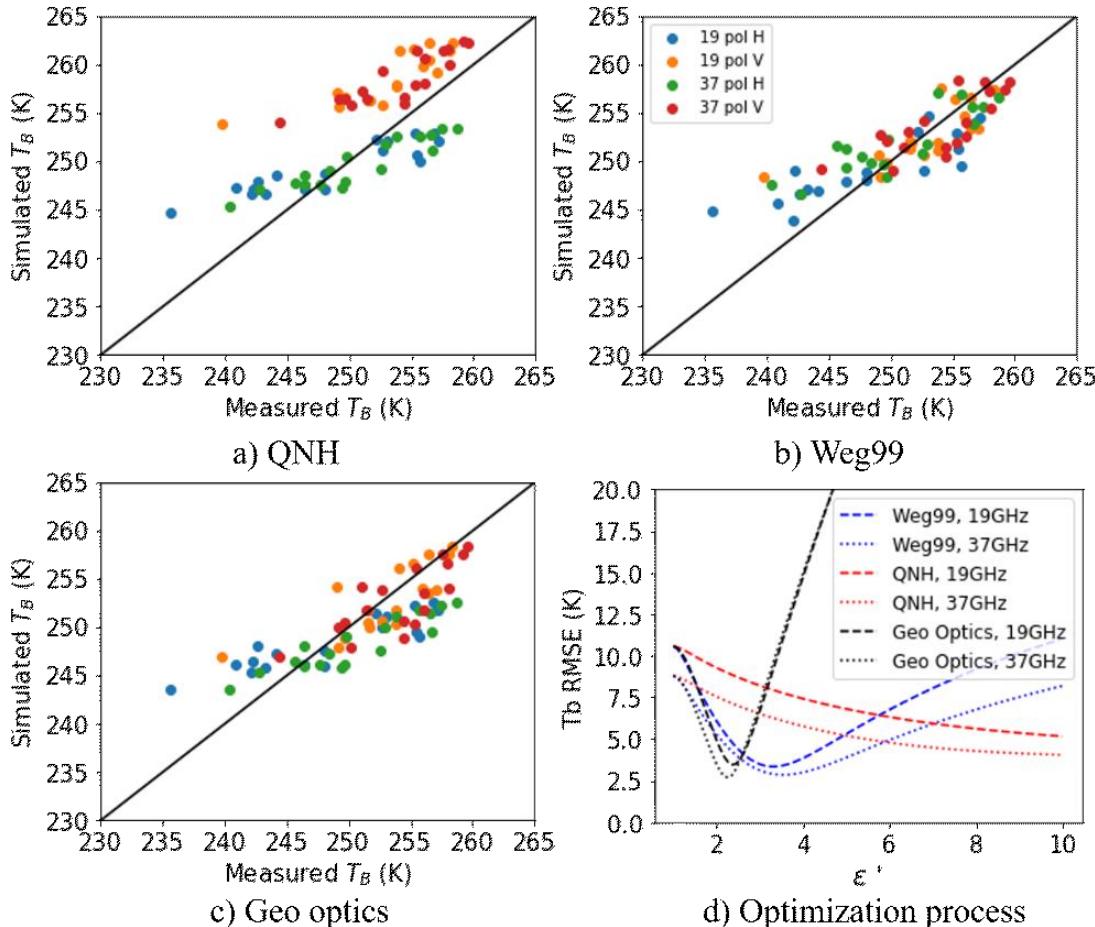


Figure 6-4. Simulated vs measured brightness temperatures for all models with optimized permittivity in a), b), and c) and optimization results in d).

Table 6-6. Results from optimization of permittivity.

Model	ϵ'		RMSE (K)						R^2
	19	37	19H	19V	37H	37V	Total		
QNH	10.0	10.0	4.3	6.0	3.1	5.0	4.6	0.51	
Weg99	3.3	3.6	4.0	2.7	3.2	2.6	3.1	0.71	
Geo optics	2.4	2.3	4.2	2.7	3.7	2.8	3.4	0.66	

6.4.3 Analysis of rock sites

The two rocky sites (rock >75%) had high biases in simulated brightness temperatures (Figure 6-3, and Table 6-5). It is difficult to precisely attribute the observed bias to only one factor (permittivity, temperature, structure of piled stones, see Figure 6-5). Part of the deviation can result from the difference in permittivity between rocks and the mainly frozen organic soil at all the other sites. The ‘rocks’ found in the Greiner Watershed study site are in fact a loose part of a limestone bedrock emerging to the surface at the top of a hill (McLennan et al. 2018). The dielectric constant (ϵ') of limestone was measured from 0.5 to 4.5 GHz in the recent study by Wang et al. (2019), giving values ranging from 8 to 8.5 at room temperature (~20-25°C), and without trend within the range of frequency used. Even though this study is at higher frequencies and at lower temperatures (~ -10°C), this permittivity differs greatly from the Mont18 values used in this paper. Moreover, the five temperature measurements taken per site after snow removal and radiometric measurement yielded a mean temperature of $-9.4 \pm 1.4^\circ\text{C}$ for both rock sites, while the mean rock temperature at the snow–rock interface was at -14°C and the air temperature was between -8 and -6°C during the experiments. Rock warming during the delay between the radiometric and temperature measurements might explain the observed difference in T_B if we recall Eq. 2, effective soil temperature is major component in T_B calculation. Also, it is more difficult to measure rock temperature than organic soil with a probe thermometer. To investigate the potential impact of temperature differences, a sensitivity analysis was performed on the brightness temperature as a function of permittivity and temperature changes for the rock sites (Figure 6-5a).

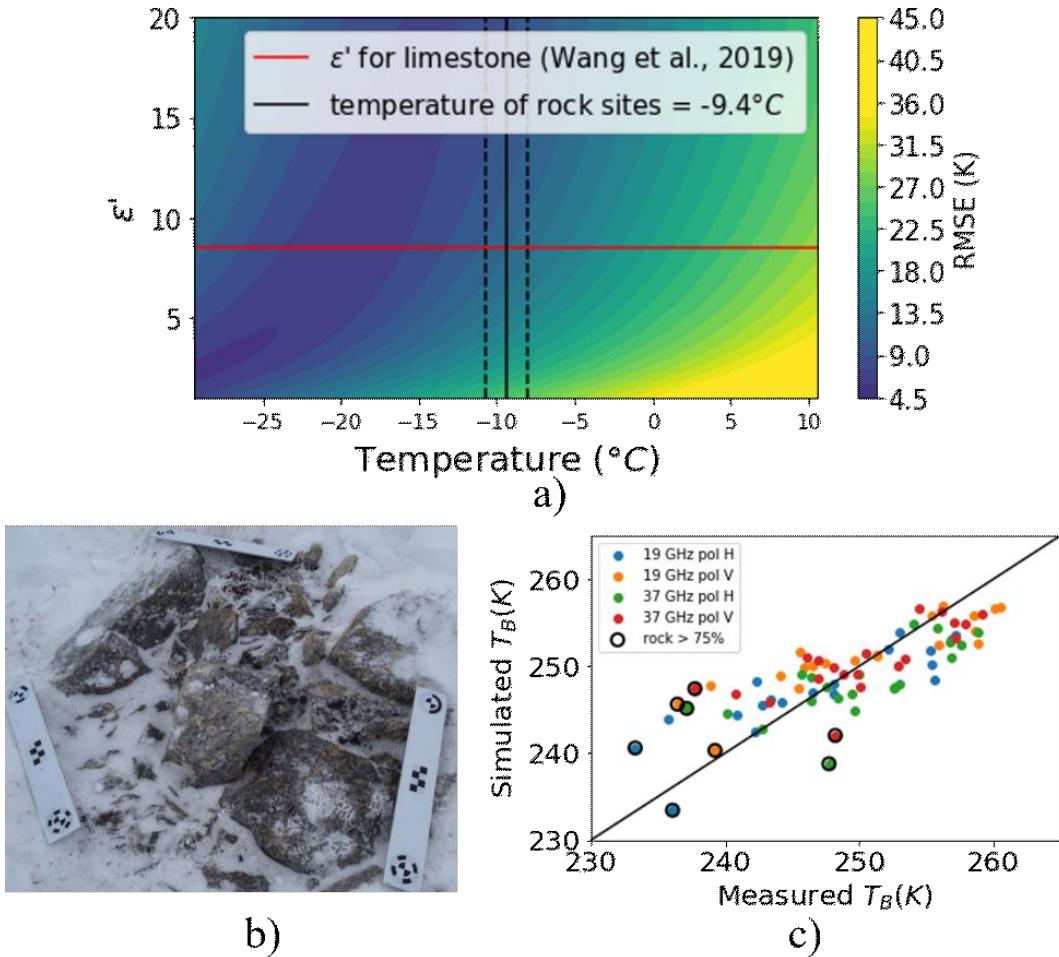


Figure 6-5. a) Representation of RMSE as function of permittivity and bias in effective temperature of the rock > 75% sites with Weg99 model and roughness SfM. **b)** Image of one of the rock sites. **c)** Simulation with modification of $\epsilon'=8.3$ and a change in temperature of -8°C (from -9.4°C to -17°C) for rock sites.

Figure 6-5b shows the RMSE associated with rock sites as a function of ϵ' and effective temperature compared to mean T_B measurements at 19 and 37 GHz. Assuming ϵ' from Wang et al. (2019) (red line in Figure 6-5b), a low RMSE is reached with a change in temperature of -8°C (from -9.4°C to -17°C on Figure 6-5a) from the measured temperature (black line). Soil temperatures are presented in Table 6-2 with $T_{soil} = -17^{\circ}\text{C}$ for 2019-04-30, for which values are colder than air temperature given the fact that measurements occurred earlier during the Spring season. Figure 6-5c shows measured and simulated results when a fixed optimized temperature

using Wang's permittivity (8.3) is used for rock sites, giving a total RMSE of 3.8 K. Improvements are significant in the range of data uncertainties.

6.5 Sensitivity analysis and Discussion

This discussion analyzes two points. We first examine the sensitivity of the considered soil emission model to the roughness variability at the 55 studied sites in the same tundra environment. Can a single value of roughness metrics be used to simulate emissivity of frozen arctic soil for global scale applications? We then discuss the observed differences between the measured physical roughness (by SfM) and the previously retrieved effective microwave roughness by Mont18.

