

**DÉVELOPPEMENT D'UNE APPROCHE D'ESTIMATION DE LA  
DENSITÉ DU COUVERT NIVAL À L'AIDE DES DONNÉES DE  
TÉLÉDÉTECTION HYPERSPECTRALE PROXIMALE DANS  
L'INFRAROUGE PROCHE.**

Par

Mohamed Karim El Oufir

Thèse présentée pour l'obtention du grade de  
*Philosophiae Doctor* (Ph.D.)  
en sciences de l'eau

**Jury d'évaluation**

Examineur externe	Guillaume Fortin Université de Moncton
Examineur externe	Alexandre Roy Université du Québec à Trois Rivières
Examineur interne	Jean-Pierre Dedieu Université de Grenoble
Directeur de recherche	Karem Chokmani INRS Centre Eau-Terre-Environnement
Codirecteur de recherche	Monique Bernier INRS Centre Eau-Terre-Environnement



## DÉDICACE

À ma mère Fouzia Kabbaj, qui m'a aidée à devenir ce que je suis aujourd'hui,  
qui m'a entouré d'amour et d'affection, qu'elle repose en paix ;

À mon père Abdeslam El Oufir, qui fait tout pour ma réussite, que Dieu le  
protège ;

À ma chère épouse et fidèle compagne Laila Jabrane; à ma fille Louloua El  
Oufir et à mes futurs enfants, pour m'avoir accompagné dans les sacrifices  
consentis pour la réalisation de ce travail;

À mes sœurs, Niamate et Majdoline El Oufir, pour leurs amours et leurs  
solidarités ;

Que ce travail soit un exemple de détermination pour tous les membres de  
notre grande famille.

## REMERCIEMENTS

La présente thèse est le fruit de cinq années passées au sein de l'équipe de recherche en Télédétection Environnementale et Nordique (TENOR) du Centre Eau-Terre-Environnement (ETE) de l'Institut National de la Recherche Scientifique (INRS). Cette thèse n'aurait pas vu le jour sans la contribution ou l'encouragement de plusieurs personnes dont la liste est très longue. Les remercier comme il se doit et réussir à exprimer toute gratitude la plus sincère envers eux avec des mots justes me semble aujourd'hui bien plus délicat que de rédiger cette thèse. Alors merci :

À Monsieur **Karem Chokmani**, pour votre confiance, votre patience et votre investissement qu'il soit scientifique, moral ou financier. Merci de m'avoir donné la chance de travailler sur ce sujet à caractère multidisciplinaire tout au long de ces années. Depuis le début, j'ai su que le défi était énorme, mais je savais aussi que je pouvais compter sur un chercheur exceptionnel, dévoué, rigoureux et un homme humainement exceptionnel, afin de m'épauler et de m'assister à relever ce défi avec excellence.

Madame **Monique Bernier**, pour son enthousiasme, sa disponibilité, sa générosité de partage de son expertise en télédétection de la neige qui a amplement aidé à améliorer la qualité des travaux de cette thèse. Merci aussi au temps accordé et à la finesse des corrections qu'il soit aux articles ou aux différentes sections de cette thèse. En résumé, merci pour l'attention que vous m'avez manifestée tout au long de mes études à l'INRS.

À Monsieur **Anas El Alem**, merci d'avoir été toujours présent, et d'avoir été à l'écoute et pour vos prestigieuses remarques et commentaires en matière technique et vos conseils humains. Merci aussi pour toutes les corrections, notamment celle des articles. En résumé, merci pour l'attention que vous m'avez accordée tout au long de cette aventure.

Aux piliers de notre équipe de recherche, Monsieur le professeur Saeid Homayouni, Khalid Oubennaceur, Rachid Lhissou et Yves Gauthier.

Toute l'équipe de laboratoire TENOR, spécifiquement à Mesdames Sophie Roberge, Rabiaa Ben Aicha et à Messieurs Hachem Agili, et Jimmy Poulin.

Mesdames : Amina Bendida, Lyz'andr Cloutier Shaw, et Messieurs : Salah Radi, Radouane Boulafrouh, Jalal Khalasi, Ahmed El Oufir, Ahmed Jabrane, Mohamed Amine Laadila, Zine el-Abidine El Alaoui, Kamal Aboutabit, Raâfat Sirajeddine, Said Ouziad, Talbi Mohamed, etc. Bref, à tous mes ami(e)s.

Enfin, merci aux membres du jury d'évaluation Messieurs Jean-Pierre Dedieu, Alexandre Roy et Guillaume Fortin d'avoir accepté de juger ce travail ainsi que de leur patience à lire ce long document.



## RÉSUMÉ

La neige joue un rôle primordial dans le bilan hydrique, le climat et l'économie de nombreuses régions géographiques. Le manteau neigeux est l'ensemble des couches de neige qui s'accumulent sur le sol tout au long de l'hiver. Chacune de ces couches a une densité donnée. La quantification de la variabilité de la densité dans le temps et l'espace est essentielle pour l'estimation de l'équivalent en eau de la neige, la production d'énergie hydroélectrique et l'évaluation des risques naturels (avalanches, inondations, etc.). La densité de la neige est mesurée à l'aide de diverses méthodes et technologies. Parmi celles-ci, on trouve des mesures manuelles en prélevant des carottes dans le manteau neigeux, ou l'installation de dispositifs qui reposent à plat sur le sol et pèsent la neige au fur et à mesure qu'elle s'accumule sur le dessus. Il existe également d'autres méthodes pour mesurer la densité de la neige, comme la télédétection proximale, aérienne et spatiale. Cependant, ces méthodes présentent plusieurs inconvénients; par exemple, elles ne mesurent pas la densité de chaque couche de neige qui compose la stratigraphie verticale du manteau neigeux, mais seulement la densité moyenne de ce dernier. Par conséquent, l'objectif de cette étude est de développer une approche de télédétection proximale pour estimer la densité de la neige dans une optique de suivi de la dynamique et l'évolution spatiale de ce paramètre. Pour relever ce défi, nous proposons dans cette thèse de : 1) développer une méthode innovante de classification du manteau neigeux saisonnier à partir des données hyperspectrales proche infrarouge afin de discriminer des classes de neige homogènes présentant différents degrés de métamorphose; 2) développer un modèle hybride d'estimation de la densité de la neige à partir des données proche infrarouge. Le principe de ce modèle est de classer la densité de la neige avant son estimation au moyen d'un estimateur spécifique correspondant à chaque classe prédéterminée d'état métamorphique de la neige; 3) l'utilisation d'un modèle basé sur les méthodes d'ensemble pour améliorer la qualité et la robustesse de l'estimation de la densité, quel que soit l'état d'évolution ou de métamorphose de la neige tout en fournissant un niveau d'incertitude sur l'estimation. La réalisation de ces objectifs a nécessité des campagnes de terrain hebdomadaire dans un site situé à Québec, étalées sur trois hivers, dans le but de collecter des données in situ des propriétés physiques (densité, taille des grains et type des grains) et optiques (réflectance spectrale dans le proche l'infrarouge) du profil vertical du manteau neigeux. Cent quatorze échantillons de neige ont été collectés et ensuite utilisés à des fins de calibration et de validation des modèles développés. Nos travaux ont ainsi démontré dans un premier temps qu'il est

possible de classer la neige en trois classes de neige (faiblement métamorphosée, modérément métamorphosée, et fortement métamorphosée) à l'aide des données hyperspectrales proche infrarouge avec un taux de succès global de 83% et un indice kappa de 0.75. En ce qui concerne la performance globale du modèle d'estimation de la densité de neige en deux étapes (classification suivie d'une régression), il a été démontré que l'utilisation de l'imagerie hyperspectrale proche infrarouge proximale permet d'estimer la densité de la neige avec une bonne exactitude ( $R^2 = 0,88$  et  $RMSE = 46,79 \text{ kg m}^{-3}$ ). De même, le modèle basé sur les méthodes d'ensemble quant à lui, a permis d'obtenir d'aussi bons résultats ( $R^2 = 0,90$  et  $RMSE = 44,45 \text{ kg m}^{-3}$ ), avec plus de robustesse (écart-type<sub>NASH</sub> = 0,18 et écart-type<sub>RQM</sub> = 15,04  $\text{kg m}^{-3}$  versus écart-type<sub>NASH</sub> = 0,02 et écart-type<sub>RQM</sub> = 4,27  $\text{kg m}^{-3}$  pour le modèle hybride et modèle basé sur les méthodes d'ensemble, respectivement) puisque le modèle intègre explicitement les erreurs inévitables de classification de la neige préalable à l'estimation de la densité de la neige. L'automatisation de cette approche à des fins opérationnelles permettra aux intervenants de surveiller la dynamique spatiale des accumulations de neige saisonnières à des coûts abordables et dans un temps plus court.



# TABLE DES MATIERES

<b>PARTIE 1 : SYNTHÈSE</b> .....	<b>1</b>
<b>1 INTRODUCTION GÉNÉRALE</b> .....	<b>1</b>
1.1 MISE EN CONTEXTE .....	1
1.2 PROBLEMATIQUE .....	3
1.3 HYPOTHESES ET OBJECTIFS .....	4
1.4 STRUCTURE DE LA THESE.....	6
<b>2 ÉTAT DE L'ART</b> .....	<b>7</b>
2.1 LE MANTEAU NEIGEUX SAISONNIER .....	7
2.2 LES PROPRIETES PHYSIQUES DE LA NEIGE .....	8
2.2.1 <i>Type des grains</i> .....	8
2.2.2 <i>Taille des grains et surface spécifique</i> .....	10
2.2.3 <i>Densité de la neige</i> .....	14
2.2.4 <i>Teneur en eau liquide</i> .....	17
2.3 PROPRIETES OPTIQUES DE LA NEIGE.....	18
2.3.1 <i>Réflectance spectrale de la neige</i> .....	18
2.3.2 <i>Relations et analyses entre réflectance spectrale et les propriétés physiques de la neige</i> .....	19
<b>3 MÉTHODOLOGIE GÉNÉRALE</b> .....	<b>27</b>
3.1 ZONE D'ETUDE.....	27
3.2 DISPOSITIFS EXPERIMENTAUX .....	28
3.3 ANALYSE DESCRIPTIVE DES DONNEES IN SITU.....	29
3.4 INDICES D'EVALUATION STATISTIQUES.....	32
<b>4 SYNTHÈSE DES TRAVAUX DE RECHERCHE</b> .....	<b>35</b>
4.1 OBJECTIF 1 : CLASSIFICATION DU MANTEAU NEIGEUX SAISONNIER BASEE SUR LES PROPRIETES PHYSIQUES A L'AIDE DE DONNEES HYPERSPECTRALES PROXIMALES DANS LE PROCHE INFRAROUGE .....	35
4.1.1 <i>Introduction</i> .....	35
4.1.2 <i>Approche méthodologique</i> .....	36
4.1.3 <i>Résultats et discussion</i> .....	38
4.1.4 <i>Conclusions</i> .....	41
4.2 OBJECTIF 2 : MODELE HYBRIDE D'ESTIMATION DE LA DENSITE DU MANTEAU NEIGEUX A PARTIR DE LA REFLECTANCE SPECTRALE PROCHE INFRAROUGE.....	42
4.2.1 <i>Introduction</i> .....	42
4.2.2 <i>Approche méthodologique</i> .....	43
4.2.3 <i>Résultats et discussion</i> .....	45
4.2.4 <i>Conclusions</i> .....	48
4.3 OBJECTIF 3 : SYSTEMES BASES SUR LES METHODES D'ENSEMBLES POUR ESTIMATION DE LA DENSITE DU MANTEAU NEIGEUX A PARTIR DE LA REFLECTANCE SPECTRALE PROCHE INFRAROUGE .....	49
4.3.1 <i>Introduction</i> .....	49
4.3.2 <i>Approche méthodologique</i> .....	50
4.3.3 <i>Résultats et discussion</i> .....	52
4.3.4 <i>Conclusions</i> .....	56
<b>5 CONCLUSION GÉNÉRALE</b> .....	<b>59</b>
5.1 ÉVALUATION DES HYPOTHESES. ....	59
5.2 LIMITES.....	61
5.3 ASPECTS INNOVATEURS, CONTRIBUTIONS ET RETOMBEES .....	62
5.4 PERSPECTIVES.....	63
<b>6 RÉFÉRENCES</b> .....	<b>65</b>
<b>PARTIE 2 : LES ARTICLES</b> .....	<b>73</b>

<b>1 PREMIER ARTICLE: SEASONAL SNOWPACK CLASSIFICATION BASED ON PHYSICAL PROPERTIES USING NEAR-INFRARED PROXIMAL HYPERSPECTRAL DATA.....</b>	<b>79</b>
<b>1. INTRODUCTION.....</b>	<b>80</b>
<b>2. MATERIALS AND METHODS.....</b>	<b>82</b>
2.1 IN SITU MEASUREMENTS.....	82
2.1.1 <i>Physical properties of snow</i> .....	83
2.1.2 <i>Optical properties of snow</i> .....	85
2.2 STATISTICAL ANALYSIS OF DATA .....	86
2.2.1 <i>Principal component analysis (PCA) of NIR spectra</i> .....	86
2.2.2 <i>Hierarchical ascending classification of near infrared spectra</i> .....	87
2.3 ACCURACY ASSESSMENT .....	87
<b>3. RESULTS AND DISCUSSION.....</b>	<b>88</b>
3.1 DESCRIPTIVE ANALYSIS.....	88
3.2 VISUALIZATION AND REDUCTION OF SPECTRAL DIMENSIONALITY BY PRINCIPAL COMPONENTS ANALYSIS .....	92
3.3 UNSUPERVISED SPECTRAL REFLECTANCE CLASSIFICATION.....	94
3.4 METHOD ASSESSEMENT USING A CONFUSION MATRIX.....	97
<b>4. CONCLUSIONS.....</b>	<b>98</b>
<b>5. REFERENCES.....</b>	<b>100</b>
<b>2 DEUXIÈME ARTICLE: ESTIMATING SNOWPACK DENSITY FROM NEAR-INFRARED SPECTRAL REFLECTANCE USING A HYBRID MODEL .....</b>	<b>109</b>
<b>1. INTRODUCTION.....</b>	<b>111</b>
<b>2. MATERIALS AND METHODS.....</b>	<b>113</b>
2.1 STUDY AREA.....	113
2.2 IN SITU DATA COLLECTION .....	114
2.3 METHODOLOGICAL APPROACH.....	116
<b>3. RESULTS AND DISCUSSION.....</b>	<b>119</b>
3.1 DESCRIPTIVE ANALYSIS OF DATA .....	119
3.2 STATISTICAL DEPENDENCE BETWEEN DENSITY AND SPECTRAL REFLECTANCE .....	120
3.3 CALIBRATION OF THE HYBRID MODEL .....	122
3.3.1 <i>HM classifier calibration</i> .....	122
3.3.2 <i>Calibration of the specific models</i> .....	123
3.4 EVALUATION AND VALIDATION OF THE HYBRID MODEL .....	126
3.4.1 <i>Evaluation of the specific estimators using the LOOCV algorithm</i> .....	126
3.4.2 <i>Evaluation of the hybrid model using SSV</i> .....	127
<b>4. CONCLUSION .....</b>	<b>129</b>
<b>5. REFERENCES.....</b>	<b>131</b>
<b>3 TROISIÈME ARTICLE: USING ENSEMBLE BASED SYSTEMS WITH NEAR INFRARED HYPERSPECTRAL DATA TO ESTIMATE SEASONAL SNOWPACK DENSITY .....</b>	<b>139</b>
<b>1. INTRODUCTION.....</b>	<b>141</b>
<b>2. MATERIALS AND METHODS.....</b>	<b>142</b>
2.1 IN SITU MEASUREMENTS FOR THE CALIBRATION AND VALIDATION DATABASE.....	142
2.2 ALGORITHM DEVELOPMENT .....	145
2.2.1 <i>The hybrid model</i> .....	145
2.2.2 <i>Development of the ensemble-based system</i> .....	146
2.3 ACCURACY ASSESSMENT .....	149