We now explore the performance of a single roughness parameter applicable to all sites. The mean of roughness parameters was calculated for all 55 sites and then used as a reference value for all simulations (Table 6-7). Only Weg99 and Geo Optics models are presented as they had the lowest RMSE and highest R^2 values in Table 6-6. The mean value of σ_H for Weg99 and the mean value of σ_H and l_c with $\varepsilon = \text{Table 6-6}$ were then applied as a fixed roughness metric in both models. Results in Table 6-7 show that the mean RMSE remains very similar to Table 6-5 and Table 6-6 (for Weg99, SfM, without rocks), suggesting that average roughness can be satisfactorily applied, despite the observed spatial variability (Table 6-4, 43% of variation coefficient). This offers confidence in using a single parameter for different sites (or roughness) as uncertainty due to local roughness variability may average out at larger scale.

Table 6-7. Summary of simulation with a fixed SfM value of roughness for all sites without rock.

		RMSE							
		σ_H (cm)	l_c (cm)	19H	19V	37H	37V	Total	R^2
Weg99	mean	1.65		4.3	2.6	3.0	2.8	3.2	0.77
Geo Optics	mean	1.65	39.5	4.2	2.7	3.9	2.7	3.4	0.71

The physical surface roughness measured by SfM differs greatly from the effective roughness parameter found at a different site by inverse modelling of 0.19 cm (Montpetit et al., 2018). This difference is consistent with conclusions from Tsang and Newton (1982) and Ulaby et al. (1982) that found discrepancy when using the QNH model. As such, the difference observed in our study when using Weg99 can also be attributed to the mix of QNH and the parametrization from Mo and Schmugge (1987). This explains the observed discrepancy between our measured roughness and the effective roughness found by Mont18.

Also, in this study, all measurements were performed at 55° while multiple angles were used by Montpetit et al. (2018). The angular sensitivity of roughness is evaluated in Figure 6-6 for both frequencies and polarizations. All other factors being constant (soil moisture-permittivity in particular), roughness shows a stronger influence on emissivity at higher incidence angles ($> 50^\circ$), particularly for horizontal polarization. In other words, e_p around and over 50° is more sensitive to roughness. This could be one of the reasons why multi-angular retrieved effective roughness does not match physically measured roughness (of the order of 2 cm, instead of 0.2 cm from Mont18). Other factors are also involved like the frequency dependency between 19 and 37 GHz. This greater sensitivity of emissivity at higher viewing angles was shown in the pioneering works of Wang et al., (1983) and Singh et al., (1995), which concluded that the best fit angle for satellite-borne surface roughness observations is near 50° for both polarizations.

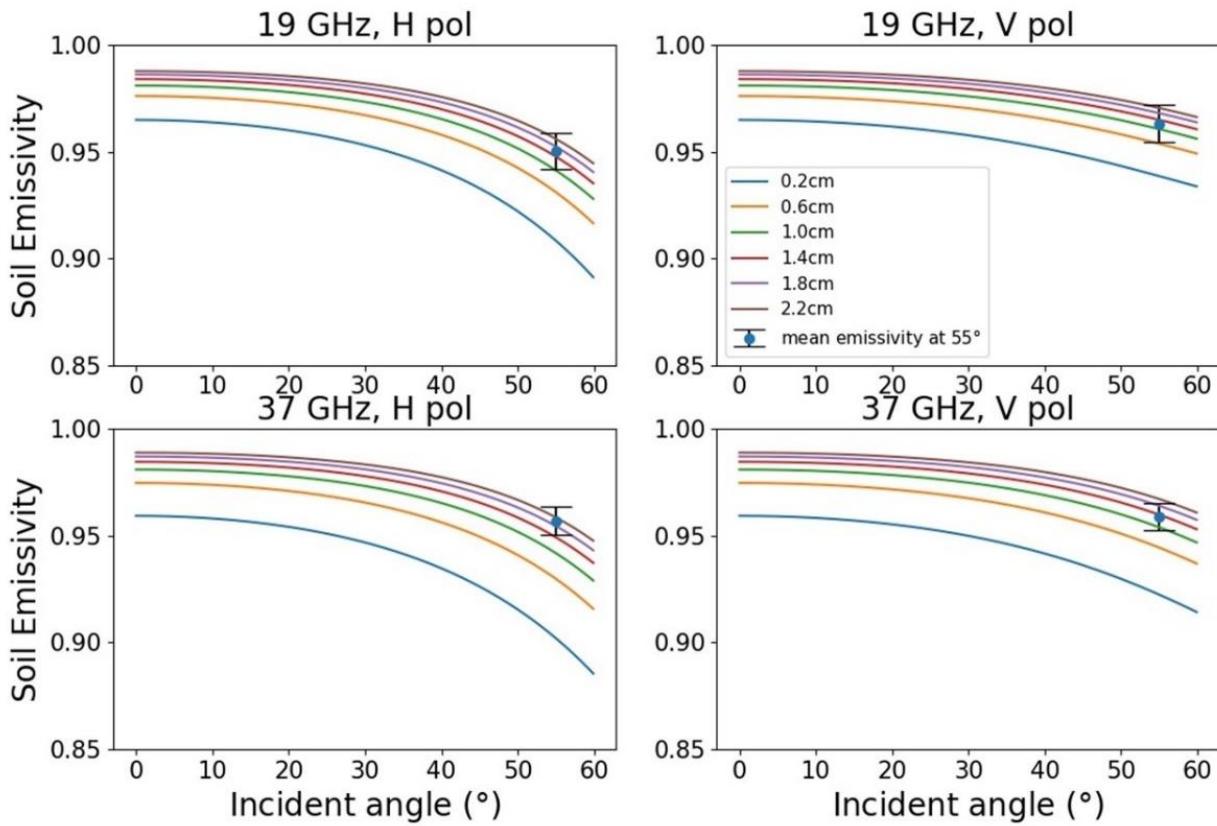


Figure 6-6. Sensitivity analysis on angular dependency of emission with different roughness values, for 19 and 37 GHz with horizontal and vertical polarization.

Our results are also in agreement with results from King et al., (2018), who studied similar types of tundra environment. Using airborne dual band SAR radar measurements at 9.6 and 17.2 GHz, they found an optimized effective roughness of 1.3 cm at an incident angle of 40°.

Very few values of estimated effective roughness at high frequencies have been validated against in-situ roughness estimates. One reason is that previous techniques, such as those that use pin profilometers, are time consuming and best for point values, while modern techniques, such as laser scanning and SfM (Martinez-Agirre et al. 2019), are relatively easy to use and efficient for large-scale studies. Rahman et al. (2008) showed that the effective bare soil roughness at C-band (5.3 GHz) retrieved from radar measurements using the IEM model is of 2.19 ± 0.49 cm, while in-

situ pin profilometer measurements gave a significantly lower soil roughness value of 0.79 ± 0.29 cm.

Our results also show permittivity values that are representative of spatial variability and permittivity fluctuations within studied soil types, as multiple landcovers were part of the in-situ validation. In the literature, in-situ permittivity values and roughness for frozen soils are currently rare, our study offers measured roughness values with permittivity and soil moisture that are valid with assumptions made within the Zhang et al. (2010) model. Results from this study could be generalized spatially, for example on a catchment scale, by linking in-situ results (roughness and permittivity) to the types of land cover. Increasingly, it is possible to derive centimeter scale roughness information from UAVs that characterize different hydrological response units within catchments. In addition, topographic and ecological land-cover classes can be derived from very high-resolution optical satellite images (such as WORLDVIEW-3 images), which opens opportunities for application of roughness to land cover classes over larger pan-Arctic scales.

6.6 Conclusion

In this study, we applied an effective and relatively simple method to measure soil roughness at multiple Arctic sites using the Structure-from-Motion (SfM) technique. Measurements of surface roughness over 55 sites across 4 Arctic tundra ecotypes had an average RMS height (σ_H) of 1.65 cm and mean $2 D_{x,y}$ correlation length (l_c) of 39.5 cm. The observed variability appears relatively low for σ_H but high for l_c . For the first time, we tested three different rough surface reflectivity models (QNH, Weg99 and Geo Optics) at 19 and 37 GHz over frozen ground conditions and compared simulations to ground-based radiometer observations. Results show best performance with the Weg99 model parametrized with SfM-based roughness (1.65 cm) and frozen organic soil permittivity (ϵ) from theoretical model by Zhang et al. (2010). When permittivity is optimized, Weg99 still best fit observations. Accuracy considering fixed permittivity and measured roughness at each site for Tb simulations yielded similar results indicating a fixed value could be used for large scale application. The Geo Optics model also shows good results if the permittivity is optimized (see Table 6-6).

A fixed value for roughness (σ_H) for all the sites gives similar modelling performance even though variability of σ_H between sites was observed. The mean roughness value of $\sigma_H = 1.65 \text{ cm}$ and ε given in Table 6-6 using the Weg99 model appears to be representative of Arctic tundra land cover, mainly characterized by sedge/shrub with organic soil and rock between 10% to 75%.

Analysis of particular rock sites with limestone composition and similar roughness to organic soils revealed different behavior in radiometric measurements, suggesting a need to consider specific rock permittivity and a colder effective temperature to match simulations and observations. This is an important finding as rock surfaces cover up to 8% of terrestrial high Arctic areas (Ponomarenko et al. 2019). Because of the large difference in permittivity between rocks and soil, future studies may consider a mixed model that takes into account the fraction of rocks in each land cover or geological class. This could be useful in inversion of parameters for remote sensing planetary surfaces.

This study thus offers surface roughness values that can be used on a larger scale in a satellite retrieval algorithm for global Arctic monitoring by remote sensing. Using inversion algorithm to retrieve surface parameters is difficult because both backscattering coefficient and brightness temperature are strongly affected in the same way by several factors including roughness, soil moisture, vegetation or snow cover (e.g. Moradizadeh and Saradjian, 2016; Wigneron et al., 2017). The reduction in microwave dielectric sensitivity to soil moisture caused by surface roughness is a well-known problem. In addition, estimating these parameters remains challenging, as shown in numerous studies (e.g. Du et al., 2010, with active radiometry; Roy et al., 2016, Shi et al., 2016, with passive radiometry). For example, surface roughness change linked to land cover change, such as observed shrub expansion in the Arctic, could be an important source of uncertainties for modelling active and passive microwave signals. The photogrammetry method presented in this paper offers an effective and low-cost way to reliably measure soil roughness when performing ground-based validation of passive/active microwave data while allowing us to gain a better understanding of geophysical properties of frozen soil.

Acknowledgment

The authors would like to thank Benoît Montpetit and Alex Mavrovic for their contribution and helpful comments on this work. We thank Donald McLennan, Johann Wagner and Serguei Ponomarenko for the ecosystem map and their help in Cambridge Bay. We also thank Daniel Kramer, Simon Levasseur, Coralie Gautier, Guillaume Couture and Patrick Cliche from Université de Sherbrooke and Ludovic Brucker from the NASA Cryospheric Sciences Laboratory for field work assistance, instrument maintenance and overall guidance.

Funding

This research was made possible thanks to the financial support of the Natural Sciences and Engineering Research Council of Canada (NSERC), Polar Knowledge Canada, the Canadian Foundation for Innovation and research funding from Northumbria University, UK.

References

- AMAP (2019) Arctic Climate Change Update 2019, p. 12.
- Armstrong, R. L. et Brodzik, M. J. (1995) An earth-gridded SSM/I data set for cryospheric studies and global change monitoring. *Advances in Space Research*.
- Asmus, K. W. et Grant, C. (1999) Surface Based Radiometer (SBR) Data Acquisition System. *International Journal of Remote Sensing*, vol. 20, n°15-16, p. 3125-3129.
- Bartelt, P. et Lehning, M. (2002) A physical SNOWPACK model for the Swiss avalanche warning. *Cold Regions Science and Technology*, vol. 35, n°3, p. 123-145.
- Benson, C. S. et Sturm, M. (1993) Structure and wind transport of seasonal snow on the Arctic slope of Alaska. *Annals of Glaciology*, vol. 18, n°January 1993, p. 261-267.
- Böttcher, K., Aurela, M., Kervinen, M., Markkanen, T., Mattila, O. P., Kolari, P., Metsämäki, S., Aalto, T., Arslan, A. N. et Pulliainen, J. (2014) MODIS time-series-derived indicators for the beginning of the growing season in boreal coniferous forest - A comparison with CO₂ flux measurements and phenological observations in Finland. *Remote Sensing of Environment*.
- Breiman, L. (2001) Random forests. *Machine Learning*.
- Brodzik, M. J., Long, D. G. et Hardman, M. A. (2018) Best practices in crafting the calibrated, Enhanced-Resolution passive-microwave EASE-Grid 2.0 brightness temperature Earth System Data Record. *Remote Sensing*, vol. 10, n°11.
- Chang, A. T. C., Foster, J. L., Hall, D. K., Rango, A. et Hartline, B. K. (1982) Snow water equivalent estimation by microwave radiometry. *Cold Regions Science and Technology*.
- Clark, M. P., Hendrikx, J., Slater, A. G., Kavetski, D., Anderson, B., Cullen, N. J., Kerr, T., Örn Hreinsson, E. et Woods, R. A. (2011) Representing spatial variability of snow water equivalent in hydrologic and land-surface models: A review. *Water Resources Research*, vol. 47, n°7.
- Davesne, G., Domine, F. et Fortier, D. (2021) Effects of meteorology and soil moisture on the spatio-temporal evolution of the depth hoar layer in the polar desert snowpack. *Journal of Glaciology*, p. 1-16.
- Derksen, C., Burgess, D., Duguay, C., Howell, S., Mudryk, L., Smith, S., Thackeray, C. et Kirchmeier-Young, M. (2019) Changes in Snow, Ice, and Permafrost Across Canada. *Canada's Changing Climate Report*, p. 194-260.
- Derksen, C., Lemmetyinen, J., Toose, P., Silis, A., Pulliainen, J. et Sturm, M. (2014) Physical properties of Arctic versus subarctic snow: Implications for high latitude passive microwave snow water equivalent retrievals. *Journal of Geophysical Research: Atmospheres*, vol. 119, n°12, p. 7254-7270.
- Derksen, C., Toose, P., Lemmetyinen, J., Pulliainen, J., Langlois, A., Rutter, N. et Fuller, M. C. (2012) Evaluation of passive microwave brightness temperature simulations and snow water equivalent retrievals through a winter season. *Remote Sensing of Environment*, vol. 117, p. 236-248.

- Derksen, C., Toose, P., Rees, A., Wang, L., English, M., Walker, A. et Sturm, M. (2010) Development of a tundra-specific snow water equivalent retrieval algorithm for satellite passive microwave data. *Remote Sensing of Environment*.
- Domine, F., Barrere, M. et Morin, S. (2016) The growth of shrubs on high Arctic tundra at Bylot Island: Impact on snow physical properties and permafrost thermal regime. *Biogeosciences*, vol. 13, n°23, p. 6471-6486.
- Domine, F., Picard, G., Morin, S., Barrere, M., Madore, J.-B. et Langlois, A. (2018) Major Issues in Simulating some Arctic Snowpack Properties Using Current Detailed Snow Physics Models. Consequences for the Thermal Regime and Water Budget of Permafrost. *Journal of Advances in Modeling Earth Systems*, n°December 2018.
- Fung, A. K. (1994) Microwave scattering and emission models and their applications. Boston : Artech House Publishers.
- Gallet, J. C., Domine, F., Zender, C. S. et Picard, G. (2009) Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm. *Cryosphere*, vol. 3, n°2, p. 167-182.
- Garnaud, C., Bélair, S., Carrera, M. L., Derksen, C., Bilodeau, B., Abrahamowicz, M., Gauthier, N. et Vionnet, V. (2019) Quantifying Snow Mass Mission Concept Trade-Offs Using an Observing System Simulation Experiment. *Journal of Hydrometeorology*, vol. 20, n°1, p. 155-173.
- Gisnas, K., Westermann, S., Vikhamar Schuler, T., Melvold, K. et Etzelmüller, B. (2016) Small-scale variation of snow in a regional permafrost model. *Cryosphere*, vol. 10, n°3, p. 1201-1215.
- Goosse, H., Kay, J. E., Armour, K. C., Bodas-salcedo, A., Chepfer, H., Docquier, D., Jonko, A., Kushner, P. J., Lecomte, O., Massonnet, F., Park, H., Pithan, F., Svensson, G. et Vancoppenolle, M. (2018) Quantifying climate feedbacks in polar regions. *Nature Communications*.
- Gouttevin, I., Langer, M., Löwe, H., Boike, J., Proksch, M. et Schneebeli, M. (2018) Observation and modelling of snow at a polygonal tundra permafrost site: Spatial variability and thermal implications. *Cryosphere*, vol. 12, n°11, p. 3693-3717.
- Grünewald, T., Stötter, J., Pomeroy, J. W., Dadic, R., Moreno Baños, I., Marturià, J., Spross, M., Hopkinson, C., Burlando, P. et Lehning, M. (2013) Statistical modelling of the snow depth distribution in open alpine terrain. *Hydrology and Earth System Sciences*, vol. 17, n°8, p. 3005-3021.
- Hall, D. K., Riggs, G. A., Salomonson, V. V., DiGirolamo, N. E. et Bayr, K. J. (2002) MODIS snow-cover products. *Remote Sensing of Environment*, vol. 83, n°1-2, p. 181-194.
- James, M. R., Robson, S. et Smith, M. W. (2017) 3-D uncertainty-based topographic change detection with structure-from-motion photogrammetry: precision maps for ground control and directly georeferenced surveys. *Earth Surface Processes and Landforms*, vol. 42, n°12, p. 1769-1788.
- Kelly, R. E., Chang, A. T., Tsang, L. et Foster, J. L. (2003) A prototype AMSR-E global snow

- area and snow depth algorithm. *IEEE Transactions on Geoscience and Remote Sensing*.
- King, J., Derksen, C., Toose, P., Langlois, A., Larsen, C., Lemmetyinen, J., Marsh, P., Montpetit, B., Roy, A., Rutter, N. et Sturm, M. (2018) The influence of snow microstructure on dual-frequency radar measurements in a tundra environment. *Remote Sensing of Environment*, vol. 215, n°May, p. 242-254.
- King, J., Kelly, R., Kasurak, A., Duguay, C., Gunn, G., Rutter, N., Watts, T. et Derksen, C. (2015) Spatio-temporal influence of tundra snow properties on Ku-band (17.2 GHz) backscatter. *Journal of Glaciology*, vol. 61, n°226, p. 267-279.
- Kong, J. A. et Tsang, L. (2001) *Scattering of Electromagnetic Waves Vol3 (Vol. 9)*. New York : John Wiley & Sons, Inc.
- Krol, Q. et Löwe, H. (2016) Relating optical and microwave grain metrics of snow: The relevance of grain shape. *Cryosphere*, vol. 10, n°6, p. 2847-2863.
- Langlois, A., Bergeron, J., Brown, R., Royer, A., Harvey, R., Roy, A., Wang, L. et Thériault, N. (2014) Evaluation of CLASS 2.7 and 3.5 Simulations of Snow Properties from the Canadian Regional Climate Model (CRCM4) over Québec, Canada*. *Journal of Hydrometeorology*, vol. 15, n°4, p. 1325-1343.
- Langlois, A., Royer, A., Derksen, C., Montpetit, B., Dupont, F. et Gota, K. (2012) Coupling the snow thermodynamic model SNOWPACK with the microwave emission model of layered snowpacks for subarctic and arctic snow water equivalent retrievals. *Water Resources Research*, vol. 48, n°12.
- Larue, F., Royer, A., De Sève, D., Roy, A. et Cosme, E. (2018) Assimilation of passive microwave AMSR-2 satellite observations in a snowpack evolution model over northeastern Canada. *Hydrology and Earth System Sciences*, vol. 22, n°11, p. 5711-5734.
- Liebe, H. J. (1989) MPM-An atmospheric millimeter-wave propagation model. *International Journal of Infrared and Millimeter Waves*, vol. 10, n°6, p. 631-650.
- Liston, G. E. (2004) Representing subgrid snow cover heterogeneities in regional and global models. *Journal of Climate*, vol. 17, n°6, p. 1381-1397.
- Lowe, D. G. (2004) Distinctive image features from scale invariant keypoints. *International Journal of Computer Vision*, vol. 60, p. 91-11020042.
- Luojas, K., Pulliainen, J., Takala, M., Derksen, C., Rott, H., Nagler, T., Solberg, R., Wiesmann, A., Metsamaki, S., Malnes, E. et Bojkov, B. (2011) Investigating the feasibility of the globsnow snow water equivalent data for climate research purposes.
- Martinez-Agirre, A., Álvarez-Mozos, J., Milenković, M., Pfeifer, N., Giménez, R., Valle Melón, J. M. et Rodríguez Miranda, Á. (2019) Evaluation of Terrestrial Laser Scanner and Structure from Motion photogrammetry techniques for quantifying soil surface roughness parameters over agricultural soils. *Earth Surface Processes and Landforms*, p. esp.4758.
- Mavrovic, A., Pardo Lara, R., Berg, A., Demontoux, F., Royer, A. et Roy, A. (2021) Soil dielectric characterization during freeze-Thaw transitions using L-band coaxial and soil moisture probes. *Hydrology and Earth System Sciences*, vol. 25, n°3, p. 1117-1131.
- Mironov, V. L., Kosolapova, L. G., Fomin, S. V., Savin, I. V. et Muzalevskiy, K. V. (2015)