<b>3. RESULTS AND DISCUSSION.....</b>	<b>150</b>
3.1 ANALYSIS OF IN SITU SNOW DATA.....	150
3.2 ESTIMATOR CALIBRATION.....	150
3.3 EVALUATION AND VALIDATION OF THE ENSEMBLE-BASED SYSTEM.....	152
3.4 RELIABILITY TEST.....	154
<b>4. CONCLUSIONS.....</b>	<b>156</b>
<b>5. REFERENCES.....</b>	<b>162</b>



## LISTE DES TABLEAUX

TABLEAU 2-1: PRINCIPALES CLASSES MORPHOLOGIQUES DE TYPE DE GRAIN, THE INTERNATIONAL CLASSIFICATION FOR SEASONAL SNOW ON THE GROUND (FIERZ <i>ET AL.</i> , 2009).....	8
TABLEAU 2-2 : TAILLE DES GRAINS SELON LA CLASSIFICATION INTERNATIONALE DE LA NEIGE SAISONNIERE AU SOL (FIERZ <i>ET AL.</i> , 2009).....	11
TABLEAU 2-3 : REPARTITION DE LA DENSITE DE LA NEIGE PAR TYPE DE GRAINS : + NEIGE FRAICHE, $\Delta$ PARTICULES RECONNAISSABLES, $\bullet$ GRAINS FINS, $\circ$ GRAINS RONDS, $\wedge$ GIVRE DE PROFONDEUR, (PAHAUT, 1975). LES DIFFERENTES NUANCES DE GRIS MONTRENT LES NIVEAUX DE METAMORPHOSE DE CHAQUE ECHANTILLON DE NEIGE. ....	16
TABLEAU 2-4 : VALEURS TYPIQUES DE LA REFLECTANCE SPECTRALE (300 - 2500 NM) DES DIFFERENTS TYPES DE SURFACES A LA SURFACE DE LA TERRE (KUIPERS MUNNEKE, 2009).....	18
TABLEAU 3-1. RAPPORT SUR LES DONNEES DE TEMPERATURE POUR LES HIVERS 2018, 2019 ET 2020.....	28
TABLEAU 3-2. RAPPORT SUR LES DONNEES D'ACCUMULATION DE NEIGE AU SOL POUR LES HIVERS 2018, 2019 ET 2020.....	28
TABLEAU 3-3 : DISTRIBUTION DE LA DENSITE DE LA NEIGE EN FONCTION DU TYPE ET DE LA TAILLE DES GRAINS DE NEIGE (DONNEES DE TERRAIN : 2018, 2019 ET 2020), AVEC LEURS SYMBOLOGIES CORRESPONDANTES. (RG) GRAINS FINS ; (FC) GRAINS A FACE PLANES ; (DH) GIVRE DE PROFONDEUR (GOBELETS) ; (MF) GRAINS RONDS (GRAINS DE FONTE). LES DIFFERENTES NUANCES DE GRIS MONTRENT LES NIVEAUX DE METAMORPHOSE (FAIBLE, MODERE, ELEVE) DE CHAQUE COUCHE DE NEIGE RECUPEREE.....	32
TABLEAU 3-4 : PARAMETRES UTILISES DANS LA MATRICE DE CONFUSION ET POUR CALCULER L'INDICE DE KAPPA : A ET D SONT LE NOMBRE DE VALEURS BIEN CLASSEES, B ET C SONT LE NOMBRE DE VALEURS MAL CLASSEES, N1, N2, N3, ET N4 SONT LES TOTAUX DE A + B, C + D, A + C, ET B + D, RESPECTIVEMENT, N EST LA TAILLE DE L'ECHANTILLON, PO=A + DN, ET PC =N1 $\times$ N3 + N2 $\times$ N4N2. ....	34
TABLEAU 4-1 : EQUATIONS DES TROIS MODELES CALIBRES (ESTIMATEURS SPECIFIQUES) UTILISANT LA REGRESSION MULTIVARIEE PAS A PAS POUR ESTIMER LA DENSITE DE LA NEIGE. ....	47
TABLEAU 4-2 : ABCISSES ET POIDS DE LA DISTRIBUTION NORMAL STANDARD.....	51
TABLE 1-1 : TEMPERATURE DATA REPORT FOR THE WINTERS OF 2018, 2019, AND 2020.....	89
TABLE 1-2 : GROUND SNOW ACCUMULATION DATA REPORT FOR THE WINTERS OF 2018, 2019, AND 2020.....	89
TABLE 1-3 : DISTRIBUTION OF SNOW DENSITY IN TERMS OF TYPE AND SIZE OF SNOW GRAINS (FIELD DATA: 2018, 2019 AND 2020), WITH THEIR CORRESPONDING SYMBOLOGIES. (PP) PRECIPITATION PARTICLES; (DF) DECOMPOSING AND FRAGMENTED PRECIPITATION PARTICLES; (RG) ROUNDED GRAINS; (FC) FACETED CRYSTALS; (DH) DEPTH HOAR (GOBLETS); (MF) MELT FORMS. THE DIFFERENT SHADES OF GRAY SHOW THE LEVELS OF METAMORPHOSIS (LOW, MODERATE, HIGH) OF EACH RECUPERATED SNOW LAYER. ....	90
TABLE 1-4. CONFUSION MATRIX RESULTS; C1—WEAKLY METAMORPHOSED, C2—MODERATELY METAMORPHOSED, C3—STRONGLY METAMORPHOSED.....	98
TABLE 2-1 : DISTRIBUTION OF SNOW DENSITY AS A FUNCTION OF TYPE AND SIZE OF SNOW GRAINS, FOR WMM, MHM, AND HVM, RESPECTIVELY, (FIELD DATA: 2018, 2019 AND 2020). PRECIPITATION PARTICLES (+), DECOMPOSING AND FRAGMENTED PRECIPITATION PARTICLES ( $\Delta$ ), ROUNDED GRAINS ( $\bullet$ ), FACETED CRYSTALS ( $\square$ ), DEPTH HOAR ( $\wedge$ ), MELT FORMS ( $\circ$ ).THE DIFFERENT SHADES OF GRAY SHOW THE	

LEVELS OF METAMORPHOSIS (LOW, MODERATE, HIGH) OF EACH RECUPERATED SNOW LAYER. ....	119
TABLE 2-2 : EQUATIONS OF THE THREE CALIBRATED MODELS (SPECIFIC ESTIMATORS) USING STEPWISE MULTIVARIATE REGRESSION TO ESTIMATE SNOW DENSITY. ....	126
TABLE 3-1: ABSCISSA AND WEIGHT OF THE OPTIMAL THRESHOLDS.....	147
TABLE 3-2: DISTRIBUTION OF SNOW DENSITY IN TERMS OF TYPE AND SIZE OF SNOW GRAINS (FIELD DATA: 2018, 2019 AND 2020) (EL OUFIR ET AL., 2021A). ....	150
TABLE 3-3: CALIBRATION EQUATIONS FOR EACH SPECIFIC ESTIMATOR. R2 IS THE COEFFICIENT OF DETERMINATION OF THE MULTIVARIATE REGRESSIONS; SAMP IS THE SIZE OF THE TRAINING DATASET OF EACH ESTIMATOR; EXPVARIS THE EXPLANATORY VARIABLE; U, N AND L ARE THE UPPER, NOMINAL AND LOWER THRESHOLDS; THE ARROW (↑) INDICATES AN ESTIMATOR TRAINED WITH DATA SUPERIOR TO THE THRESHOLD; AND THE DOWNWARD ARROW (↓) INDICATES AN ESTIMATOR TRAINED WITH DATA INFERIOR THE THRESHOLD; THE COLOURS LIGHT BLUE, MARINE BLUE AND DARK BLUE REFER TO THE ESTIMATORS USED TO CALCULATE THE SNOW DENSITY OF THE WMM, MHM AND HVM CLASSES, RESPECTIVELY. ....	151

## LISTE DES FIGURES

FIGURE 2-1 : PRINCIPALES CLASSES MORPHOLOGIQUES DES FORMES DES GRAINS (FIERZ <i>ET AL.</i> , 2009).....	9
FIGURE 2-2 : CYCLE DE METAMORPHOSE DE LA NEIGE (PAHAUT, 1975); C1 : FAIBLEMENT METAMORPHOSE, C2 : MOYENNEMENT METAMORPHOSE, C3 : FORTEMENT METAMORPHOSE.....	10
FIGURE 2-3 : TAILLE DES GRAINS, MESURES DE TERRAIN ; HIVER 2018. ....	12
FIGURE 2-4 : SCHEMA DE LA REPARTITION DES TROIS PHASES DE L'EAU, (A) DANS LE CAS DES FAIBLES TEL ET (B) DANS LE CAS DES FORTES TEL (MARBOUTY, 1984).....	17
FIGURE 2-5 : LA REFLECTANCE SPECTRALE D'UNE NEIGE PURE DE $SS = 50 \text{ M}^2 \text{ KG}^{-1}$ ET REPRESENTATION DES BANDES DU VIS, DU PIR ET MIR (GALLET, 2010).....	19
FIGURE 2-6 : REFLECTANCE SPECTRALE DES CRISTAUX DE NEIGE FRAICHE (CNF), DES PARTICULES RECONNAISSABLES (PR), DES GRAINS FINS (GFS), GRAINS A FACES PLANES (GFP), GIVRE DE PROFONDEUR (DES GOBELETS) (GP), DU GIVRE DE SURFACE (GS), DES GRAINS DE FONTE (GFE), ET DES RONDS (GR). LA REFLECTANCE MEDIANE A CHAQUE LONGUEUR D'ONDE EST MONTREE AVEC DES LIGNES COLOREES ET LA GAMME INTERQUARTILE EST MONTREE AVEC L'OMBRAGE GRIS. LA LIGNE POINTILLEE MONTRE LA BANDE DE LONGUEUR D'ONDE A 1310 NM (HORTON & JAMIESON, 2017).....	20
FIGURE 2-7 : LA REFLECTANCE SPECTRALE MEDIANE DE CHAQUE TYPE DE NEIGE (HORTON & JAMIESON, 2017).....	21
FIGURE 2-8 : COEFFICIENTS DE DETERMINATIONS LINEAIRES ENTRE REFLECTANCE ET $SS$ , EN FONCTION DES LONGUEURS D'ONDES (DOMINE <i>ET AL.</i> , 2006).....	22
FIGURE 2-9 : SENSIBILITE DE LA $SS$ A UNE ERREUR EXPERIMENTALE SUR LA MESURE DE REFLECTANCE POUR 4 LONGUEURS D'ONDES (900, 1030, 1310 ET 1550 NM) (GALLET, 2010).....	23
FIGURE 2-10 : MESURE DE LA $SS$ EN UTILISANT UNE SPHERE D'INTEGRATION (MONTPETIT <i>ET AL.</i> , 2011).....	23
FIGURE 2-11 : CORRELATION ENTRE LA REFLECTANCE SPECTRALE ET LA DENSITE DE LA NEIGE DANS LE PIR (LI <i>ET AL.</i> , 2016).....	24
FIGURE 2-12 : REFLECTANCE SPECTRALE EN FONCTION DE LA LONGUEUR D'ONDE POUR DIFFERENTS TAUX D'HUMIDITE (NEGI <i>ET AL.</i> , 2010A).....	25
FIGURE 3-1 : CARTE DE LOCALISATION DU SECTEUR D'ETUDE ET DE LA ZONE D'ECHANTILLONNAGE SERVI A LA CALIBRATION ET LA VALIDATION DES APPROCHES DEVELOPPEES. ....	27
FIGURE 3-2 : LA CAROTTEUSE D'ECHANTILLONNAGE DE NEIGE. ....	29
FIGURE 3-3 : DISPOSITIF D'ACQUISITION D'IMAGES HYPERSPECTRALES PROXIMALES. ....	29
FIGURE 3-4 : LA STRATIGRAPHIE VERTICALE A L'INTERIEUR DE LA CAROTTEUSE, HIVER 2018. ....	30
FIGURE 3-5 : ACQUISITION HYPERSPECTRALE DE LA STRATIGRAPHIE VERTICALE DU MANTEAU NEIGEUX. ....	31
FIGURE 4-1 : GRAPHIQUE DE SCORE POUR LA CP1 ET LA CP2 DES VALEURS DE REFLECTANCE SPECTRALE. LES LIGNES DE SEPARATION EN GRAS PERMETTENT DE DISTINGUER VISUELLEMENT LES CLASSES DE NEIGE EN TERMES DE DEGRE DE METAMORPHOSE (NEIGE FAIBLEMENT, MODEREMENT ET FORTEMENT METAMORPHOSEE).....	40
FIGURE 4-2 : LES VALEURS DE REFLECTANCE SPECTRALE DANS LE PIR DES TROIS CLASSES DE NEIGE.....	40
FIGURE 4-3 : LES REFLECTANCES SPECTRALES PIR DES TROIS CLASSES DE NEIGE.....	44