- Dielectric model for thawed and frozen organic soils at 1.4 GHz. International Geoscience and Remote Sensing Symposium (IGARSS), vol. 2015-July, p. 7180-7183.
- Mo, T. et Schmugge, T. J. (1987) A Parameterization of the Effect of Surface Roughness on Microwave Emission. IEEE Transactions on Geoscience and Remote Sensing, vol. GE-25, n°4, p. 481-486.
- Montpetit, B., Royer, A., Langlois, A., Cliché, P., Roy, A., Champollion, N., Picard, G., Domine, F. et Obbard, R. (2012) New shortwave infrared albedo measurements for snow specific surface area retrieval. Journal of Glaciology, vol. 58, n°211, p. 941-952.
- Montpetit, B., Royer, A., Roy, A. et Langlois, A. (2018) In-situ passive microwave emission model parameterization of sub-arctic frozen organic soils. Remote Sensing of Environment, vol. 205, n°November 2017, p. 112-118.
- Montpetit, B., Royer, A., Wigneron, J. P., Chanzy, A. et Mialon, A. (2015) Evaluation of multi-frequency bare soil microwave reflectivity models. Remote Sensing of Environment, vol. 162, p. 186-195.
- Natali, S. M., Watts, J. D., Rogers, B. M., Potter, S., Ludwig, S. M., Selbmann, A.-K., Sullivan, P. F., Abbott, B. W., Arndt, K. A., Birch, L., Björkman, M. P., Bloom, A. A., Celis, G., Christensen, T. R., Christiansen, C. T., Commane, R., Cooper, E. J., Crill, P., Czimczik, C., Davydov, S., Du, J., Egan, J. E., Elberling, B., Euskirchen, E. S., Friberg, T., Genet, H., Göckede, M., Goodrich, J. P., Grogan, P., Helbig, M., Jafarov, E. E., Jastrow, J. D., Kalhor, A. A. M., Kim, Y., Kimball, J. S., Kutzbach, L., Lara, M. J., Larsen, K. S., Lee, B.-Y., Liu, Z., Loranty, M. M., Lund, M., Lupascu, M., Madani, N., Malhotra, A., Matamala, R., McFarland, J., McGuire, A. D., Michelsen, A., Minions, C., Oechel, W. C., Olefeldt, D., Parmentier, F.-J. W., Pirk, N., Poulter, B., Quinton, W., Rezanezhad, F., Risk, D., Sachs, T., Schaefer, K., Schmidt, N. M., Schuur, E. A. G., Semenchuk, P. R., Shaver, G., Sonnentag, O., Starr, G., Treat, C. C., Waldrop, M. P., Wang, Y., Welker, J., Wille, C., Xu, X., Zhang, Z., Zhuang, Q. et Zona, D. (2019) Large loss of CO₂ in winter observed across the northern permafrost region. Nature Climate Change, vol. 9, n°11, p. 852-857.
- Nitta, T., Yoshimura, K., Takata, K., O'ishi, R., Sueyoshi, T., Kanae, S., Oki, T., Abe-Ouchi, A. et Liston, G. E. (2014) Representing variability in subgrid snow cover and snow depth in a global land model: Offline validation. Journal of Climate, vol. 27, n°9, p. 3318-3330.
- Notz, D. et Stroeve, J. (2016) Observed Arctic sea-ice loss directly follows anthropogenic CO₂ emission. Science, vol. 354, n°6313, p. 747-750.
- Ouellet, F., Langlois, A., Blukacz-Richards, E. A., Johnson, C. A., Royer, A., Neave, E. et Larter, N. C. (2017) Spatialization of the SNOWPACK snow model for the Canadian Arctic to assess Peary caribou winter grazing conditions. Physical Geography, vol. 38, n°2, p. 143-158.
- Parr, C., Sturm, M. et Larsen, C. (2020) Snowdrift Landscape Patterns: An Arctic Investigation. Water Resources Research, vol. 56, n°12.
- Picard, G., Brucker, L., Roy, A., Dupont, F., Fily, M., Royer, A. et Harlow, C. (2013) Simulation of the microwave emission of multi-layered snowpacks using the Dense Media Radiative

- transfer theory: the DMRT-ML model. *Geoscientific Model Development*, vol. 6, n°4, p. 1061-1078.
- Picard, G., Sandells, M. et Löwe, H. (2018) SMRT: An active-passive microwave radiative transfer model for snow with multiple microstructure and scattering formulations (v1.0). *Geoscientific Model Development*, vol. 11, n°7, p. 2763-2788.
- Prince, M., Roy, A., Brucker, L., Royer, A., Kim, Y. et Zhao, T. (2018) Northern hemisphere surface freeze-thaw product from aquarius L-band radiometers. *Earth System Science Data*, vol. 10, n°4, p. 2055-2067.
- Proksch, M., Löwe, H. et Schneebeli, M. (2015) Density, specific surface area, and correlation length of snow measured by high-resolution penetrometry. *Journal of Geophysical Research: Earth Surface*, vol. 120, n°2, p. 346-362.
- Proksch, M., Rutter, N., Fierz, C. et Schneebeli, M. (2016) Intercomparison of snow density measurements: Bias, precision, and vertical resolution. *Cryosphere*.
- Pulliainen, J. (2006) Mapping of snow water equivalent and snow depth in boreal and sub-arctic zones by assimilating space-borne microwave radiometer data and ground-based observations. *Remote Sensing of Environment*, vol. 101, n°2, p. 257-269.
- Pulliainen, J. et Hallikainen, M. T. (2001) Retrieval of Regional Snow Water Equivalent from Space-Borne Passive Microwave Observations. *Remote Sensing of Environment*, vol. 75, n°1, p. 76-85.
- Pulliainen, J., Luojus, K., Derksen, C., Mudryk, L., Lemmetyinen, J., Salminen, M., Ikonen, J., Takala, M., Cohen, J., Smolander, T. et Norberg, J. (2020) Patterns and trends of Northern Hemisphere snow mass from 1980 to 2018. *Nature*, vol. 581, n°7808, p. 294-298.
- Pulwicki, A., Flowers, G. E., Radic, V. et Bingham, D. (2018) Estimating winter balance and its uncertainty from direct measurements of snow depth and density on alpine glaciers. *Journal of Glaciology*, vol. 64, n°247, p. 781-795.
- Revuelto, J., Billecocq, P., Tuzet, F., Cluzet, B., Lamare, M., Larue, F. et Dumont, M. (2020) Random forests as a tool to understand the snow depth distribution and its evolution in mountain areas. *Hydrological Processes*, n°October, p. hyp.13951.
- Richter-Menge, J., Overland, J. E., Mathis, J. T. et Osborne, E. (2017) Arctic Report Card 2017, p. 1-96.
- Romanovsky, V. E., Smith, S. L. et Christiansen, H. H. (2010) Permafrost thermal state in the polar northern hemisphere during the international polar year 2007-2009: A synthesis. *Permafrost and Periglacial Processes*, vol. 21, n°2, p. 106-116.
- Roy, A., Royer, A., St-Jean-Rondeau, O., Montpetit, B., Picard, G., Mavrovic, A., Marchand, N. et Langlois, A. (2016) Microwave snow emission modeling uncertainties in boreal and subarctic environments. *The Cryosphere*, vol. 10, n°2, p. 623-638.
- Roy, A., Royer, A., Wigneron, J. P., Langlois, A., Bergeron, J. et Cliche, P. (2012) A simple parameterization for a boreal forest radiative transfer model at microwave frequencies. *Remote Sensing of Environment*, vol. 124, p. 371-383.
- Roy, V., Goita, K., Royer, A., Walker, A. E. et Goodison, B. E. (2004) Snow water equivalent

- retrieval in a Canadian boreal environment from microwave measurements using the HUT snow emission model. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, n°9, p. 1850-1859.
- Rutter, N., Sandells, M., Derksen, C., Toose, P., Royer, A., Montpetit, B., Langlois, A., Lemmetyinen, J. et Pullainen, J. (2014) Snow stratigraphic heterogeneity within ground-based passive microwave radiometer footprints: Implications for emission modeling. *Journal of Geophysical Research: Earth Surface*, vol. 119, n°3, p. 550-565.
- Rutter, N., Sandells, M. J., Derksen, C., King, J., Toose, P., Wake, L., Watts, T., Essery, R., Roy, A., Royer, A., Marsh, P., Larsen, C. et Sturm, M. (2019) Effect of snow microstructure variability on Ku-band radar snow water equivalent retrievals. *The Cryosphere*, vol. 13, n°11, p. 3045-3059.
- Saberi, N., Kelly, R., Flemming, M. et Li, Q. (2020) Review of snow water equivalent retrieval methods using spaceborne passive microwave radiometry. *International Journal of Remote Sensing*, vol. 41, n°3, p. 996-1018.
- Saberi, N., Kelly, R., Pan, J., Durand, M., Goh, J. et Scott, K. A. (2020) The Use of a Monte Carlo Markov Chain Method for Snow-Depth Retrievals: A Case Study Based on Airborne Microwave Observations and Emission Modeling Experiments of Tundra Snow. *IEEE Transactions on Geoscience and Remote Sensing*, p. 1-14.
- Sandells, M., Lowe, H., Picard, G., Dumont, M., Essery, R., Flouri, N., Kontu, A., Lemmetyinen, J., Maslanka, W., Morin, S., Wiesmann, A. et Matzler, C. (2021) X-Ray Tomography-Based Microstructure Representation in the Snow Microwave Radiative Transfer Model. *IEEE Transactions on Geoscience and Remote Sensing*, p. 1-15.
- Santos, P. M. D. et Júlio, E. N. B. S. (2013) A state-of-the-art review on roughness quantification methods for concrete surfaces. *Construction and Building Materials*, vol. 38, p. 912-923.
- Screen, J. A. et Simmonds, I. (2010) The central role of diminishing sea ice in recent Arctic temperature amplification. *Nature*, vol. 464, n°7293, p. 1334-1337.
- Serreze, M. C. et Barry, R. G. (2011) Processes and impacts of Arctic amplification: A research synthesis. *Global and Planetary Change*, vol. 77, n°1-2, p. 85-96.
- Stieglitz, M., Déry, S. J., Romanovsky, V. E. et Osterkamp, T. E. (2003) The role of snow cover in the warming of arctic permafrost. *Geophysical Research Letters*, vol. 30, n°13.
- Sturm, M., McFadden, J. P., Liston, G. E., Stuart Chapin, F., Racine, C. H. et Holmgren, J. (2001) Snow-shrub interactions in Arctic Tundra: A hypothesis with climatic implications. *Journal of Climate*.
- Sturm, M. et Wagner, A. M. (2010) Using repeated patterns in snow distribution modeling: An Arctic example. *Water Resources Research*, vol. 46, n°12, p. 1-15.
- Takala, M., Luojus, K., Pullainen, J., Derksen, C., Lemmetyinen, J., Kärnä, J. P., Koskinen, J. et Bojkov, B. (2011) Estimating northern hemisphere snow water equivalent for climate research through assimilation of space-borne radiometer data and ground-based measurements. *Remote Sensing of Environment*.
- Tonietto, L., Gonzaga, L., Veronez, M. R., Kazmierczak, C. de S., Arnold, D. C. M. et Costa, C.