FIGURE 4-4 : SEUILS UTILISES POUR DISTINGUER LES TROIS CLASSES DE NEIGE A L'AIDE DE LA METHODE CART.....	44
FIGURE 4-5 : RESULTATS DE LA SUBDIVISION DE LA BASE DE CALIBRATION EN TROIS SOUS-GROUPES SPECIFIQUES. 1) LE SOUS-GROUPE DE DONNEES QUI A ETE UTILISE POUR CALIBRER L'ESTIMATEUR SPECIFIQUE DE LA CLASSE DE NEIGE FMM, 2) LE SOUS-GROUPE DE DONNEES QUI A ETE UTILISE POUR CALIBRER L'ESTIMATEUR SPECIFIQUE DE LA CLASSE DE NEIGE MFM, 3) LE SOUS-GROUPE DE DONNEES QUI A ETE UTILISE POUR CALIBRER L'ESTIMATEUR SPECIFIQUE DE LA CLASSE DE NEIGE FFM.....	45
FIGURE 4-6 : (A) RESULTAT DE CALIBRATION EN UTILISANT DES DIFFERENCES DE BANDE NORMALISEES (75% DE LA BASE DE DONNEES); (B) RESULTATS DE LA VALIDATION PAR DONNEES INDEPENDANTES (25% DE LA BASE DE DONNEES). .....	46
FIGURE 4-7 : ÉVALUATION DU MH A L'AIDE DES DONNEES INDEPENDANTES.....	47
FIGURE 4-8 : LE SCHEMA DU FQG EN DEUX DIMENSIONS UTILISANT DEUX VARIABLES (V1 ET V2), ET SON APPLICATION POUR CALIBRER LE MBME. ....	52
FIGURE 4-9 : LA DENSITE DE LA NEIGE ESTIMEE PAR LES DEUX MODELES A) MBME, ET B) MH PAR RAPPORT AUX MESURES IN SITU POUR LA BASE DE DONNEES INDEPENDANTE. ....	54
FIGURE 4-10 : HISTOGRAMMES DU TEST DE ROBUSTESSE DU MBME ET DU MH : A) ECART-TYPE ( $NASH_{MBME}$ ) = 0.02, B) ECART-TYPE ( $NASH_{MH}$ ) = 0.18, C) ECART-TYPE ( $EQM_{MBME}$ ) = 4.27 KG M <sup>-3</sup> , D) ECART-TYPE ( $EQM_{MH}$ ) = 16.04 KG M <sup>-3</sup> . ....	55
FIGURE 4-11 : LES BOITES A MOUSTACHES REPRESENTANT LA DISTRIBUTION DES VALEURS DE DENSITE DE NEIGE ESTIMEES EXPRIMEES EN A) NASH ET B) EQM, SELON LES DEUX MODELES MBME ET MH. ....	56
FIGURE 1-1 : GEOGRAPHICAL LOCATION OF THE SAMPLING SITE. ....	82
FIGURE 1-2 : SNOW CORE SAMPLER. ....	83
FIGURE 1-3 : (A) SNOW PIT, HP: HEIGHT OF THE PIT; (B) SNOW PIT AFTER PROFILE EXTRACTION, WINTER 2018. ....	84
FIGURE 1-4 : THE VERTICAL PROFILE WITHIN THE SNOW CORER, WINTER 2018. ....	84
FIGURE 1-5 : PROXIMAL HYPERSPECTRAL IMAGE ACQUISITION DEVICE.....	85
FIGURE 1-6 : HYPERSPECTRAL ACQUISITION OF THE SNOW SAMPLES VERTICAL PROFILE. ....	86
FIGURE 1-7 : FLOWCHART OF THE METHODOLOGICAL APPROACH. WM: WEAKLY METAMORPHOSED; MM: MODERATELY METAMORPHOSED; SM: STRONGLY METAMORPHOSED.; GS: GLOBAL SUCCES; Kp KAPPA INDEX; ICSSG: INTERNATIONAL CLASSIFICATION FOR SEASONAL SNOW ON THE GROUND. ....	88
FIGURE 1-8 : (A) SNOW GRAINS OF EACH LAYER OF THE VERTICAL STRATIGRAPHY; (B) FALSE-COLOR RGB IMAGE; (C) NIR SPECTRAL REFLECTANCE OF EACH LAYER OF THE VERTICAL STRATIGRAPHY (THE RED, GREEN, AND BLUE VERTICAL LINES IN THE SPECTRAL PLOT SHOW THE LOCATION OF THE BANDS USED TO GENERATE THE FALSE-COLOR RGB IMAGE).....	91
FIGURE 1-9 : SNOW LAYER RETAINED (HOMOGENEOUS), SNOW LAYER REJECTED (HETEROGENEOUS). ....	91
FIGURE 1-10 : NIR SPECTRAL REFLECTANCE VALUES OF DIFFERENT HOMOGENEOUS SNOW LAYERS. ....	92
FIGURE 1-11 : SCORE PLOT FOR PC1 AND PC2 OF SPECTRAL REFLECTANCE VALUES. THE CUT-OFF BOLD LINES HELP TO VISUALLY DISTINGUISH AMONG THE SNOW CLASSES IN TERMS OF METAMORPHOSIS DEGREE (WEAKLY, MODERATELY, STRONGLY METAMORPHOSED SNOW).....	92
FIGURE 1-12. THE COEFFICIENTS OF PC1 AS A FUNCTION OF WAVELENGTHS.....	93
FIGURE 1-13 DENDROGRAM OBTAINED USING A HIERARCHICAL ASCENDING CLASSIFICATION; CH— CUT-OFF HEIGHT; C1—WEAKLY METAMORPHOSED, C2—MODERATELY METAMORPHOSED, AND C3—STRONGLY METAMORPHOSED. ....	94



FIGURE 1-14 : THE NEAR-INFRARED SPECTRAL REFLECTANCE VALUES OF THE THREE SNOW CLASSES. ....	95
FIGURE 1-15 : SNOW GRAINS FROM THE WEAKLY METAMORPHOSED CLASS. ....	96
FIGURE 1-16 : SNOW GRAINS FROM THE MODERATELY METAMORPHOSED CLASS. ....	96
FIGURE 1-17 : SNOW GRAINS FROM THE STRONGLY METAMORPHOSED CLASS.....	97
FIGURE 2-1 : GEOGRAPHIC LOCATION OF THE SAMPLING AREA IN THE TECHNOLOGY PARK IN QUEBEC CITY, CANADA. ....	113
FIGURE 2-2. SNOW CORE SAMPLER. ....	114
FIGURE 2-3 : PROXIMAL ACQUISITION STATION FROM THE COMPANY RESONON (RESONON INC., BOZEMAN, MT, USA). ....	114
FIGURE 2-4 : (A) SNOW PIT AFTER PROFILE EXTRACTION; (B) THE VERTICAL PROFILE SAMPLED BY THE SNOW CORER, WINTER 2018 (EL OUFIR <i>ET AL.</i> , 2021). ....	115
FIGURE 2-5 : (A) HYPERSPECTRAL ACQUISITION OF A SNOW SAMPLE'S VERTICAL PROFILE; (B) FALSE-COLOR RGB IMAGE OF THE SPATIAL TRANSITIONS OF THE VERTICAL STRATIGRAPHY OF THE SNOWPACK (EL OUFIR <i>ET AL.</i> , 2021). ....	116
FIGURE 2-6 : FLOWCHART OF THE METHODOLOGICAL APPROACH. HM REFERS TO HYBRID MODEL, S.E REFERS TO SPECIFIC ESTIMATOR, AND LOOCV REFERS TO LEAVE-ONE-OUT CROSS-VALIDATION. ....	118
FIGURE 2-7 : THE NIR SPECTRAL REFLECTANCE OF THE THREE SNOW CLASSES. ....	120
FIGURE 2-8 : CORRELOGRAM AND CORRELATION MATRIX OF THE SPECTRAL REFLECTANCE AND DENSITY FOR ALL MEASUREMENTS: (A) SINGLE BANDS; (B) NORMALIZED BAND DIFFERENCES; (C) BAND RATIOS; AND (D) BAND DIFFERENCES. ....	121
FIGURE 2-9 : RESULTS OF (A) CALIBRATION USING NORMALIZED BAND DIFFERENCES (75% OF THE DATABASE); AND (B) VALIDATION (25% OF THE DATABASE). ....	122
FIGURE 2-10 : THRESHOLDS USED TO DISTINGUISH BETWEEN THE THREE CLASSES OF SNOW USING THE CART METHOD. THRESHOLD1 = 0.475 AND THRESHOLD2 = 0.634.....	123
FIGURE 2-11 : RESULTS OF CORRELATION MATRICES WITH THE DIFFERENT SPECTRAL INDICES STUDIED. (A) BAND DIFFERENCE (WMM); (B) NORMALIZED RATIO (MHM); AND (C) BAND DIFFERENCE (HVM). ....	124
FIGURE 2-12 : RESULTS OF THE HYBRID MODEL TO ESTIMATE SPECIFIC ESTIMATORS. (A) CLASS WMM; (B) CLASS MHM; AND (C) CLASS HVM. ....	125
FIGURE 2-13 : RESULTS OF THE LOOCV OF THE HYBRID MODEL SPECIFIC ESTIMATORS. (A) CLASS WMM; (B) CLASS MHM; AND (C) CLASS HVM. ....	127
FIGURE 2-14 : EVALUATION OF THE REGIONAL HYBRID MODEL USING THE SSV DATA.....	128
FIGURE 3-1: GEOGRAPHICAL LOCATION OF THE SAMPLING AREA (EL OUFIR <i>ET AL.</i> , 2021B). ....	143
FIGURE 3-2: SNOW CORE SAMPLER (EL OUFIR <i>ET AL.</i> , 2021A). ....	144
FIGURE 3-3: NIR SPECTRAL REFLECTANCE ACQUISITION DEVICE FOR THE VERTICAL PROFILE OF SNOW SAMPLES FROM THE COMPANY RESONON (RESONON INC., BOZEMAN, MT, USA) (EL OUFIR <i>ET AL.</i> , 2021A). ....	144
FIGURE 3-4: DENSITY CLASS DETERMINATION USING THE HYBRID MODEL. THE LIGHT BLUE, THE MARINE BLUE AND THE DARK BLUE DOTS INDICATE THE WMM, MHM AND HVM CLASSES RESPECTIVELY, AND REPRESENT THE CALIBRATION DATABASE USED TO CALIBRATE THE CORRESPONDING ESTIMATORS. THE GREY LINES ARE THE TWO DISCRIMINATION THRESHOLDS USED BASED ON WAVELENGTHS V1 (1161 NM) AND V2 (1024 NM).....	145
FIGURE 3-5: THE TWO-DIMENSIONAL GQF SCHEME USING VARIABLES V1 AND V2 AND ITS APPLICATION TO CALIBRATE THE EBS. THE BLACK, RED AND BLUE LINES REPRESENT THE OPTIMAL THRESHOLDS (LOWER, NOMINAL AND UPPER RESPECTIVELY) FOR V1 (OTV1L = 0.632, OT1N = 0.648 AND OTV1U = 0.664)	

AND V2 (OTV2L = 0.468, OTV2N = 0.480, AND OTV2U = 0.492). K(1–3) AND P(1–3) ARE THE INDICES OF THE OPTIMAL THRESHOLDS ASSOCIATED WITH V1 AND V2. THE LIGHT BLUE, MARINE BLUE AND DARK BLUE POINTS REPRESENT THE DATA USED FOR TRAINING (WMM, MHM, AND HVM, RESPECTIVELY) TO CALIBRATE THE SPECIFIC ESTIMATORS. AT THE TOP RIGHT IS THE FLOW CHART OF THE SIMPLIFIED EBS OPERATIONAL MODE. THE LIGHT BLUE, MARINE BLUE AND DARK BLUE BOXES DESIGNATE THE AREAS WITH WMM, MHM AND HVM CLASSES RESPECTIVELY. THE OVERLAPPING AREAS IN LIGHT AND DARK GREY INDICATE THE TRANSITIONS BETWEEN LOW-MODERATE AND MODERATE-HIGH DENSITIES, RESPECTIVELY. THE TERMS OF THE EQUATIONS ARE DETAILED IN EQUATION 6. A DETAILED FLOW CHART IS PRESENTED IN APPENDIX B (FIGURE 3-11). ..... 148

FIGURE 3-6 : STABILITY TEST (K-FOLD CROSS-VALIDATION) FLOW CHART..... 149

FIGURE 3-7: SNOW DENSITY ESTIMATED BY THE TWO MODELS (A) EBS AND B) HM COMPARED TO THE IN SITU MEASUREMENTS FOR THE INDEPENDENT DATABASE. .... 154

FIGURE 3-8 : HISTOGRAMS SHOWING THE ROBUSTNESS TEST BETWEEN EBS AND HM: A) STANDARD DEVIATION (NASHEBS) = 0.02, B) STANDARD DEVIATION (NASHHM) = 0.18, C) STANDARD DEVIATION (RMSEEBS) = 4.27 KG M-3, D) STANDARD DEVIATION (RMSEHM) = 16.04 KG M-3. .... 155

FIGURE 3-9 : BOXPLOTS REPRESENTING THE DISTRIBUTION OF ESTIMATED SNOW DENSITY VALUES EXPRESSED IN A) NASH AND B) RMSE, ACCORDING TO THE TWO MODELS EBS AND HM. .... 155

FIGURE 3-10: SCHEME OF TRAINING SUBGROUP SELECTION IN ONE OF THE MODERATE SNOW CLASS CASES (BROWN POINT). .... 160

FIGURE 3-11: FLOW CHART OF THE DEVELOPED ALGORITHM FOR DENSITY ESTIMATION (SAMP IS THE NUMBER OF SAMPLES; OTV1 AND OTV2 REFER TO THE OPTIMAL THRESHOLDS OF V1 AND V2; AND EST IS THE SPECIFIC ESTIMATORS AS DESCRIBED IN TABLE 3-3). ..... 161

## LISTE DES ABRÉVIATIONS

<b>Abréviations</b>	<b>Définition du terme</b>
PIR	Proche infrarouge
VIS	Visible
MIR	Moyen infrarouge
MH	Modèle hybride
ES	Estimateurs spécifiques
MBME	Modèle basé sur les méthodes de l'ensemble
CNF	Cristaux de neige fraîche
PR	Particules reconnaissables
GFS	Grains fins
GFP	Grains à face planes
GP	Givre de profondeur
GS	Givre de surface
GR	Grains ronds
GFE	Grains de fonte
FG	Formations de glace
SS	Surface spécifique
$\rho_{glace}$	Densité de la glace
BET	Brunauer-Emmett-Teller
$r_{eff}$	Rayon effectif
d	Profondeur de la neige
$\rho$	Densité de la neige
EEN	Équivalent en eau de la neige
IR	Infrarouge
R <sup>2</sup>	Coefficient de détermination
NASH	Critère de Nash
EQM	L'erreur quadratique moyenne
ACP	Analyse en composantes principales
CAH	Classification ascendante hiérarchique
CP	Composantes principales
Coeff	Coefficients
FMM	Faiblement à modérément métamorphosée
MFM	Modérément à fortement métamorphosée
FFM	Fortement à très fortement métamorphosée

# **PARTIE 1 : SYNTHÈSE**

---

# 1 INTRODUCTION GÉNÉRALE

---

## 1.1 Mise en contexte

Il existe deux types de manteaux neigeux : un manteau permanent et un manteau saisonnier. Les manteaux neigeux permanents persistent plusieurs années et se trouvent principalement dans les régions Antarctiques et Groenland. Tandis que, les manteaux neigeux saisonniers ne durent pas longtemps et commencent à fondre durant la saison de fonte printanière. La fonte des manteaux neigeux saisonniers a une grande importance hydrologique et économique (Fayad *et al.*, 2017; Viviroli *et al.*, 2007). On estime qu'un sixième de la population mondiale dépend de la fonte de la neige pour l'approvisionnement en eau douce (Armstrong & Brun, 2008). Son importance est également évidente dans la prévision des inondations et à l'optimisation de la gestion des ressources en eau pour des applications telles que la production d'hydroélectricité et l'irrigation. Pour toutes ces raisons, la pression sur le suivi et la mesure de cette ressource en eau est en demande croissante où le développement socio-économique cause une demande drastique en eau (Environnement et ressources naturelles Canada, 2010).

Les mesures in situ des propriétés physiques de la neige fournissent des données pour étudier, comprendre et prévoir les processus d'évolutions des manteaux neigeux saisonniers. Ces mesures peuvent fournir des intrants aux modèles mathématiques du climat, à l'hydrologie, et à la prévision des avalanches (Kinar & Pomeroy, 2015). Depuis la déposition jusqu'à la fonte, la neige au sol est un matériau hautement poreux constitué d'une structure de glace continue et d'un espace poreux, formant ensemble la microstructure de la neige (Fierz *et al.*, 2009). La neige au sol est dans un état de transformation continu, suite aux variations de la température de l'air et de l'épaisseur du couvert. Cette transformation de la taille et de la forme des grains ainsi que de la densité du couvert est connue sous le nom de métamorphisme.

En raison de la nature intermittente des précipitations, de l'action du vent et du métamorphisme de la neige, des couches distinctes de neige s'accumulent pour former le manteau neigeux (Fierz *et al.*, 2009). Chaque couche de neige a une histoire propre qui peut être très différente de celle des autres couches supérieures ou inférieures et aboutir à une évolution très différente. C'est pourquoi, tous les différents types de neige peuvent coexister simultanément sur une même verticale du manteau neigeux. Chaque couche du profil vertical du manteau neigeux diffère des couches adjacentes par au moins une des caractéristiques suivantes : la taille des grains et la densité, qui définissent ensemble le type des grains, la teneur en eau liquide et la température de la neige. Il sera donc nécessaire de disposer d'une mesure de cette stratification (Marbouty, 1983).

La neige au sol se distingue de la plupart des surfaces terrestres par sa forte réflectance spectrale dans les longueurs d'onde visible (VIS) et proche-infrarouge (PIR) (350 - 1700 nm). Dans le VIS (350 - 900 nm) la neige possède une réflectance spectrale proche de 1, c'est-à-dire qu'il renvoie la quasi-totalité du rayonnement incident. En outre, la réflectance de la neige est sensible à la présence d'impuretés du fait de la grande transparence de la glace. Plus la quantité d'impuretés est importante, plus la réflectance est basse (Doherty *et al.*, 2013; Negi *et al.*, 2010a).

Dans le PIR (900 - 1700 nm), la réflectance de la neige diminue, et la majeure partie du rayonnement incident dans ces longueurs d'onde est absorbée par le manteau neigeux (Warren, 1982). Dans cette partie du spectre optique, la réflectance de la neige varie principalement en fonction des propriétés physiques de la neige et son âge de dépôt (Negi *et al.*, 2010a). Plus les grains de neige sont petits, plus la réflectance de la neige est grande. Plus ils sont gros, plus la réflectance est basse, et donc plus la quantité d'énergie absorbée par le manteau neigeux est importante. Cette dernière propriété a pour effet d'accélérer le métamorphisme de la neige, c'est-à-dire d'augmenter la vitesse de grossissement des cristaux de glace (Flanner *et al.*, 2011).

D'après des expériences sur la réflectance spectrale du PIR, O'Brien and Munis (1975) ont conclu que la densification de la neige s'accompagne d'une réduction de la réflectance de la neige. Liljequist (1956) a conclu qu'immédiatement après une chute de neige, la réflectance spectrale est généralement élevée, mais avec le temps, la réflectance diminuera en partie du fait que la neige devient plus dense et en partie due à l'augmentation de la taille des grains. D'autre part, l'indice de réfraction de l'eau liquide diffère peu de l'indice de réfraction de la glace. Cependant, il existe un léger décalage spectral entre les indices des deux phases de l'eau. La réflectance de la neige sèche est donc peu différente de celle d'une neige humide, généralement plus faible, particulièrement dans le moyen infrarouge (MIR) (Epanapelli *et al.*, 2018b; Negi *et al.*, 2010a). L'utilisation de données hyperspectrales pourrait permet d'identifier la présence d'eau sous forme liquide dans la neige en tirant parti de ce léger décalage spectral entre les deux indices (Green *et al.*, 2006). La réflectance de la neige est également sensible aux caractéristiques angulaires du rayonnement incident. Plus le rayonnement incident est proche de la verticale, plus la réflectance est faible. Ceci peut-être expliqué d'une manière simple : un photon qui arrive perpendiculaire au manteau neigeux aura plus de mal à faire demi-tour qu'un photon qui arrive avec une incidence rasante (Warren, 1982). **Ainsi, la neige est un matériau dont les propriétés optiques varient fortement en fonction des caractéristiques du rayonnement incident, de la quantité d'impuretés absorbantes qu'il contient et de ses propriétés physiques.**

## 1.2 Problématique

Habituellement, le moyen le plus utilisé pour surveiller les manteaux neigeux est l'échantillonnage in situ via des fosses à neige et/ou tube d'échantillonnage de neige. Toutefois, ce processus de surveillance est laborieux et pour des impératifs budgétaires évidents il demeure trop limité dans le temps et dans l'espace, vis-à-vis de la forte variabilité spatio-temporelle du manteau neigeux (Baba *et al.*, 2018). En effet, la fréquence spatio-temporelle de ces méthodes standards est insuffisante pour mesurer et détecter les variations des propriétés physiques des manteaux neigeux saisonniers (Kinar & Pomeroy, 2015) et les coûts alloués aux analyses en laboratoire sont souvent élevés, particulièrement dans un territoire aussi large que celui de la province du Québec. En outre, ce type de mesures invasives perturbe et modifie irrévocablement le manteau neigeux (Vander Jagt *et al.*, 2015). Il est alors temps de développer des techniques permettant une gestion optimale des méthodes de suivi et de surveillance des propriétés physiques des manteaux neigeux saisonniers dans le temps et dans l'espace en exploitant l'information produite par ces programmes d'échantillonnage in situ.

La télédétection s'avère un outil prometteur, capable à la fois de fournir la couverture spatiale et la fréquence temporelle essentielle à la détection des propriétés physiques des manteaux neigeux saisonniers. Grâce à sa répétitivité et sa capacité à opérer sur une large gamme du spectre électromagnétique, la télédétection optique répond parfaitement aux critères nécessaires pour suivre l'évolution et la métamorphose de la couverture neigeuse saisonnière. Un moyen de caractérisation des propriétés physiques de la neige est la mesure de sa réflectance spectrale (Warren, 1982). En effet, la neige est parmi les matériaux les plus réfléchissants sur la terre et sa réflectance spectrale présente de grandes variations le long du spectre optique.

Les variations des propriétés physiques de la neige sont détectables en se basant sur l'information enregistrée par imagerie, particulièrement les caméras hyperspectrales. Negi *et al.* (2010a) ont montré qu'en raison de l'augmentation et du vieillissement des propriétés physiques du manteau neigeux, une tendance à la diminution de la réflectance a été observée dans la région du PIR et à des longueurs d'onde plus élevées. Cependant, dans la région VIS, aucune tendance définie n'a été observée. De ces faits, la décision d'utiliser une caméra hyperspectrale PIR dans ce travail. La combinaison de l'imagerie hyperspectrale aux mesures in situ serait souhaitable dans un contexte de préservation des manteaux neigeux et de gain en temps et en coût. L'adjonction de ces techniques permettra également d'améliorer les processus d'automatisation de l'instrumentation des mesures du manteau neigeux en mettant l'accent sur le développement d'outils de surveillance complémentaires et relativement peu coûteux au lieu du post-traitement des échantillons dans un laboratoire ou des données dans un bureau.

Si toutefois la détection optique de certaines propriétés physiques de la neige (taille des grains, teneur en eau liquide) est une tâche relativement simple (Domine *et al.*, 2006; Eppanapelli *et al.*, 2018a), puisque leurs propriétés sont corrélées parfaitement avec certaines longueurs d'onde du spectre PIR de la neige, cette opération est beaucoup plus complexe pour la densité de la neige. Une des difficultés majeures est que la relation entre la densité de la neige et la réflectivité spectrale en PIR est non bijective (surjective<sup>1</sup>). En effet, plusieurs amplitudes de réflectivité peuvent être associées à une même densité et vice versa, cela influence les corrélations entre la densité et la réflectance spectrale. En outre, la résolution spectrale de l'ancienne génération des capteurs multi spectraux destinés à l'étude des propriétés physiques de la neige fait généralement référence à des groupes de seulement trois à dix bandes discrètes du spectre et, ne permettait pas la bonne exploitation des données spectrales surtout pour le suivi de ce phénomène très dynamique dans le temps et l'espace. Or, depuis le nouveau millénaire, des données hyperspectrales font l'acquisition de bandes spectrales étroites de moins de 5 nm se qualifiant pour de telles applications.

Cette étude doctorale porte ainsi sur l'estimation de la densité des manteaux neigeux saisonniers en utilisant l'imagerie hyperspectrale proximale PIR (900 – 1700 nm). L'objectif est d'étudier et de modéliser cette propriété afin de pouvoir développer un système de mesure de la densité de la neige sous des conditions contrôlées. Dans cette perspective, nous utiliserons des méthodes d'analyse de données afin d'établir des relations empiriques entre les caractéristiques physiques de la neige et la réflectance spectrale correspondante.

### 1.3 Hypothèses et objectifs

La présente thèse propose une méthodologie basée sur des connaissances scientifiques multidisciplinaires combinant la télédétection proximale optique, les mesures physiques de terrain de la neige et les outils statistiques pour le suivi de la dynamique spatio-temporelle de la densité des manteaux neigeux saisonniers du Québec. Ainsi, l'objectif principal de cette thèse est de **développer une approche d'estimation de la densité de neige pour le suivi des manteaux neigeux saisonniers en exploitant les méthodes d'ensemble et des données hyperspectrales PIR**. Pour aboutir aux fins de cet objectif, il a été scindé en trois objectifs spécifiques décrits dans les paragraphes suivants.

Le premier objectif spécifique de cette thèse est basé sur les deux hypothèses suivantes :

*1. Étant donné que la microstructure de la neige influence ses propriétés optiques, plus précisément dans le spectre PIR (900-1700 nm), il serait possible de classer la neige associée au manteau neigeux saisonnier en utilisant la réflectance spectrale et 2. L'évolution des processus*

---

<sup>1</sup> C'est une application pour laquelle tout élément de l'ensemble d'arrivée a au moins un antécédent, c'est-à-dire est image d'au moins un élément de l'ensemble de départ. Il est équivalent de dire que l'ensemble image est égal à l'ensemble d'arrivée.



*métamorphiques des différentes propriétés physiques de la neige est similaire au sein d'une même classe optique et présente des différences significatives d'une classe optique à l'autre.* En effet, la réflectance spectrale de la neige est en partie contrôlée par des changements dans ses propriétés physiques, en particulier dans la partie PIR du spectre. La similarité spectrale de deux échantillons indique la similitude de leur composition chimique et de leurs caractéristiques physiques. Cette information peut être utilisée pour distinguer, sans reconnaissance a priori, entre différentes classes de neige en se basant seulement sur l'information spectrale.