- A. da (2019) New Method for Evaluating Surface Roughness Parameters Acquired by Laser Scanning. *Scientific Reports*, vol. 9, n°1, p. 1-16.
- Toure, A. M., Goïta, K., Royer, A., Kim, E. J., Durand, M., Margulis, S. A. et Lu, H. (2011) A case study of using a multilayered thermodynamical snow model for radiance assimilation. *IEEE Transactions on Geoscience and Remote Sensing*.
- Trudel, M., Charbonneau, F., Avendano, F. et Leconte, R. (2010) Quick Profiler (QuiP): A friendly tool to extract roughness statistical parameters using a needle profiler. *Canadian Journal of Remote Sensing*, vol. 36, n°4, p. 391-396.
- Tsang, L., Chen, C. Te, Chang, A. T. C., Guo, J. et Ding, K. H. (2000) Dense media radiative transfer theory based on quasicrystalline approximation with applications to passive microwave remote sensing of snow. *Radio Science*.
- Tsang, L., Kong, J. A. et Ding, K. H. (2000) *Scattering of Electromagnetic Waves Vol1* (Vol. 1). New York : John Wiley & Sons, Inc.
- Turner, R., Panciera, R., Tanase, M. A., Lowell, K., Hacker, J. M. et Walker, J. P. (2014) Estimation of soil surface roughness of agricultural soils using airborne LiDAR. *Remote Sensing of Environment*, vol. 140, p. 107-117.
- Vargel, C., Royer, A., St-jean-rondeau, O., Picard, G., Roy, A., Sasseville, V. et Langlois, A. (2020) Remote Sensing of Environment Arctic and subarctic snow microstructure analysis for microwave brightness temperature simulations. *Remote Sensing of Environment*, vol. 242, n°March, p. 111754.
- Vionnet, V., Brun, E., Morin, S., Boone, A., Faroux, S., Le Moigne, P., Martin, E. et Willemet, J. M. (2012) The detailed snowpack scheme Crocus and its implementation in SURFEX v7.2. *Geoscientific Model Development*, vol. 5, n°3, p. 773-791.
- Wang, J. R. et Choudhury, B. J. (1981) Remote sensing of soil moisture content over bare field at 1.4 GHz frequency. *Journal of Geophysical Research*, vol. 86, n°C6, p. 5277-5282.
- Wang, J. R., O'Neill, P. E., Jackson, T. J. et Engman, E. T. (1983) Multifrequency Measurements of the Effects of Soil Moisture, Soil Texture, And Surface Roughness. *IEEE Transactions on Geoscience and Remote Sensing*, vol. GE-21, n°1, p. 44-51.
- Wang, S., Sun, Q., Wang, N. et Yang, L. (2020) Variation in the dielectric constant of limestone with temperature. *Bulletin of Engineering Geology and the Environment*, vol. 79, n°3, p. 1349-1355.
- Wegmüller, U. et Mätzler, C. (1999) Rough bare soil reflectivity model. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, n°3 I, p. 1391-1395.
- Weiss, A. D. (2000) Topographic Position and Landforms analysis. Poster presentation, ESRI User Conference, San Diego, CA, vol. 64, p. 227-245.
- Wiesmann, A. et Mätzler, C. (1999) Microwave emission model of layered snowpacks. *Remote Sensing of Environment*.
- Winstral, A., Elder, K. et Davis, R. E. (2002) Spatial Snow Modeling of Wind-Redistributed Snow Using Terrain-Based Parameters. *Journal of Hydrometeorology*, vol. 3, n°5, p. 524-538.

Zhang, L., Shi, J., Zhang, Z. et Zhao, K. (2003) The estimation of dielectric constant of frozen soil-water mixture at microwave bands. International Geoscience and Remote Sensing Symposium (IGARSS), vol. 4, n°40271080, p. 2903-2905.

Zhang, L., Zhao, T., Jiang, L. et Zhao, S. (2010) Estimate of phase transition water content in freeze-thaw process using microwave radiometer. IEEE Transactions on Geoscience and Remote Sensing, vol. 48, n°12, p. 4248-4255.

7 Conclusion

La recherche présentée dans cette thèse a permis de mieux comprendre comment les variables d'état de surface (neige et sol) affectent la modélisation du transfert radiatif de la neige arctique. Les chapitres ont analysé à différentes échelles l'impact de ces variables et des processus qui y sont rattachés (ex. redistribution de la neige par le vent) sur les propriétés du manteau neigeux arctique. Plus spécifiquement, le chapitre 4 explore les caractéristiques contrôlant les processus de distribution (topographie et végétation) de la hauteur de neige à l'aide de l'algorithme *Random Forest* (RF). Le chapitre 5 propose une amélioration de la paramétrisation de la neige en incorporant la variabilité de la hauteur et microstructure de la neige à l'aide de mesures *in-situ*. Finalement, le chapitre 6 évalue la paramétrisation du sol gelé dans le transfert radiatif à l'aide d'observations *in-situ* en proposant une méthode de mesure de rugosité du sol. Ces trois chapitres ont donc permis d'analyser ces propriétés géophysiques du couvert nival en utilisant des outils de télédétection et de modélisation pour diminuer l'erreur de l'estimation de l'ÉEN à grande échelle liée à la variabilité spatiale locale, tout en améliorant la compréhension des processus locaux gouvernant cette variabilité.

L'algorithme RF, entraîné à partir de paramètres topographiques et écologiques a permis une première prédiction à haute résolution dans l'Arctique, à partir d'une méthode initialement développée pour le milieu alpin (Revuelto *et al.*, 2020). Pour toute application nécessitant une information du couvert nival à l'échelle locale (10 m - 1 km), l'algorithme RF jumelé au MNT *Arctic DEM* permet donc de répliquer le patron spatial de la distribution de neige contenue dans les données d'entraînement. Ce genre de prédiction constitue un élément novateur tenté pour la première fois pour la modélisation de la neige en Arctique. Ceci est particulièrement intéressant pour la modélisation du pergélisol en Arctique par exemple, qui pourrait bénéficier d'une représentation à haute résolution (10 m) des zones d'accumulation et érosion de la neige (Gisnas *et al.*, 2016). La capacité des algorithmes d'intelligence artificielle à répliquer le patron spatial du couvert de neige est une opportunité qui mérite d'être approfondie et aussi appliquée à différents types d'études, notamment pour des applications hydrologiques ou encore de géorisques liés au couvert nival (ex. inondations, avalanches). Plus spécifique à cette thèse, RF pourrait être utilisé pour prédire le CV_{sd} à l'aide de paramètres topographiques pour des pixels (25km) de PMW satellitaires. Cette prédiction serait particulièrement intéressante dans la paramétrisation de la

variabilité spatiale de la hauteur de neige (chapitre 5) dans des produits opérationnels comme GlobSnow 3.0 (Pulliainen *et al.*, 2020).

L'ajout de variabilité de la neige intrapixel a permis d'améliorer les simulations de température de brillance micro-ondes avec le code SMRT par rapport à un manteau neigeux spatialement uniforme. Les simulations démontrent que la variabilité intrapixel influence la T_B et doit être prise en compte. En plus de considérer la variation de la hauteur de neige (CV_{sd}), la variation de l'épaisseur des principales couches du couvert nival y est ajoutée en utilisant le lien entre l'épaisseur totale et la fraction de givre de profondeur (DHF). Ce type de paramétrisation constitue une avenue originale pour la simulation micro-ondes du manteau neigeux en mode passif et pourrait être utilisé dans l'assimilation de mesures PMW satellitaires pour l'estimation du ÉEN comme le produit GlobSnow 3.0. La variabilité de la neige étant un processus bien connu, ce travail constitue une première dans la modélisation du transfert radiatif en allant contre l'hypothèse que la neige est uniforme à l'intérieur d'un pixel de 25km. De plus, la paramétrisation de la variabilité de la neige intrapixel du manteau arctique pourrait être bénéfique dans d'autres domaines de modélisation (climatique, météorologique, flux de carbone ou pergélisol) qui incorpore des mesures de PMW avec un modèle de transfert radiatif.

La paramétrisation en transfert radiatif du sol gelé a permis d'investiguer l'effet de la rugosité et de la permittivité du sol. Une méthode de mesure de la rugosité basée sur la photogrammétrie a permis d'optimiser la permittivité à partir d'observations radiométriques au sol et de comparer trois modèles de réflectivité du sol disponibles dans SMRT. Cette méthode a aussi permis d'obtenir une rugosité micro-ondes paramétrée en 3D avec SfM ce qui est une première dans le transfert radiatif de la neige. De plus, ce travail a permis de quantifier ce paramètre (rugosité) qui était jusqu'à aujourd'hui difficilement quantifiable ou mesurable. Cette méthode offre donc une méthodologie simple et efficace afin de mesurer la rugosité lors de validations radiométriques terrestres. La méthode présentée dans le chapitre 6 pourrait être utilisée lors des futures validations terrains du radar dual-Ku en vue de la prochaine mission satellite canadienne pour l'observation de la neige (Garnaud *et al.*, 2019).

7.1 Perspectives et projets futurs

Des travaux futurs pourraient se concentrer sur la prédition de CV_{sd} à l'aide de paramètres topographiques comme mentionnés plus haut. Ce genre de travail pourrait non seulement bénéficier la paramétrisation de la variabilité en transfert radiatif, mais aussi les études climatiques et hydrologiques qui prennent déjà en compte ce paramètre. Ce travail nécessiterait des cartes de hauteur de neige (LIDAR ou SfM) par RPAS ou avion qui couvre des zones $> 1\ 000\ km^2$ (ou plusieurs pixels de 25km), mais permettrait de mieux comprendre ce qui influence le CV_{sd} . Par la suite, il serait intéressant de comparer des simulations SMRT basées sur ces valeurs prédites de CV_{sd} avec des mesures de capteurs satellitaires ou aéroportés.