Afin de vérifier la validité de ces hypothèses, l'objectif spécifique été de développer ***une méthode de classification des propriétés physiques (densité, taille des grains et type des grains) du manteau neigeux saisonnier en utilisant l'imagerie hyperspectrale dans le PIR afin de discriminer les classes optiques de la neige à différents degrés de métamorphose, basée uniquement sur sa réflectance spectrale.***

Plusieurs modèles ont été conçus pour estimer la densité de la neige à partir d'informations spectrales. Cependant, aucun n'a encore atteint une performance significative. L'une des principales difficultés est que la relation entre la densité de la neige et la réflectance spectrale est non bijective (surjective). En effet, plusieurs amplitudes de réflectance peuvent être associées à la même densité et vice versa, de sorte que la corrélation entre la densité et la réflectance spectrale peut être très faible. Pour résoudre ce problème, l'hypothèse sur laquelle reposent les travaux du deuxième objectif spécifiques est la suivante : 3. *Le développement d'un modèle spécifique à chaque niveau métamorphique ou classe de neige peut améliorer la précision des estimations de la densité.* Ainsi, le second objectif était de ***développer un modèle hybride (MH) d'estimation de la densité des manteaux neigeux saisonniers du Québec, composé d'un classificateur et de trois estimateurs spécifiques à trois niveaux ou classes de métamorphose (neige faiblement, moyennement métamorphosée, et fortement métamorphosée), étalonnés par régression multivariée.***

Les algorithmes de classification tels qu'utilisés pour étalonner le classificateur du MH sont généralement connus pour leur instabilité (Li & Belford, 2002). Une mauvaise sélection de l'estimateur final du MH, suite à une mauvaise classification, peut ainsi induire à des erreurs d'estimation de la densité de la neige. D'un autre côté, vu la complexité du phénomène à modéliser, il est souvent recommandé de se baser sur plusieurs décisions avant de prendre une décision finale (Polikar, 2006). C'est en partant de ces deux concepts que l'hypothèse de la troisième partie de la thèse a été formulée : 4. *L'utilisation des méthodes statistiques avancées telles que les méthodes d'ensemble à des fins de classification et de régression peut contrôler les erreurs dues à la classification et à l'estimation et développer des résultats de densité plus robustes.* Le troisième objectif des travaux de cette thèse était ainsi ***d'optimiser la performance du MH via le développement d'un modèle basé sur les méthodes de l'ensemble (MBME) pour l'estimation de la densité des manteaux neigeux saisonniers.***

## 1.4 Structure de la thèse

La présente thèse a la forme d'une thèse par articles. La première partie comprend une synthèse qui fait le lien entre chacun des trois articles qui la composent, et qui répondent aux trois sous-objectifs précédemment énoncés. Cette synthèse comprend l'introduction et les objectifs de la recherche, l'état de l'art des méthodes employées ainsi qu'un résumé des résultats et des conclusions. Elle permet de positionner ce travail par rapport aux travaux existants. La seconde partie présente les trois articles rédigés dans le cadre de cette thèse. Les deux premiers articles appuient respectivement le premier et deuxième sous-objectif de la thèse, tandis que le troisième article répond au dernier sous-objectif.

## 2 ÉTAT DE L'ART

---

Ce chapitre décrit les propriétés physiques et optiques des manteaux neigeux saisonniers et présente les principaux concepts utiles à la compréhension de la méthodologie.

### 2.1 Le manteau neigeux saisonnier

La couverture neigeuse est une importante composante du système climatique global, exerçant une influence considérable sur la température et la circulation atmosphérique. La neige saisonnière fournit de l'eau à environ 2 milliards de personnes dans le monde (Barnett *et al.*, 2005). C'est la principale source d'approvisionnement en eau au Canada (McKay & Findlay, 1971). En effet, la fonte du manteau neigeux qui se forme chaque année est d'une grande importance hydrologique et économique (Fayad *et al.*, 2017; Viviroli *et al.*, 2007). Cela explique pourquoi le principal objectif des modèles numériques de manteau neigeux était de simuler l'accumulation et la fonte de la neige. Il n'est donc pas étonnant que sa mesure et sa modélisation numérique fassent l'objet, d'une activité scientifique sans cesse croissante.

Le manteau neigeux saisonnier est le résultat de dépôt des précipitations neigeuses sur le sol. Au cours de chaque hiver, la répétition des chutes de neige, souvent de qualités et d'intensités différentes, provoque l'apparition de strates ou des couches distinctes dans le manteau neigeux (Kinar & Pomeroy, 2015). Cette stratification conduit ainsi à la formation d'un matériau hétérogène. Chaque couche peut être constituée de microstructure de neiges différente des couches voisines, et de ce fait, la stabilité du manteau neigeux dépend de la cohésion de chaque couche avec les couches voisines. Ces couches stratigraphiques diffèrent des couches adjacentes au-dessus et au-dessous par au moins l'une des propriétés physiques suivantes : taille des grains, type des grains, densité et teneur en eau liquide. Une fois la neige est déposée, ces propriétés physiques se transforment en quelques jours sous l'effet du métamorphisme (Colbeck, 1982) et leurs caractéristiques initiales changent rapidement.

La neige est un matériau très divisé, fragile et en perpétuelle évolution. L'ensemble des processus physiques modifiant la morphologie des grains de neige et l'évolution stratigraphique du manteau neigeux au cours du temps est dénommé métamorphisme (Colbeck, 1982; Colbeck, 1983; Sommerfeld, 1983). Les processus métamorphiques sont le résultat de la compression mécanique et par flux de masse (neige, eau liquide et vapeur d'eau) et flux d'énergie (rayonnement, par convection et conduction) à travers le couvert neigeux (Arons & Colbeck, 1995; Colbeck, 1991; Colbeck & Anderson, 1982). C'est un ensemble des phénomènes physiques affectant le manteau neigeux et produisant des changements dans les propriétés physiques (la taille des grains, le type

des grains, la densité et la teneur en eau liquide) et optiques (la réflectance spectrale) (Colbeck, 1982).

## 2.2 Les propriétés physiques de la neige

### 2.2.1 Type des grains

Les grains de neige qui constituent le manteau neigeux sont classés en fonction de leur type. Le Tableau 2-1 présente les principales classes morphologiques des types des grains. Cette classification de base est complétée par des sous-classes (Fierz *et al.*, 2009). En effet, les classes principales du type de grain sont classées en utilisant un symbole ou un code d'abréviation en majuscules unique. Les sous-classes sont classées en utilisant le symbole approprié ou un code d'abréviation de quatre lettres, ou deux lettres minuscules sont ajoutées au code de classe principal (Fierz *et al.*, 2009). Ce code d'abréviation est utile pour les formats d'échange de données électroniques tandis que les couleurs peuvent être utilisées pour des représentations continues dans l'espace ou dans le temps, par exemple dans des sorties de modèles de manteau neigeux. Une convention sur les couleurs à utiliser pour les classes principales est donnée dans la classification internationale des neiges saisonnières au sol (convention de couleurs pour les principales classes de formes de grains morphologiques – page 30) (Fierz *et al.*, 2009). Cette représentation de la classification morphologique et des processus physiques aide les différents groupes d'utilisateurs à obtenir une classification plus fiable et une interprétation physique plus facile de leurs observations.

Tableau 2-1: Principales classes morphologiques de type de grain, The International Classification for Seasonal Snow on the Ground (Fierz *et al.*, 2009).

<b>Classe</b>	<b>Symbole</b>	<b>Code</b>
Cristaux de neige fraîche	+	CNF
Particules reconnaissables	/	PR
Grains fins	•	GFS
Grains à faces planes	□	GFP
Givre de profondeur, gobelets	∧	GP
Givre de surface	∨	GS
Grains ronds, Grains de fonte	○	GR, GFE
Formations de glace	■	FG

L'examen des grains de neige à diverses profondeurs dans un manteau neigeux permet de découvrir plusieurs types tels que des particules reconnaissables, des grains ronds, soit petits soit gros, des grains ayant des facettes hexagonales ou partiellement hexagonales, des grains ayant des formes de gobelets et une multitude de formes intermédiaires (Figure 2-1). Le type des grains est déterminé sur le terrain en utilisant une carte millimétrique et une loupe de grossissement alors qu'un stéréo microscope est nécessaire pour un travail spécialisé en laboratoire (Lesaffre *et al.*, 1998).




Figure 2-1 : Principales classes morphologiques des formes des grains (Fierz *et al.*, 2009).

D'un autre côté, la neige au sol n'est pas un matériau inerte dans le temps. Dès l'instant de son dépôt et même au moment de sa chute, la neige est soumise aux effets conjugués de plusieurs facteurs dont les plus déterminants sont les conditions météorologiques (Pahaut, 1975). Elle va s'ensuivre trois cycles d'évolutions ou de métamorphose : 1) Métamorphose de gradient : est impliqué lorsque le manteau neigeux est soumis à des inégalités de température entre le sol, isolé, et la surface, en

contact avec l'atmosphère. L'existence d'un tel gradient de température est à l'origine de gradients de pression de vapeur d'eau qui induisent des flux de vapeur d'eau à travers tout le manteau (Taillandier, 2006); 2) Métamorphose d'isothermie (ou de faible gradient) : se produit lorsque le gradient de température au sein du manteau neigeux est négligeable et correspond à un régime de très faibles sursaturations. Il se rencontre principalement dans les manteaux neigeux épais, qui minimisent les gradients thermiques ou lors de conditions atmosphériques stables, quand la température reste proche de 0 °C. Ce métamorphisme entraîne principalement une densification de la neige et un arrondissement des grains (Taillandier, 2006); et 3) Métamorphose de fonte. Ces trois cycles d'évolution amènent les grains de neige de leur forme initiale (neige fraîche ou récente) à des formes granulaires âgées (Figure 2-2). L'origine de ces regroupements de neige de la Figure 2-2 réside dans les processus métamorphiques subis par les grains de neige après leur dépôt et leur transformation dans le manteau neigeux. Ces processus opèrent de différentes manières en fonction de la température, du gradient de température et de la quantité d'eau dans la neige (Pahaut, 1975).




Figure 2-2 : Cycle de métamorphose de la neige (Pahaut, 1975); C1 : faiblement métamorphosé, C2 : moyennement métamorphosé, C3 : fortement métamorphosé.

### 2.2.2 Taille des grains et surface spécifique

La taille des grains ou particules de neige (également appelée "cristaux") est souvent définie comme le plus petit élément constitutif du manteau neigeux. En effet, les couches dans le manteau neigeux sont créées par des événements de dépôt et des processus métamorphiques (Pielmeier & Schneebeli, 2003). Ces derniers sont responsables de la création et de la destruction des couches dans le manteau neigeux et de la modification de la microstructure de neige au fil du temps (Colbeck,

1991). Le manteau neigeux est composé des grains de neige plus ou moins liés les uns aux autres, qui ont des formes et des tailles qui changent au cours du processus de métamorphisme. Afin d'obtenir la description d'un échantillon de neige, il est nécessaire de donner des renseignements sur sa structure. Le paramètre le plus simple est la taille moyenne des grains (Marbouty, 1983). On peut donc considérer que la taille des grains d'une couche de neige est la taille moyenne de ses grains. Dans les modèles, si une appréciation de la structure est nécessaire, la neige est en général considérée comme un ensemble de grains sphériques (modèles optiques) ou d'ellipsoïdes (modèles électroniques) (Marbouty, 1983). Selon la classification internationale des neiges saisonnières au sol (Fierz *et al.*, 2009), la taille des grains peut être exprimée en utilisant les termes du **Tableau 2-2 : Taille des grains selon la classification internationale de la neige saisonnière au sol (Fierz *et al.*, 2009)**.

Tableau 2-2 : Taille des grains selon la classification internationale de la neige saisonnière au sol (Fierz *et al.*, 2009).

Terme	Taille (mm)
Très fin	< 0,2
Fin	0,2 – 0,5
Moyen	0,5 – 1,0
Grossier	1,0 – 2,0
Très grossier	2,0 – 5,0
Extrêmement grossier	> 5,0

La taille d'un grain ou d'une particule est sa plus grande extension mesurée en millimètres. On distingue des petits et des gros grains dans les manteaux neigeux. Une méthode simple pour mesurer la taille des grains sur le terrain consiste à placer un échantillon de grains sur une plaque qui a une grille millimétrique (Figure 2-3). La taille moyenne et la taille maximale moyenne sont ensuite estimées en comparant la taille des grains avec l'espacement des lignes de la grille sur la plaque (Fierz *et al.*, 2009).

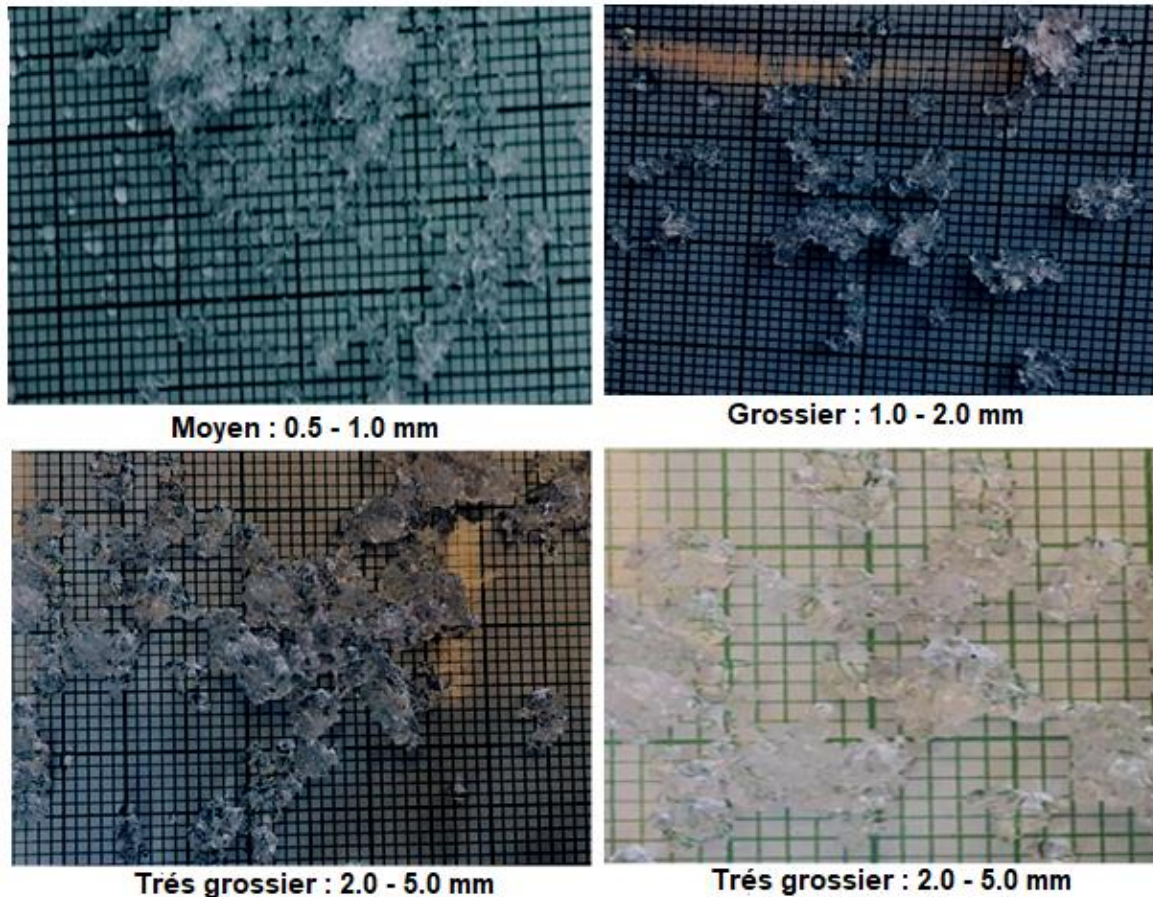


Figure 2-3 : Taille des grains, mesures de terrain ; hiver 2018.

La variable taille de grains reste ambiguë et de surcroît dépendants de l'observateur (Aoki *et al.*, 2000). Il serait donc plus judicieux de se concentrer sur une variable physique objective et mesurable : la surface spécifique (SS) (Gallet, 2010). La SS est un paramètre important qui peut être utilisé dans les modèles d'évolution du manteau neigeux. Elle régit également l'absorption d'espèces chimiques par la neige et influe sur les réactions chimiques qui se produisent dans le manteau neigeux (Gallet, 2010). La SS est également importante pour les applications impliquant des interactions chimiques ou électromagnétiques. Elle est définie comme la surface totale de l'interface air/glace soit par unité de masse ( $SS_m$  ( $m^2 kg^{-1}$ )) d'un échantillon de neige ou par unité de volume ( $SS_v$  ( $m^2 m^{-3}$ )) (Fierz *et al.*, 2009).

La SS de la neige est reliée au rapport ( $\frac{S}{V}$ ), avec la surface (S) d'un grain de neige et son volume (V). Elle apparaît donc comme une variable objective qui se substitue avantageusement à la taille de grains et elle vaut :

$$SS = \frac{S}{\rho_{\text{glace}} \times V} ; (m^2 kg^{-1}) \quad (2-1)$$



Avec  $S$  la surface d'un cristal de neige,  $V$  son volume et  $\rho_{glace}$  est la densité de la glace qui vaut  $917 \text{ kg m}^{-3}$  à  $0^\circ\text{C}$  (Gallet, 2010). Il existe plusieurs méthodes pour mesurer la SS de la neige. Nous allons en présenter les quatre principales :

#### 2.2.2.1 Stéréologie

Brièvement, un bloc de neige est rempli d'un liquide insoluble dans l'eau qui gèle à  $T < 0^\circ\text{C}$  pour le durcir. Le polissage de l'échantillon produit des coupes en série qui sont photographiées (Perla *et al.*, 1986). Les images sont ensuite analysées (Davis *et al.*, 1987) pour donner une valeur de la SS après environ quatre heures de travail. Par cette méthode, Narita (1969) a mesuré la SS de différents échantillons de neige. Il a obtenu une centaine de valeurs de SS comprises entre  $6$  et  $75 \text{ m}^2 \text{ kg}^{-1}$ . Cette méthode est également bien établie, mais ne fonctionne pas bien pour les grains de neige fraîche avec SS élevée, qui sont facilement détruites lors de l'imprégnation ou de la découpe (Gallet, 2010), et qui ne peuvent pas être manipulées facilement.

#### 2.2.2.2 Adsorption de méthane

La plupart des mesures de SS publiées à ce jour ont été obtenues en utilisant l'adsorption de méthane à  $77\text{K}$  (Legagneux *et al.*, 2002). Cette méthode consiste à placer la neige dans un cylindre en inox et à mesurer l'isotherme d'adsorption du méthane sur la neige à la température de l'azote liquide ( $77\text{K}$ ), par une méthode volumétrique. La méthode de traitement mathématique Brunauer-Emmett-Teller (BET) est ensuite appliquée à l'isotherme afin de déterminer la surface totale de l'échantillon (Brunauer *et al.*, 1938). La SS est ensuite obtenue en divisant cette surface totale par la masse de l'échantillon de neige. Bien que cette méthode soit fiable et précise, avec une reproductibilité de  $6\%$ , l'obtention d'une valeur prend trois heures et nécessite de l'azote liquide. Cette méthode nécessite une chambre froide pour préparer l'échantillon de neige et une isotherme locale qui limitera les variations de température lors de la mesure de l'isotherme (Gallet, 2010). Dépendante d'azote liquide, cette mesure par adsorption de méthane est très délicate à mettre en place sur le terrain. Même si un isotherme demande trois heures de travail, la mesure de la SS de la neige par adsorption de méthane est la méthode la plus couramment utilisée et la plupart des données de SS disponibles dans la littérature sont mesurées avec cette méthode (Gallet, 2010).

#### 2.2.2.3 Tomographie de rayons X

Le terme tomographie signifie l'obtention d'images 3D de la structure d'un matériau, comme l'irradiation par rayons X. Cette méthode de mesure utilise l'imagerie par rayon X pour déterminer la surface de la neige (Kerbrat *et al.*, 2008). Des échantillons de neige sont prélevés et imprégnés au chloronaphtalène afin de conserver la microstructure de la neige. Une image en trois dimensions en

niveau de gris est obtenue par mesure de l'absorption des rayons X à travers l'échantillon de neige. Les images possèdent trois niveaux de contraste associés à trois phases : la neige, le chloronaphtalène et l'air (bulles d'air n'ayant pas été imprégnée). Le traitement des images permet d'obtenir une image binaire en trois dimensions de l'échantillon de la neige (Flin *et al.*, 2003). Une mesure de SS de neige par tomographie est très délicate à mettre en œuvre sur le terrain. Plusieurs heures sont nécessaires à l'obtention d'une valeur et même si la résolution d'une source de rayon X est de l'ordre de quelques microns, elle est encore insuffisante si la SS est supérieure à 70 m<sup>2</sup> kg<sup>-1</sup> (Kerbrat *et al.*, 2008), valeur souvent dépassée dans le cas d'une neige fraîche.

#### 2.2.2.4 Méthodes optiques

Les trois méthodes présentées ci-dessus sont longues et parfois entachées d'une forte incertitude. De plus, elles se révèlent délicates pour être appliquées sur le terrain. Une solution permettant de mesurer rapidement et de manière fiable la SS de la neige sur le terrain a été proposée par la communauté scientifique est basée sur des méthodes optiques (Gallet, 2010). Une taille de grain dite optique équivalente peut être définie à partir de la SS (Grenfell & Warren, 1999). La taille de grain d'équivalent optique est liée à la SS et donc à la microstructure de la neige. Si on assimile la neige à des sphères, ce qui est le cas lorsque l'on modélise les propriétés optiques du manteau neigeux (Grenfell & Warren, 1999) le rayon d'une sphère de même rapport ( $\frac{S}{V}$ ) que la particule de neige peut être considérée comme la taille de grain. Dans ce cas simplifié, la formule de la SS vaut :

$$SS = \frac{3}{\rho_{\text{glace}} \times r_{\text{eff}}} ; (\text{m}^2 \text{kg}^{-1}) \quad (2-2)$$

Avec  $r_{\text{eff}}$  est le rayon effectif ou le rayon des particules sphériques représentant les particules de neige, ou encore le rayon optique (Gallet, 2010). La SS de la neige est donc inversement proportionnelle à la taille des grains de neige, si ces derniers sont sphériques.

#### 2.2.3 Densité de la neige

La densité de la neige aussi appelée masse volumique, représentant la masse de neige dans un volume de référence, exprimée en kg m<sup>-3</sup>. Le volume de référence est souvent appelé « volume de contrôle ». Il s'agit d'un volume arbitraire pour lequel la masse de neige est mesurée. Elle est probablement la variable la plus couramment mesurée dans un manteau neigeux, normalement déterminée en pesant de la neige d'un volume connu. La densité de la neige englobe tous les constituants de la neige (grains de neige, eau liquide et air) tandis que la densité de la neige sèche se rapporte à la matrice de grains de neige et à l'air seulement (Fierz *et al.*, 2009). Le métamorphisme, qui produit des formes différentes de taille et formes de grains, entraîne également une densité

constante ou croissante. En effet, les divers processus métamorphiques et le compactage de la neige par son poids augmentent la densité de la neige durant l'année en partant de valeurs autour de  $80 \text{ kg m}^{-3}$  pour une neige récente, pour finir à  $500\text{-}600 \text{ kg m}^{-3}$  au moment de la fonte (Pomeroy & Gray, 1995).

Le métamorphisme de la neige transforme généralement le type et la taille des grains de la neige même lorsque d'autres paramètres, tels que la densité, restent constants (Gallet, 2010). Le Tableau 2-3 montre la répartition des densités par type de neige (Pahaut, 1975), cela vérifie que la neige se tasse au fur et à mesure de son évolution. Les différentes nuances de gris utilisées dans les graphiques à barres indiquent les niveaux de métamorphose de chaque échantillon de neige récupérée.

Pour un pays comme le Canada, qui couvre une très grande superficie avec une vaste couverture de neige, la surveillance régulière de la densité de la neige est importante (Roy *et al.*, 2004; Sturm *et al.*, 2010). La densité est mesurée à l'aide d'une variété de méthodes et de technologies. Il s'agit notamment de mesures manuelles consistant à prélever des carottes de neige (comme les tubes à neige " fédéraux ", p. ex. ESC-30) (Fassnacht *et al.*, 2013; Male, 1981), ou de l'installation de dispositifs qui reposent à plat sur le sol et pèsent la neige à mesure qu'elle s'accumule sur le dessus (comme les oreillers à neige) (Molnau, 1971). Cependant, chacune de ces méthodes présente plusieurs inconvénients (Kinar & Pomeroy, 2015; Zuanon, 2013). Les mesures des carottes de neige demandent beaucoup de travail, prennent du temps, ne sont pas réalisables pour une collecte de données sur 24 heures et sont sujettes à des erreurs humaines. Les oreillers de neige présentent des erreurs de mesure, des problèmes de logistique et de transport pour leur installation, et ne peuvent mesurer qu'une surface d'environ  $10 \text{ m}^2$  (Kinar & Pomeroy, 2015). Il existe également d'autres méthodes pour mesurer la densité de la neige, notamment la télédétection proximale (comme la sonde d'équivalent en eau de la neige GMON (GammaMONitor) (Campbell Scientific Canada, Edmonton, AB, Canada)) (Wright *et al.*, 2011), la télédétection spatiale (télédétection par micro-ondes) (De Sève *et al.*, 1997). Cependant, ces méthodes présentent certains inconvénients ; par exemple, elles ne mesurent pas la densité de chaque couche de neige qui compose la stratigraphie verticale du manteau neigeux, mais seulement la densité moyenne du manteau neigeux. Récemment, les données des capteurs optiques ont été utilisées comme alternative pour surveiller la couverture neigeuse sur de grandes surfaces et ont permis d'améliorer la surveillance et la gestion de cette ressource en eau (Negi *et al.*, 2013). Pour optimiser le processus de modélisation de la densité de la neige et développer de nouveaux modèles efficaces, la haute résolution spectrale des capteurs hyperspectraux est essentielle (Gergely *et al.*, 2010).

Tableau 2-3 : Répartition de la densité de la neige par type de grains : + neige fraîche, λ particules reconnaissables, • grains fins, o grains ronds, ^ givre de profondeur, (Pahaut, 1975). Les différentes nuances de gris montrent les niveaux de métamorphose de chaque échantillon de neige.

Densité (kg m <sup>-3</sup> )		< 50	50 - 100	100 - 150	150 - 200	200 - 250	250 - 300	300 - 350	350 - 400	400 - 450	450 - 500	> 500
+	%	9	33	49	9							
	Nombre des échantillons (192)	13	63	93	21							
λ	%		7	19	38	22	14					
	Nombre des échantillons (69)		5	13	26	15	10					
•	%			2	8	20	22	23	18	7		
	Nombre des échantillons (117)			2	9	23	26	27	22	8		
^	%					11	33	35	18	3		
	Nombre des échantillons (63)					7	21	22	11	2		
o	%					4	8	14	30	30	11	3
	Nombre des échantillons (249)					10	20	35	75	75	27	

La mesure de la profondeur de la neige (d) ainsi que la mesure de la densité de la neige (ρ) servent à déterminer l'équivalent en eau de la neige (EEN) en tant qu'intrants dans les modèles hydrologiques.

$$EEN = d \rho \text{ (kg m}^{-2}\text{)} \quad (2-3)$$

La seule mesure de la profondeur n'est pas suffisante pour obtenir l'EEN car la densité varie horizontalement et en permanence. (Gray *et al.*, 1970) et doit être mesurée plutôt que d'être censée être une valeur particulière telle que 100 kg m<sup>-3</sup> pour la neige fraîchement tombée (Pomeroy & Gray, 1995).

#### 2.2.4 Teneur en eau liquide

La teneur en eau liquide est définie comme la quantité d'eau dans la neige qui est dans la phase liquide. En effet, l'eau liquide dans la neige provient de la fonte, de la pluie ou d'une combinaison des deux. Les mesures de la teneur en eau liquide ou de l'humidité sont exprimées sous la forme d'une fraction de volume ou de masse. Les deux peuvent être rapportés en pourcentage (%) (Marbouty, 1983). Lorsque de l'eau liquide est présente dans la neige, on dit qu'elle est humide et la température d'équilibre entre les trois phases présentes de l'eau (solide, liquide et gazeuse) est nécessairement proche de 0°C (Colbeck, 1973). On peut distinguer deux régimes de transformation liés à la quantité d'eau liquide ou de la teneur en eau liquide présente dans la neige ou encore à la composition du mélange eau, glace et air (vapeur d'eau) : 1) Régime des faibles teneurs en eau liquide; 2) Régime des fortes teneurs en eau liquide (Figure 2-4).




Figure 2-4 : Schéma de la répartition des trois phases de l'eau, (a) dans le cas des faibles TEL et (b) dans le cas des fortes TEL (Marbouty, 1984).

La teneur en eau liquide est une mesure de la quantité fractionnée d'eau liquide dans les espaces poreux du manteau neigeux. Ceci est différent de l'EEN, qui est la hauteur d'eau résultante lorsque le manteau neigeux est complètement fondu. De plus, la présence d'eau liquide dans le manteau neigeux change avec le temps pendant la période de fusion (Marbouty, 1983). La fonte des neiges est considérée comme ayant trois périodes distinctes : 1) La phase de réchauffement : la température du manteau neigeux augmente et une température isotherme est atteinte à 0°C ; 2) La phase de maturation : lorsque l'eau est contenue dans le manteau neigeux, mais qu'elle ne sort pas du manteau neigeux et 3) La phase de saturation : lorsque le manteau neigeux ne peut plus contenir de l'eau liquide, la fonte de la neige se produit. Il existe plusieurs méthodes pour déterminer le pourcentage de la teneur en eau liquide de la neige sur le terrain. Ceux-ci comprennent la calorimétrie à froid

(congélation), la calorimétrie à l'alcool et la méthode de dilution (Boyne & Fisk, 1990), les mesures diélectriques (Denoth, 1994) et les mesures optiques (Eppanapelli *et al.*, 2018b; Negi *et al.*, 2010a).