De plus, des travaux futurs pourraient également regarder l'influence de la variabilité sur des simulations SMRT en mode actif. Il a été montré dans le chapitre 5 que la variabilité de la neige arctique doit être prise en compte lors de simulation en micro-ondes passives à 37 GHz. L'influence combinée de la variation du DHF et de la variation de la hauteur de neige (CV_{sd}) modifie la diffusion du manteau neigeux et par conséquent influence la T_B . Il serait pertinent de continuer ce type d'analyse avec un capteur actif (Radar à synthèse d'ouverture, SAR) et analyser comment la variabilité influence le coefficient de rétrodiffusion. Le modèle SMRT permettrait de faire des simulations en mode actif et d'utiliser les mêmes relations et paramètres *in-situ* du manteau neigeux présenté dans le chapitre 5.

La méthode de mesure de rugosité présentée dans le chapitre 6 pourrait être étendue aux interfaces du manteau neigeux. Le modèle SMRT peut tenir compte de la rugosité des interfaces air-neige, neige-sol et entre-deux couches de neige. Dans cette thèse, la rugosité du sol est seulement utilisée pour moduler l'émission du sol alors que toutes les interfaces sont considérées comme plat. La méthode de mesure de rugosité du sol pourrait être utilisée telle quelle pour estimer l'interface neige-sol alors qu'une nouvelle technique utilisant une caméra proche infrarouge devra être mise au point afin d'estimer la rugosité des autres interfaces.

Les trois articles (Chapitres 4, 5 et 6) présentés dans cette thèse visent à être utilisés dans un produit tel que GlobSnow 3.0 ou d'autres méthodes d'assimilation (Helmert et al., 2018) utilisant une

inversion de modèle RT dans le but d'obtenir des informations sur le couvert nival. Les modèles de ÉEN globaux pourraient bénéficier d'une meilleure représentation de la neige arctique et les papiers présentés dans le chapitre 5 et 6 offrent des paramétrisations en RT du sol et de la neige mieux adaptées aux conditions uniques de l'arctique. Cette thèse a donc analysé à l'échelle locale le manteau neigeux et a permis de mieux caractériser le couvert neigeux arctique pour améliorer les produits globaux de ÉEN.

8 Références (hors articles)

- AMAP (2019) Arctic Climate Change Update 2019, p. 12.
- Armstrong, R. L. et Brodzik, M. J. (1995) An earth-gridded SSM/I data set for cryospheric studies and global change monitoring. *Advances in Space Research*.
- Asmus, K. W. et Grant, C. (1999) Surface Based Radiometer (SBR) Data Acquisition System. *International Journal of Remote Sensing*, vol. 20, n°15-16, p. 3125-3129.
- Bartelt, P. et Lehning, M. (2002) A physical SNOWPACK model for the Swiss avalanche warning. *Cold Regions Science and Technology*, vol. 35, n°3, p. 123-145.
- Benson, C. S. et Sturm, M. (1993) Structure and wind transport of seasonal snow on the Arctic slope of Alaska. *Annals of Glaciology*, vol. 18, n°January 1993, p. 261-267.
- Böttcher, K., Aurela, M., Kervinen, M., Markkanen, T., Mattila, O. P., Kolari, P., Metsämäki, S., Aalto, T., Arslan, A. N. et Pulliainen, J. (2014) MODIS time-series-derived indicators for the beginning of the growing season in boreal coniferous forest - A comparison with CO₂ flux measurements and phenological observations in Finland. *Remote Sensing of Environment*.
- Breiman, L. (2001) Random forests. *Machine Learning*.
- Brodzik, M. J., Long, D. G. et Hardman, M. A. (2018) Best practices in crafting the calibrated, Enhanced-Resolution passive-microwave EASE-Grid 2.0 brightness temperature Earth System Data Record. *Remote Sensing*, vol. 10, n°11.
- Chang, A. T. C., Foster, J. L., Hall, D. K., Rango, A. et Hartline, B. K. (1982) Snow water equivalent estimation by microwave radiometry. *Cold Regions Science and Technology*.
- Clark, M. P., Hendrikx, J., Slater, A. G., Kavetski, D., Anderson, B., Cullen, N. J., Kerr, T., Örn Hreinsson, E. et Woods, R. A. (2011) Representing spatial variability of snow water equivalent in hydrologic and land-surface models: A review. *Water Resources Research*, vol. 47, n°7.
- Davesne, G., Domine, F. et Fortier, D. (2021) Effects of meteorology and soil moisture on the spatio-temporal evolution of the depth hoar layer in the polar desert snowpack. *Journal of Glaciology*, p. 1-16.
- Derksen, C., Burgess, D., Duguay, C., Howell, S., Mudryk, L., Smith, S., Thackeray, C. et Kirchmeier-Young, M. (2019) Changes in Snow, Ice, and Permafrost Across Canada. *Canada's Changing Climate Report*, p. 194-260.
- Derksen, C., Lemmetyinen, J., Toose, P., Silis, A., Pulliainen, J. et Sturm, M. (2014) Physical properties of Arctic versus subarctic snow: Implications for high latitude passive microwave snow water equivalent retrievals. *Journal of Geophysical Research: Atmospheres*, vol. 119, n°12, p. 7254-7270.
- Derksen, C., Toose, P., Lemmetyinen, J., Pulliainen, J., Langlois, A., Rutter, N. et Fuller, M. C. (2012) Evaluation of passive microwave brightness temperature simulations and snow water

- equivalent retrievals through a winter season. *Remote Sensing of Environment*, vol. 117, p. 236-248.
- DerkSEN, C., Toose, P., Rees, A., Wang, L., English, M., Walker, A. et Sturm, M. (2010) Development of a tundra-specific snow water equivalent retrieval algorithm for satellite passive microwave data. *Remote Sensing of Environment*.
- Domine, F., Barrere, M. et Morin, S. (2016) The growth of shrubs on high Arctic tundra at Bylot Island: Impact on snow physical properties and permafrost thermal regime. *Biogeosciences*, vol. 13, n°23, p. 6471-6486.
- Domine, F., Picard, G., Morin, S., Barrere, M., Madore, J.-B. et Langlois, A. (2018) Major Issues in Simulating some Arctic Snowpack Properties Using Current Detailed Snow Physics Models. Consequences for the Thermal Regime and Water Budget of Permafrost. *Journal of Advances in Modeling Earth Systems*, n°December 2018.
- Fung, A. K. (1994) Microwave scattering and emission models and their applications. Boston : Artech House Publishers.
- Gallet, J. C., Domine, F., Zender, C. S. et Picard, G. (2009) Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm. *Cryosphere*, vol. 3, n°2, p. 167-182.
- Garnaud, C., Bélair, S., Carrera, M. L., Derksen, C., Bilodeau, B., Abrahamowicz, M., Gauthier, N. et Vionnet, V. (2019) Quantifying Snow Mass Mission Concept Trade-Offs Using an Observing System Simulation Experiment. *Journal of Hydrometeorology*, vol. 20, n°1, p. 155-173.
- Gisnas, K., Westermann, S., Vikhamar Schuler, T., Melvold, K. et Etzelmüller, B. (2016) Small-scale variation of snow in a regional permafrost model. *Cryosphere*, vol. 10, n°3, p. 1201-1215.
- Goosse, H., Kay, J. E., Armour, K. C., Bodas-salcedo, A., Chepfer, H., Docquier, D., Jonko, A., Kushner, P. J., Lecomte, O., Massonnet, F., Park, H., Pithan, F., Svensson, G. et Vancoppenolle, M. (2018) Quantifying climate feedbacks in polar regions. *Nature Communications*.
- Gouttevin, I., Langer, M., Löwe, H., Boike, J., Proksch, M. et Schneebeli, M. (2018) Observation and modelling of snow at a polygonal tundra permafrost site: Spatial variability and thermal implications. *Cryosphere*, vol. 12, n°11, p. 3693-3717.
- Grünewald, T., Stötter, J., Pomeroy, J. W., Dadic, R., Moreno Baños, I., Marturià, J., Sross, M., Hopkinson, C., Burlando, P. et Lehning, M. (2013) Statistical modelling of the snow depth distribution in open alpine terrain. *Hydrology and Earth System Sciences*, vol. 17, n°8, p. 3005-3021.
- Hall, D. K., Riggs, G. A., Salomonson, V. V., DiGirolamo, N. E. et Bayr, K. J. (2002) MODIS snow-cover products. *Remote Sensing of Environment*, vol. 83, n°1-2, p. 181-194.
- Helmut, J., Şorman, A. Ş., Montero, R. A., de Michele, C., de Rosnay, P., Dumont, M., Finger, D. C., Lange, M., Picard, G., Potopová, V., Pullen, S., Vikhamar-Schuler, D., & Arslan, A. N. (2018). Review of snow data assimilation methods for hydrological, land surface, meteorological and climate models: Results from a COST harmonosnow survey. *Geosciences*

(Switzerland), 8(12). <https://doi.org/10.3390/geosciences8120489>

- James, M. R., Robson, S. et Smith, M. W. (2017) 3-D uncertainty-based topographic change detection with structure-from-motion photogrammetry: precision maps for ground control and directly georeferenced surveys. *Earth Surface Processes and Landforms*, vol. 42, n°12, p. 1769-1788.
- Kelly, R. E., Chang, A. T., Tsang, L. et Foster, J. L. (2003) A prototype AMSR-E global snow area and snow depth algorithm. *IEEE Transactions on Geoscience and Remote Sensing*.
- King, J., Derksen, C., Toose, P., Langlois, A., Larsen, C., Lemmetyinen, J., Marsh, P., Montpetit, B., Roy, A., Rutter, N. et Sturm, M. (2018) The influence of snow microstructure on dual-frequency radar measurements in a tundra environment. *Remote Sensing of Environment*, vol. 215, n°May, p. 242-254.
- King, J., Kelly, R., Kasurak, A., Duguay, C., Gunn, G., Rutter, N., Watts, T. et Derksen, C. (2015) Spatio-temporal influence of tundra snow properties on Ku-band (17.2 GHz) backscatter. *Journal of Glaciology*, vol. 61, n°226, p. 267-279.
- Kong, J. A. et Tsang, L. (2001) Scattering of Electromagnetic Waves Vol3 (Vol. 9). New York : John Wiley & Sons, Inc.
- Krol, Q. et Löwe, H. (2016) Relating optical and microwave grain metrics of snow: The relevance of grain shape. *Cryosphere*, vol. 10, n°6, p. 2847-2863.
- Langlois, A., Bergeron, J., Brown, R., Royer, A., Harvey, R., Roy, A., Wang, L. et Thériault, N. (2014) Evaluation of CLASS 2.7 and 3.5 Simulations of Snow Properties from the Canadian Regional Climate Model (CRCM4) over Québec, Canada*. *Journal of Hydrometeorology*, vol. 15, n°4, p. 1325-1343.
- Langlois, A., Royer, A., Derksen, C., Montpetit, B., Dupont, F. et Gota, K. (2012) Coupling the snow thermodynamic model SNOWPACK with the microwave emission model of layered snowpacks for subarctic and arctic snow water equivalent retrievals. *Water Resources Research*, vol. 48, n°12.
- Larue, F., Royer, A., De Sève, D., Roy, A. et Cosme, E. (2018) Assimilation of passive microwave AMSR-2 satellite observations in a snowpack evolution model over northeastern Canada. *Hydrology and Earth System Sciences*, vol. 22, n°11, p. 5711-5734.
- Liebe, H. J. (1989) MPM-An atmospheric millimeter-wave propagation model. *International Journal of Infrared and Millimeter Waves*, vol. 10, n°6, p. 631-650.
- Liston, G. E. (2004) Representing subgrid snow cover heterogeneities in regional and global models. *Journal of Climate*, vol. 17, n°6, p. 1381-1397.
- Lowe, D. G. (2004) Distinctive image features from scale invariant keypoints. *International Journal of Computer Vision*, vol. 60, p. 91-11020042.
- Luoju, K., Pulliainen, J., Takala, M., Derksen, C., Rott, H., Nagler, T., Solberg, R., Wiesmann, A., Metsamaki, S., Malnes, E. et Bojkov, B. (2011) Investigating the feasibility of the globssnow snow water equivalent data for climate research purposes.
- Martinez-Agirre, A., Álvarez-Mozos, J., Milenković, M., Pfeifer, N., Giménez, R., Valle Melón, J. M. et Rodríguez Miranda, Á. (2019) Evaluation of Terrestrial Laser Scanner and

- Structure from Motion photogrammetry techniques for quantifying soil surface roughness parameters over agricultural soils. *Earth Surface Processes and Landforms*, p. esp.4758.
- Mavrovic, A., Pardo Lara, R., Berg, A., Demontoux, F., Royer, A. et Roy, A. (2021) Soil dielectric characterization during freeze-Thaw transitions using L-band coaxial and soil moisture probes. *Hydrology and Earth System Sciences*, vol. 25, n°3, p. 1117-1131.
- Mironov, V. L., Kosolapova, L. G., Fomin, S. V., Savin, I. V. et Muzalevskiy, K. V. (2015) Dielectric model for thawed and frozen organic soils at 1.4 GHz. *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 2015-July, p. 7180-7183.
- Mo, T. et Schmugge, T. J. (1987) A Parameterization of the Effect of Surface Roughness on Microwave Emission. *IEEE Transactions on Geoscience and Remote Sensing*, vol. GE-25, n°4, p. 481-486.
- Montpetit, B., Royer, A., Langlois, A., Cliché, P., Roy, A., Champollion, N., Picard, G., Domine, F. et Obbard, R. (2012) New shortwave infrared albedo measurements for snow specific surface area retrieval. *Journal of Glaciology*, vol. 58, n°211, p. 941-952.
- Montpetit, B., Royer, A., Roy, A. et Langlois, A. (2018) In-situ passive microwave emission model parameterization of sub-arctic frozen organic soils. *Remote Sensing of Environment*, vol. 205, n°November 2017, p. 112-118.
- Montpetit, B., Royer, A., Wigneron, J. P., Chanzy, A. et Mialon, A. (2015) Evaluation of multi-frequency bare soil microwave reflectivity models. *Remote Sensing of Environment*, vol. 162, p. 186-195.
- Natali, S. M., Watts, J. D., Rogers, B. M., Potter, S., Ludwig, S. M., Selbmann, A.-K., Sullivan, P. F., Abbott, B. W., Arndt, K. A., Birch, L., Björkman, M. P., Bloom, A. A., Celis, G., Christensen, T. R., Christiansen, C. T., Commane, R., Cooper, E. J., Crill, P., Czimczik, C., Davydov, S., Du, J., Egan, J. E., Elberling, B., Euskirchen, E. S., Friborg, T., Genet, H., Göckede, M., Goodrich, J. P., Grogan, P., Helbig, M., Jafarov, E. E., Jastrow, J. D., Kalhori, A. A. M., Kim, Y., Kimball, J. S., Kutzbach, L., Lara, M. J., Larsen, K. S., Lee, B.-Y., Liu, Z., Loranty, M. M., Lund, M., Lupascu, M., Madani, N., Malhotra, A., Matamala, R., McFarland, J., McGuire, A. D., Michelsen, A., Minions, C., Oechel, W. C., Olefeldt, D., Parmentier, F.-J. W., Pirk, N., Poulter, B., Quinton, W., Rezanezhad, F., Risk, D., Sachs, T., Schaefer, K., Schmidt, N. M., Schuur, E. A. G., Semenchuk, P. R., Shaver, G., Sonnentag, O., Starr, G., Treat, C. C., Waldrop, M. P., Wang, Y., Welker, J., Wille, C., Xu, X., Zhang, Z., Zhuang, Q. et Zona, D. (2019) Large loss of CO₂ in winter observed across the northern permafrost region. *Nature Climate Change*, vol. 9, n°11, p. 852-857.
- Nitta, T., Yoshimura, K., Takata, K., O'ishi, R., Sueyoshi, T., Kanae, S., Oki, T., Abe-Ouchi, A. et Liston, G. E. (2014) Representing variability in subgrid snow cover and snow depth in a global land model: Offline validation. *Journal of Climate*, vol. 27, n°9, p. 3318-3330.
- Notz, D. et Stroeve, J. (2016) Observed Arctic sea-ice loss directly follows anthropogenic CO₂ emission. *Science*, vol. 354, n°6313, p. 747-750.
- Ouellet, F., Langlois, A., Blukacz-Richards, E. A., Johnson, C. A., Royer, A., Neave, E. et Larter, N. C. (2017) Spatialization of the SNOWPACK snow model for the Canadian Arctic to assess Peary caribou winter grazing conditions. *Physical Geography*, vol. 38, n°2, p. 143-158.

- Parr, C., Sturm, M. et Larsen, C. (2020) Snowdrift Landscape Patterns: An Arctic Investigation. *Water Resources Research*, vol. 56, n°12.
- Picard, G., Brucker, L., Roy, A., Dupont, F., Fily, M., Royer, A. et Harlow, C. (2013) Simulation of the microwave emission of multi-layered snowpacks using the Dense Media Radiative transfer theory: the DMRT-ML model. *Geoscientific Model Development*, vol. 6, n°4, p. 1061-1078.
- Picard, G., Sandells, M. et Löwe, H. (2018) SMRT: An active-passive microwave radiative transfer model for snow with multiple microstructure and scattering formulations (v1.0). *Geoscientific Model Development*, vol. 11, n°7, p. 2763-2788.
- Prince, M., Roy, A., Brucker, L., Royer, A., Kim, Y. et Zhao, T. (2018) Northern hemisphere surface freeze-thaw product from aquarius L-band radiometers. *Earth System Science Data*, vol. 10, n°4, p. 2055-2067.
- Proksch, M., Löwe, H. et Schneebeli, M. (2015) Density, specific surface area, and correlation length of snow measured by high-resolution penetrometry. *Journal of Geophysical Research: Earth Surface*, vol. 120, n°2, p. 346-362.
- Proksch, M., Rutter, N., Fierz, C. et Schneebeli, M. (2016) Intercomparison of snow density measurements: Bias, precision, and vertical resolution. *Cryosphere*.
- Pulliainen, J. (2006) Mapping of snow water equivalent and snow depth in boreal and sub-arctic zones by assimilating space-borne microwave radiometer data and ground-based observations. *Remote Sensing of Environment*, vol. 101, n°2, p. 257-269.
- Pulliainen, J. et Hallikainen, M. T. (2001) Retrieval of Regional Snow Water Equivalent from Space-Borne Passive Microwave Observations. *Remote Sensing of Environment*, vol. 75, n°1, p. 76-85.
- Pulliainen, J., Luojus, K., Derksen, C., Mudryk, L., Lemmetyinen, J., Salminen, M., Ikonen, J., Takala, M., Cohen, J., Smolander, T. et Norberg, J. (2020) Patterns and trends of Northern Hemisphere snow mass from 1980 to 2018. *Nature*, vol. 581, n°7808, p. 294-298.
- Pulwicki, A., Flowers, G. E., Radic, V. et Bingham, D. (2018) Estimating winter balance and its uncertainty from direct measurements of snow depth and density on alpine glaciers. *Journal of Glaciology*, vol. 64, n°247, p. 781-795.
- Revuelto, J., Billecocq, P., Tuzet, F., Cluzet, B., Lamare, M., Larue, F. et Dumont, M. (2020) Random forests as a tool to understand the snow depth distribution and its evolution in mountain areas. *Hydrological Processes*, n°October, p. hyp.13951.
- Richter-Menge, J., Overland, J. E., Mathis, J. T. et Osborne, E. (2017) Arctic Report Card 2017, p. 1-96.
- Romanovsky, V. E., Smith, S. L. et Christiansen, H. H. (2010) Permafrost thermal state in the polar northern hemisphere during the international polar year 2007-2009: A synthesis. *Permafrost and Periglacial Processes*, vol. 21, n°2, p. 106-116.
- Roy, A., Royer, A., St-Jean-Rondeau, O., Montpetit, B., Picard, G., Mavrovic, A., Marchand, N. et Langlois, A. (2016) Microwave snow emission modeling uncertainties in boreal and subarctic environments. *The Cryosphere*, vol. 10, n°2, p. 623-638.