## 2.3 Propriétés optiques de la neige

La compréhension des phénomènes optiques de réflexion spectrale VIS (400 à 900 nm) et PIR (900 à 1700 nm) est nécessaire afin de déterminer des méthodes efficaces de télédétection des propriétés physiques de la neige.

### 2.3.1 Réflectance spectrale de la neige

Les caractéristiques de réflectance des éléments de la surface terrestre, exprimées comme le rapport entre l'énergie réfléchi par la surface et l'énergie incidente sur la surface et mesurées en fonction de la longueur d'onde, sont appelées la réflectance spectrale. Elle peut varier de 0 à 100 % (Warren, 1982). La réflectance spectrale se définit comme le rapport de la réflexion de la surface de la neige à celle d'une plaque blanche qui est souvent proche de 100% pour toutes les longueurs d'onde (Gallet, 2010). Le Tableau 2-4 montre toutes les surfaces qui renvoient plus de la moitié du rayonnement solaire incident visible sur Terre sont composées de neige.

La neige possède une forte réflectance à cause des multiples surfaces de glace qui y sont présentes et qui contribuent à la diffusion de la lumière, c'est-à-dire à la perturbation de la propagation des ondes lorsque celles-ci rencontrent un obstacle (Gallet, 2010). Parce que la neige est un milieu fragile et en perpétuelle évolution, elle subit une métamorphose au cours du temps (Colbeck, 1983) qui a presque toujours pour conséquence le changement de ses propriétés physiques et la diminution de sa réflectance spectrale dans le VIS et le PIR (Flanner & Zender, 2006; Taillandier *et al.*, 2007).

Tableau 2-4 : Valeurs typiques de la réflectance spectrale (300 - 2500 nm) des différents types de surfaces à la surface de la Terre (Kuipers Munneke, 2009).

Surface	Réflectance spectrale	
	Min	Max
Neige récente	0,8	0,9
Neige âgée	0,7	0,8
Névé	0,43	0,69
Glace de glacier propre	0,34	0,51
Glace de glacier sale	0,15	0,33
Eau des océans	0,03	0,25
Barre rocheuse	0,15	0,3
Prairie	0.16	0.2

La Figure 2-5, montre que la réflectance de la neige présente une forte variabilité sur le spectre optique qui nous intéresse (300 - 2500 nm). Elle est forte dans le visible et l'ultraviolet et devient modérée à faible dans le PIR et encore plus dans le MIR (Warren, 1982). Selon Negi *et al.* (2010a) la réflectance spectrale en PIR est très sensible aux propriétés physiques de la neige. Tandis que, dans le VIS (pour la neige pure) elle est sensible aux détections des impuretés. La taille des grains, le type des grains et la densité augmentent normalement avec le vieillissement de la neige, ce qui entraîne une réduction de la réflectance spectrale (Negi *et al.*, 2010a). En outre, la présence d'eau liquide, ou la teneur en eau liquide a également un effet sur la réflectance spectrale de la neige dans le spectre PIR (Eppanapelli *et al.*, 2018a; Negi *et al.*, 2010a).

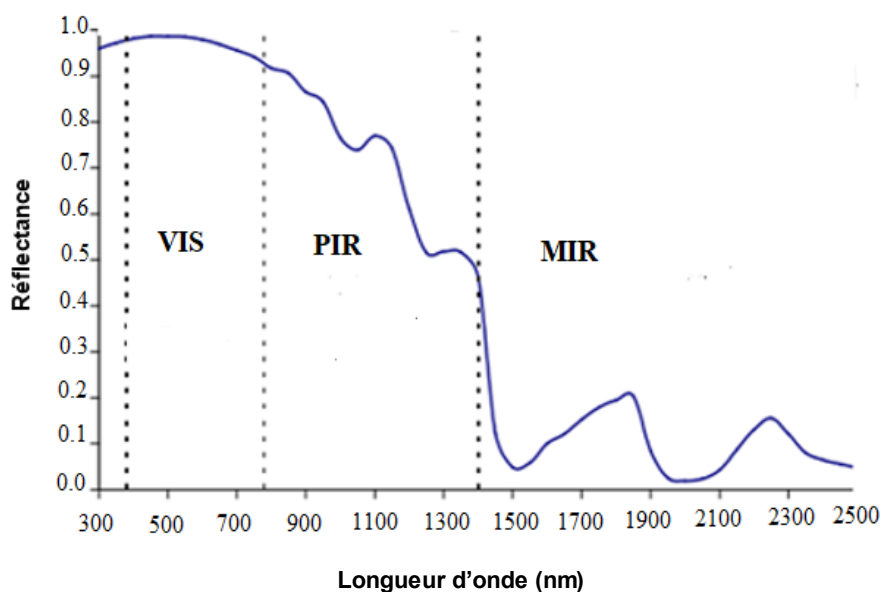


Figure 2-5 : La réflectance spectrale d'une neige pure de  $SS = 50 \text{ m}^2 \text{ kg}^{-1}$  et représentation des bandes du VIS, du PIR et MIR (Gallet, 2010).

### 2.3.2 Relations et analyses entre réflectance spectrale et les propriétés physiques de la neige

#### 2.3.2.1 Type des grains

Les types des grains de la neige peuvent être cartographiés à partir d'images optiques (proximales (Domine *et al.*, 2006; Gallet *et al.*, 2014), aéroportées ou satellitaires (Kokhanovsky *et al.*, 2019; Lyapustin *et al.*, 2009)) en développant des relations entre la microstructure de la neige et la réflectance en proche et moyen infrarouge. Horton and Jamieson (2017) ont calculé des indices de différence normalisés dans le PIR qui ont démontré un grand potentiel de classification des types de neige. La forme géométrique de la neige influe également la relation entre la SS et la réflectance, car les géométries arrondies telles que les sphères réfléchissent moins que les cubes, les colonnes ou les géométries creuses. Bühler *et al.* (2015) ont utilisé des images aéroportées à haute résolution

spatiale pour identifier les régions de neige fraîche, de neige soufflée par le vent et de neige mouillée en terrain alpin en calculant des indices de différence normalisés dans le PIR.

Les types des grains ont été rapportés dans de nombreuses études et montrent systématiquement que la neige fraîchement déposée (CNF) a une plus grande SS (Domine *et al.*, 2007; Gallet *et al.*, 2009; Horton & Jamieson, 2017; Libois *et al.*, 2015). Par exemple, sur un total de 345 échantillons de neige, Domine *et al.* (2007) ont rapporté qu'une SS moyenne de  $85 \text{ m}^2 \text{ kg}^{-1}$  représente une neige fraîchement tombée, une SS de  $40 \text{ m}^2 \text{ kg}^{-1}$  représente des particules reconnaissables (PR), une SS de  $21 \text{ m}^2 \text{ kg}^{-1}$  représente des grains fins (GFS), une SS de  $18 \text{ m}^2 \text{ kg}^{-1}$  représente des grains à faces planes GFP, une SS de  $12 \text{ m}^2 \text{ kg}^{-1}$  représente des gobelets (GP), une SS de  $34 \text{ m}^2 \text{ kg}^{-1}$  représente des givres de surface (GS) et une SS de  $29 \text{ m}^2 \text{ kg}^{-1}$  représente des grains ronds (GR) et des grains de fonte (GFE). Cela explique que, la réflectance spectrale de différents types ou formes de grain est relativement mieux expliquée par leur SS ou taille des grains (Domine *et al.*, 2007).

Les types des grains associés à une SS plus grande étaient généralement plus réfléchissants aux longueurs d'ondes PIR et MIR. Par exemple, Domine *et al.* (2007) ont révélé que les CNF et les GF (gobelets) avaient, respectivement, la SS la plus grande et la plus petite et qu'il s'agissait des types de neige les plus et les moins réfléchissantes. Horton and Jamieson (2017) ont trouvé que les grains fins étaient sensiblement moins réfléchissants que les GFP proches de la surface du couvert nival (Figure 2-6 et Figure 2-7).

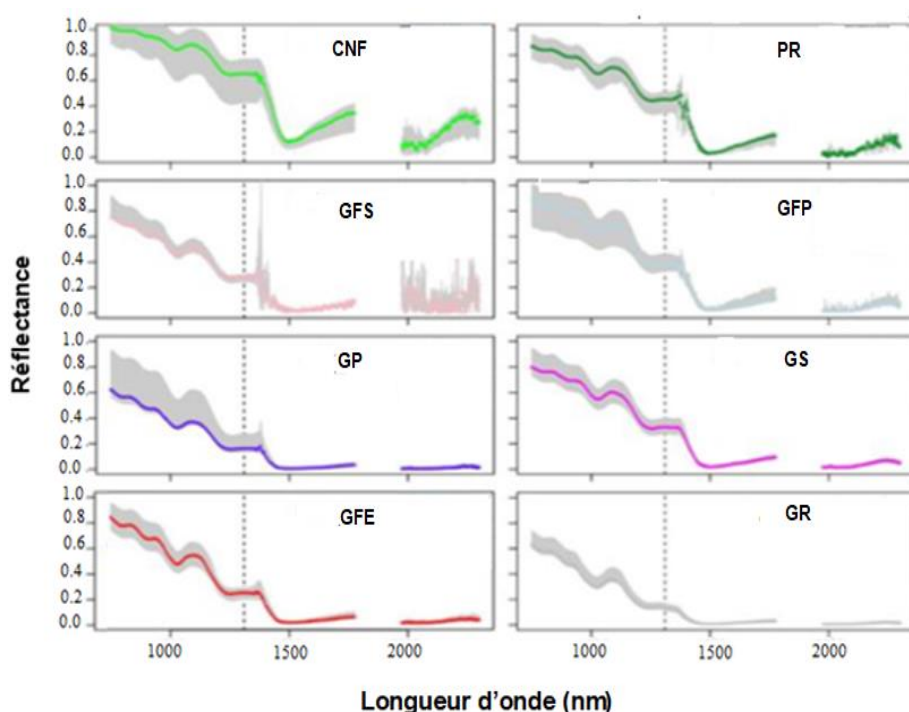


Figure 2-6 : Réflectance spectrale des cristaux de neige fraîche (CNF), des particules reconnaissables (PR), des grains fins (GFS), grains à faces planes (GFP), givre de profondeur (des gobelets) (GP), du givre de surface (GS), des grains de fonte (GFE), et des ronds (GR). La réflectance médiane à chaque longueur d'onde est montrée avec des lignes colorées et la gamme interquartile est montrée avec l'ombrage gris. La ligne pointillée montre la bande de longueur d'onde à 1310 nm (Horton & Jamieson, 2017).






Figure 2-7 : La réflectance spectrale médiane de chaque type de neige (Horton & Jamieson, 2017).

### 2.3.2.2 Taille des grains ou surface spécifique de la neige

La complexité de la stratigraphie empêche généralement un échantillonnage détaillé et exhaustif de la neige pour déterminer la SS qui est considérée comme un paramètre de microstructure essentiel pour la caractérisation de la neige (Gallet *et al.*, 2009). En effet, la réflectance spectrale de la neige est déterminée en partie par la taille et la forme des grains de neige, en particulier dans le spectre proche et moyen infrarouge. De nombreux modèles de réflectance spectrale des neiges représentent les grains de neige par des sphères d'un rapport surface / volume égal à celui des grains de neige, c'est-à-dire par sa SS (Gallet, 2010). Des études expérimentales et de terrain ont montré que la vitesse de décroissance de la SS est en fonction de la température et du gradient de température (Cabanes *et al.*, 2002; Taillandier *et al.*, 2007). Pour un même gradient de température, plus la température est élevée et plus la décroissance de la SS de la neige est rapide (Taillandier *et al.*, 2007). Si la SS de la neige diminue, sa réflectance spectrale diminue et donc la quantité d'énergie absorbée augmente de sorte que la température de la neige de surface augmente, d'où en conséquence le métamorphisme et cela constitue une rétroaction positive. La Figure 2-8 indique que toutes les longueurs d'onde supérieures à environ 1000 nm seraient appropriées, l'absorption étant très importante à ces longueurs d'onde (Domine *et al.*, 2006). Dans la gamme du MIR (1000 à 2500 nm), la glace est un absorbeur puissant et sa réflectance est très fortement influencée par la taille et la forme, tout en étant insensible aux impuretés (Gallet, 2010). Décrire l'effet de la taille et de la forme des cristaux sur les propriétés optiques de la neige est une tâche énorme et la communauté scientifique s'y intéresse incessamment.

Selon Gallet *et al.* (2014), la SS est le paramètre le plus déterminant pour la réflectance de la neige dans le spectre du PIR (900 à 1700 nm). La Figure 2-9 montre que pour une erreur expérimentale donnée sur la mesure de réflectance (dR), l'erreur engendrée sur la valeur de SS (dSS/dR) est deux fois plus faible à 1030 nm et trois fois plus faible à 1310 nm qu'à 900 nm. Les mesures de SS sont

donc plus précises si on utilise de plus grandes longueurs d'onde, comme 1310 nm. Également, il a été observé qu'à 1550 nm, la précision est encore meilleure pour des neiges dont la SS est supérieure à  $110 \text{ m}^2 \text{ kg}^{-1}$ . Il est donc plus avantageux de travailler avec des longueurs d'onde comme 1310 et 1550 nm (Gallet, 2010). De plus, au-delà de 1000 nm de longueur d'onde, l'effet des impuretés est négligeable (Flanner *et al.*, 2007; Painter *et al.*, 2007) car la glace devient très absorbante (Warren & Brandt, 2008). Domine *et al.* (2006) ont montré expérimentalement que la SS de la neige à elle seule suffisait à expliquer les variations de la réflectance pour des longueurs d'onde comprises entre 1310 et 2260 nm. À partir d'une bonne corrélation entre la SS et réflectance sur ces longueurs d'onde, ces auteurs suggèrent qu'il serait possible de mesurer la SS de la neige à partir de sa réflectance dans cette plage spectrale. Les mêmes auteurs en partenariat avec Painter *et al.* (2007) ont utilisé un spectroradiomètre disponible dans le commerce fonctionnant à des longueurs d'onde comprises entre 350 et 2500 nm pour relier le rayonnement spectral de la neige à la taille des particules optiques de la neige. Les résultats obtenus ont prouvé que pour des tailles de particules de neige comprises entre  $50 \mu\text{m}$  et  $100 \mu\text{m}$ , la précision était de  $\pm 10 \mu\text{m}$  et  $\pm 50 \mu\text{m}$ , respectivement. D'autres chercheurs ont déterminé la SS de la neige en utilisant une sphère d'intégration fabriquée à partir d'un polymère avec un coefficient de réflexion optique connu (Gallet *et al.*, 2009). L'erreur dans la détermination de la SS avec cette technique était de 12%. Les longueurs d'onde de la lumière infrarouge (IR) utilisées dans les expériences étaient de 1310 nm et 1550 nm. Montpetit *et al.* (2011) ont adapté le système de Gallet *et al.* (2009) et ont démontré que la sphère d'intégration pouvait être utilisée pour déterminer la SS et la réflectance spectrale le long du côté d'un mur de la fosse (Figure 2-10). Des courbes d'étalonnage ont été utilisées par la suite pour corrélérer la SS et la réflectance.