- Roy, A., Royer, A., Wigneron, J. P., Langlois, A., Bergeron, J. et Cliche, P. (2012) A simple parameterization for a boreal forest radiative transfer model at microwave frequencies. *Remote Sensing of Environment*, vol. 124, p. 371-383.
- Roy, V., Goita, K., Royer, A., Walker, A. E. et Goodison, B. E. (2004) Snow water equivalent retrieval in a Canadian boreal environment from microwave measurements using the HUT snow emission model. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, n°9, p. 1850-1859.
- Rutter, N., Sandells, M., Derksen, C., Toose, P., Royer, A., Montpetit, B., Langlois, A., Lemmetyinen, J. et Pulliainen, J. (2014) Snow stratigraphic heterogeneity within ground-based passive microwave radiometer footprints: Implications for emission modeling. *Journal of Geophysical Research: Earth Surface*, vol. 119, n°3, p. 550-565.
- Rutter, N., Sandells, M. J., Derksen, C., King, J., Toose, P., Wake, L., Watts, T., Essery, R., Roy, A., Royer, A., Marsh, P., Larsen, C. et Sturm, M. (2019) Effect of snow microstructure variability on Ku-band radar snow water equivalent retrievals. *The Cryosphere*, vol. 13, n°11, p. 3045-3059.
- Saberi, N., Kelly, R., Flemming, M. et Li, Q. (2020) Review of snow water equivalent retrieval methods using spaceborne passive microwave radiometry. *International Journal of Remote Sensing*, vol. 41, n°3, p. 996-1018.
- Saberi, N., Kelly, R., Pan, J., Durand, M., Goh, J. et Scott, K. A. (2020) The Use of a Monte Carlo Markov Chain Method for Snow-Depth Retrievals: A Case Study Based on Airborne Microwave Observations and Emission Modeling Experiments of Tundra Snow. *IEEE Transactions on Geoscience and Remote Sensing*, p. 1-14.
- Sandells, M., Lowe, H., Picard, G., Dumont, M., Essery, R., Floury, N., Kontu, A., Lemmetyinen, J., Maslanka, W., Morin, S., Wiesmann, A. et Matzler, C. (2021) X-Ray Tomography-Based Microstructure Representation in the Snow Microwave Radiative Transfer Model. *IEEE Transactions on Geoscience and Remote Sensing*, p. 1-15.
- Santos, P. M. D. et Júlio, E. N. B. S. (2013) A state-of-the-art review on roughness quantification methods for concrete surfaces. *Construction and Building Materials*, vol. 38, p. 912-923.
- Screen, J. A. et Simmonds, I. (2010) The central role of diminishing sea ice in recent Arctic temperature amplification. *Nature*, vol. 464, n°7293, p. 1334-1337.
- Serreze, M. C. et Barry, R. G. (2011) Processes and impacts of Arctic amplification: A research synthesis. *Global and Planetary Change*, vol. 77, n°1-2, p. 85-96.
- Stieglitz, M., Déry, S. J., Romanovsky, V. E. et Osterkamp, T. E. (2003) The role of snow cover in the warming of arctic permafrost. *Geophysical Research Letters*, vol. 30, n°13.
- Sturm, M., McFadden, J. P., Liston, G. E., Stuart Chapin, F., Racine, C. H. et Holmgren, J. (2001) Snow-shrub interactions in Arctic Tundra: A hypothesis with climatic implications. *Journal of Climate*.
- Sturm, M. et Wagner, A. M. (2010) Using repeated patterns in snow distribution modeling: An Arctic example. *Water Resources Research*, vol. 46, n°12, p. 1-15.
- Takala, M., Luojus, K., Pulliainen, J., Derksen, C., Lemmetyinen, J., Kärnä, J. P., Koskinen, J. et Bojkov, B. (2011) Estimating northern hemisphere snow water equivalent for climate

research through assimilation of space-borne radiometer data and ground-based measurements. *Remote Sensing of Environment*.

- Tonietto, L., Gonzaga, L., Veronez, M. R., Kazmierczak, C. de S., Arnold, D. C. M. et Costa, C. A. da (2019) New Method for Evaluating Surface Roughness Parameters Acquired by Laser Scanning. *Scientific Reports*, vol. 9, n°1, p. 1-16.
- Toure, A. M., Goïta, K., Royer, A., Kim, E. J., Durand, M., Margulis, S. A. et Lu, H. (2011) A case study of using a multilayered thermodynamical snow model for radiance assimilation. *IEEE Transactions on Geoscience and Remote Sensing*.
- Trudel, M., Charbonneau, F., Avendano, F. et Leconte, R. (2010) Quick Profiler (QuiP): A friendly tool to extract roughness statistical parameters using a needle profiler. *Canadian Journal of Remote Sensing*, vol. 36, n°4, p. 391-396.
- Tsang, L., Chen, C. Te, Chang, A. T. C., Guo, J. et Ding, K. H. (2000) Dense media radiative transfer theory based on quasicrystalline approximation with applications to passive microwave remote sensing of snow. *Radio Science*.
- Tsang, L., Kong, J. A. et Ding, K. H. (2000) *Scattering of Electromagnetic Waves Vol1 (Vol. 1)*. New York : John Wiley & Sons, Inc.
- Turner, R., Panciera, R., Tanase, M. A., Lowell, K., Hacker, J. M. et Walker, J. P. (2014) Estimation of soil surface roughness of agricultural soils using airborne LiDAR. *Remote Sensing of Environment*, vol. 140, p. 107-117.
- Vargel, C., Royer, A., St-jean-rondeau, O., Picard, G., Roy, A., Sasseville, V. et Langlois, A. (2020) Remote Sensing of Environment Arctic and subarctic snow microstructure analysis for microwave brightness temperature simulations. *Remote Sensing of Environment*, vol. 242, n°March, p. 111754.
- Vionnet, V., Brun, E., Morin, S., Boone, A., Faroux, S., Le Moigne, P., Martin, E. et Willemet, J. M. (2012) The detailed snowpack scheme Crocus and its implementation in SURFEX v7.2. *Geoscientific Model Development*, vol. 5, n°3, p. 773-791.
- Wang, J. R. et Choudhury, B. J. (1981) Remote sensing of soil moisture content over bare field at 1.4 GHz frequency. *Journal of Geophysical Research*, vol. 86, n°C6, p. 5277-5282.
- Wang, J. R., O'Neill, P. E., Jackson, T. J. et Engman, E. T. (1983) Multifrequency Measurements of the Effects of Soil Moisture, Soil Texture, And Surface Roughness. *IEEE Transactions on Geoscience and Remote Sensing*, vol. GE-21, n°1, p. 44-51.
- Wang, S., Sun, Q., Wang, N. et Yang, L. (2020) Variation in the dielectric constant of limestone with temperature. *Bulletin of Engineering Geology and the Environment*, vol. 79, n°3, p. 1349-1355.
- Wegmüller, U. et Mätzler, C. (1999) Rough bare soil reflectivity model. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, n°3 I, p. 1391-1395.
- Weiss, A. D. (2000) Topographic Position and Landforms analysis. Poster presentation, ESRI User Conference, San Diego, CA, vol. 64, p. 227-245.
- Wiesmann, A. et Mätzler, C. (1999) Microwave emission model of layered snowpacks. *Remote Sensing of Environment*.

- Winstral, A., Elder, K. et Davis, R. E. (2002) Spatial Snow Modeling of Wind-Redistributed Snow Using Terrain-Based Parameters. *Journal of Hydrometeorology*, vol. 3, n°5, p. 524-538.
- Zhang, L., Shi, J., Zhang, Z. et Zhao, K. (2003) The estimation of dielectric constant of frozen soil-water mixture at microwave bands. *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 4, n°40271080, p. 2903-2905.
- Zhang, L., Zhao, T., Jiang, L. et Zhao, S. (2010) Estimate of phase transition water content in freeze-thaw process using microwave radiometer. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, n°12, p. 4248-4255.

Annexe 1 : Publications

Meloche, J., Langlois, A., Rutter, N., Royer, McLennan, D., Billecocq, P., et Ponomarenko, S. High-resolution snow depth prediction using Random Forest algorithm with topographic parameters and an ecosystem map: a case study in the Greiner Watershed, Nunavut. *Hydrological Processes*, **Submitted**. November 2021

Contribution : Écriture du manuscrit original, investigation et analyse.

Meloche, J., Langlois, A., Rutter, N., Royer, King, J., Walker, B., Marsh, P., et Wilcox, E. Characterizing Tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals. *The Cryosphere Discussion*, **In revision**. May 2021

Contribution : Écriture du manuscrit original, investigation et analyse.

Meloche, J., Royer, A., Langlois, A., Rutter, N. et Sasseville, V. (2020) Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry. *International Journal of Digital Earth*, vol. 0, n°0, p. 1-17.

Contribution : Écriture du manuscrit original, Acquisition des données terrains, investigation et analyse.

Kramer, D., **Meloche, J.**, Langlois, A., McLennan, D., Gauthier-Barrette, C., Royer, A. and Cliche, P. 2019. Designing a DIY-UAV for arctic research purposes and proving its capabilities by retrieving snow depth via structure-from-motion, *Polar Knowledge: Aqhaliat 2019*, Polar Knowledge Canada, **Submitted**, March 2019.

Contribution : Écriture de la partie épaisseur de neige par RPAS, acquisition des données terrains, traitement des données et développement du prototype RPAS.

Annexe 2: Conférences

Meloche, J., Langlois, A., Rutter, N., Royer, King, J., Walker, B., Marsh, P., et Wilcox, E. Characterizing Tundra snow sub-pixel variability to improve brightness temperature estimation in satellite SWE retrievals AGU Fall meeting, Nouvelle-Orléans, United States, 2020 (Présentation orale) **À venir, Décembre 2021**

Meloche, J., Royer, A., Langlois, A., Rutter, N., Sasseville, V., Improvement of microwave emissivity parameterization of frozen Arctic soils using roughness measurements derived from photogrammetry. AGU virtual Fall meeting, San Fransisco, United States, 2020 (Présentation d'affiche)

Meloche, J., Kramer, D., Langlois, A., Rutter, N., McLennan, D., Royer, A. High resolution snow depth mapping using RPAS and kinematic dGPS in the canadian arctic. Eastern Snow Conference, Fairlee, Vermont, United States, 2019 (Présentation orale)

Meloche, J., Kramer, D., Langlois, A., Royer, A. High resolution mapping of snow depth using UAV and kinematic dGPS in the canadian arctic. Arctic Net annual conference, Ottawa, Canada, 2018 (Présentation d'affiche)

Annexe 3: Incertitudes

Tableau A-1 : Incertitudes sur les mesures des intrants de simulations du manteaux neigeux avec SMRT.

Intrant au simulation	Instrument	Incertitude
Densité	Couteaux à densité	10%
SSA	IRIS	10%
Température	Thermomètre digital de type sonde	0.5 K
Rugosité du sol	SfM	0.1 mm
Comparaison au simulation		
TB mesuré	Radiomètre terrestre	2K
	SSMIS	2K