Ces techniques optiques ont montré un énorme potentiel pour l'étude et la mesure détaillées sur le terrain de la SS qui constitue la stratigraphie du manteau neigeux.

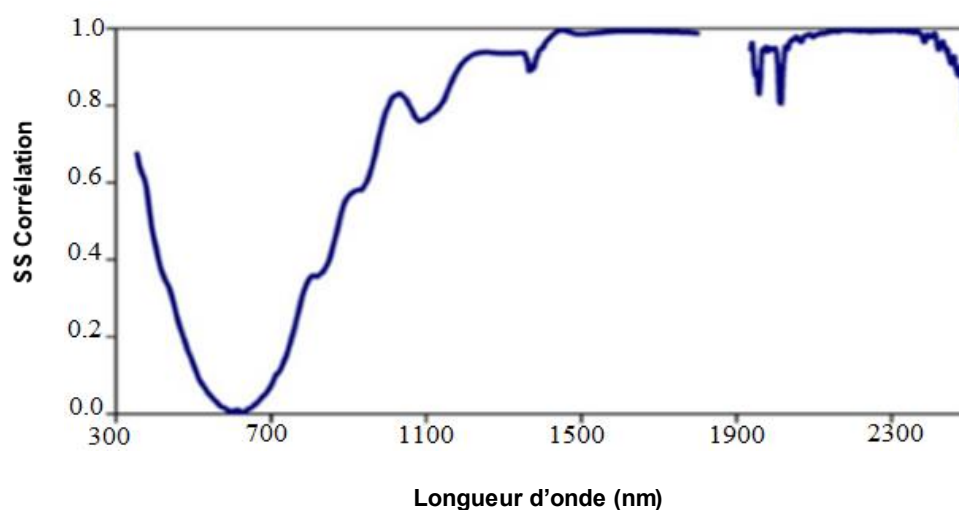


Figure 2-8 : Coefficients de déterminations linéaires entre réflectance et SS, en fonction des longueurs d'ondes (Domine *et al.*, 2006).




Figure 2-9 : Sensibilité de la SS à une erreur expérimentale sur la mesure de réflectance pour 4 longueurs d'ondes (900, 1030, 1310 et 1550 nm) (Gallet, 2010).



Figure 2-10 : Mesure de la SS en utilisant une sphère d'intégration (Montpetit *et al.*, 2011).

### 2.3.2.3 Densité de la neige

Plusieurs modèles et approches conçus pour modéliser la densité de la neige à partir de données spectrales, mais aucun n'a encore atteint une performance satisfaisante (Domine *et al.*, 2007; Li *et al.*, 2016). Ceci est probablement dû au fait que la plupart des modèles sont basés sur l'hypothèse que les mesures de densité peuvent être modélisées en utilisant la même fonction. La réflectance spectrale en fonction de la densité de la neige est présentée à la Figure 2-11. On peut voir que la réflectance spectrale diminue avec l'augmentation de la densité de la neige et montre une relation avec la densité de la neige avec  $R^2 = 0.77$  (Li *et al.*, 2016)

Selon Bohren & Beschta, 1979 la corrélation entre la réflectance spectrale et la densité de neige est probablement le résultat des changements qui se produisent dans le processus de vieillissement (métamorphose). En effet, la neige est une agrégation de nombreuses petites particules, on peut s'attendre à ce que sa réflectance spectrale soit en fonction de la densité et de la taille des grains (Bohren & Beschta, 1979). Il est important de souligner que la densité et la taille des grains sont des variables indépendantes en ce qui concerne les propriétés optiques de la neige. Les propriétés d'absorption et de diffusion d'une seule particule arbitraire dépendent de la taille. Tandis que les propriétés optiques globales d'une agrégation des particules dépendent de la densité (Bohren & Beschta, 1979) :

$$RS = RS(d, \rho) \quad (2-4)$$

avec : RS est la réflectance spectrale, d est l'agrégation d'une dimension caractéristique des particules, et  $\rho$  est la masse volumique de l'agrégation (Bohren & Beschta, 1979). Pour simplifier, d'autres paramètres ne sont pas inclus dans l'équation (2-4), tels que le type des grains, la teneur en eau liquide et les propriétés optiques intrinsèques des particules (indice de réfraction et coefficient d'absorption). Selon Bohren and Beschta (1979) une corrélation entre d et  $\rho$  est possible.

L'analyse susmentionnée confirme que la corrélation réciproque entre la réflectance spectrale dans le NIR et la densité de la neige est probablement le résultat d'autres changements dans le processus de vieillissement, tels que la température, la longueur du jour, le rayonnement, etc. (Dozier & Painter, 2004). Même si la réflectance spectrale de la neige dans le proche infrarouge dépend de la densité, elle est exprimée par la taille et la forme des grains (granulométrie) et la teneur en eau liquide de la neige (Bohren & Beschta, 1979). Par conséquent, les propriétés optiques des paramètres physiques de la neige s'influencent mutuellement et créent une relation non bijective (surjective) entre la densité de la neige et sa réflectance dans le proche infrarouge, ce qui entraîne de mauvaises corrélations.




Figure 2-11 : Corrélation entre la réflectance spectrale et la densité de la neige dans le PIR (Li *et al.*, 2016).

#### 2.3.2.4 Teneur en eau liquide de la neige

La répartition de l'eau et les variations temporelles de ces quantités dans la couverture naturelle de neige sont des paramètres importants pour les études de télédétection de la neige, les études de stabilité de la neige, et les études d'hydrologie des neiges (Kinar & Pomeroy, 2015). Green *et al.* (2002) ont développé et testé un algorithme d'ajustement spectral pour dériver la fraction granulométrique et la fraction liquide d'eau des mesures de réflectance spectrale des neiges. Des valeurs cohérentes de granulométrie et d'eau liquide ont été extraites des spectres de neige mesurés. Cette recherche a démontré que l'utilisation de modèles spectraux et de mesures spectrales est possible pour calculer la taille des grains de neige de surface et la fraction d'eau liquide. Eppanapelli *et al.* (2018b) ont examiné la dépendance de la teneur en eau liquide sur les propriétés de la réflectance spectrale de la neige. Ils ont utilisé deux capteurs optiques, un spectromètre PIR est un capteur routier, pour mesurer l'intensité de la lumière rétrodiffusée provenant de la neige avec une valeur de teneur en eau liquide connue. Les observations expérimentales ont montré que les propriétés de réflexion de la neige diminuent avec l'augmentation de la fraction de la teneur en eau liquide dans la neige.

Negi *et al.* (2010a) ont montré, qu'à partir de mesures de terrain, que pour une variation d'humidité allant jusqu'à 2,6% de la surface supérieure de la couverture neigeuse, une diminution de la réflectance a été observée dans la région PIR, une variation irrégulière dans la région VIS et aucun changement dans la région MIR (Figure 2-12). Pour des changements de teneur en eau, les variations maximales observées sont autour de 980 et 1160 nm.




Figure 2-12 : Réflectance spectrale en fonction de la longueur d'onde pour différents taux d'humidité (Negi *et al.*, 2010a).

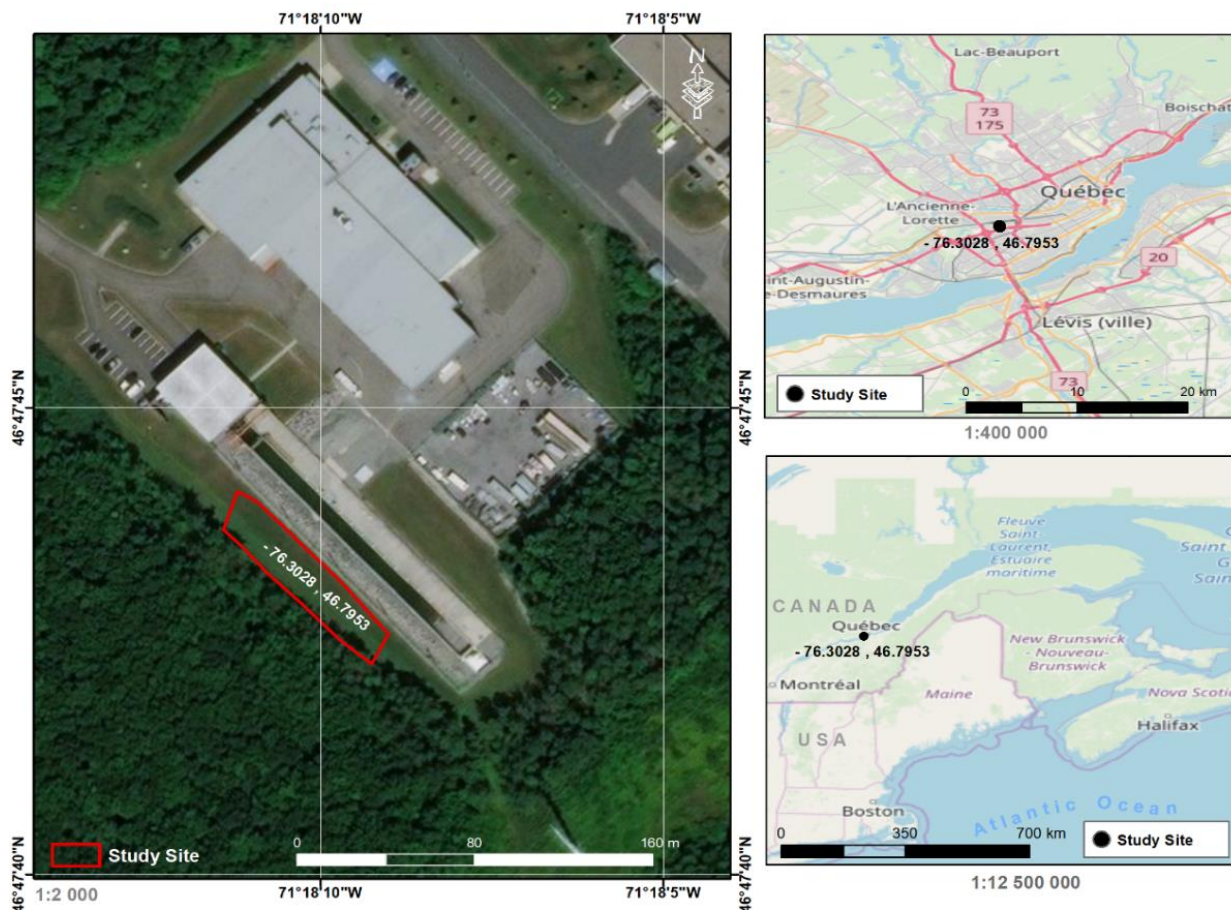




### 3 MÉTHODOLOGIE GÉNÉRALE

#### 3.1 Zone d'étude

Située à la latitude  $46^{\circ} 47' 43.22''$  nord, et la longitude  $-71^{\circ} 18' 10''$  ouest, la zone d'étude est localisée dans la ville de Québec sur un terrain appartenant à l'Institut national de la recherche scientifique (INRS) (Figure 3-1). Les mesures ont été effectuées le long des trois saisons d'hivers 2018 (19 janvier et 27 mars), 2019 (10 janvier et 3 avril) et 2020 (29 janvier et 10 mars 2020), entre 08h00 et 12h00 dans des conditions hivernales et par temps clair. Ces mesures de neige représentent différents stades d'évolution du manteau neigeux saisonnier de cette zone d'étude. Le manteau neigeux dans cette région est sec de janvier à la mi-février en raison des basses températures et devient humide en mars lorsque la température augmente. Une zone ouverte d'environ  $20 \text{ m}^2$  le long d'une forêt de feuillus, a été choisie comme site d'échantillonnage tout au long des trois hivers (Figure 3-1).



Les principales caractéristiques de rugosité et de pentes ont été évitées en échantillonnant uniquement les surfaces lisses et planes. Les surfaces contenant des impuretés ont également été évitées afin de récupérer autant d'informations représentatives que possible sur le manteau neigeux

saisonnier. Tableau 3-1 et Tableau 3-2 présentent le rapport des données de température et d'accumulation de neige au sol pour les hivers 2018, 2019 et 2020 selon <https://climate.weather.gc.ca/> consulté le 15 juillet 2021. Pour chaque profil de neige, une série de mesures physiques et optiques ont été effectuées et enregistrées.

Tableau 3-1. Rapport sur les données de température pour les hivers 2018, 2019 et 2020.

Année	Température (°C)							
	Janvier		Février		Mars		Avril	
	Max	Min	Max	Min	Max	Min	Max	Min
2018	-7,7	-18,3	-2,1	-15,2	1,6	-7,1	5,5	-4
2019	-8,2	-19	-6,2	-18,7	-0,2	-12,7	6,2	-1,6
2020	-4,5	-13,2	-3,2	-17,1	1,8	-8,6	7,1	-2,8

Tableau 3-2. Rapport sur les données d'accumulation de neige au sol pour les hivers 2018, 2019 et 2020.

Année	neige au sol (cm)							
	Janvier		Février		Mars		Avril	
	Max	Min	Max	Min	Max	Min	Max	Min
2018	67	24	81	58	80	48	56	2
2019	79	35	105	64	105	70	71	7
2020	49	14	76	47	85	61	64	0

### 3.2 Dispositifs expérimentaux

Afin de pouvoir mener à bien cette étude, deux types de données ont dû être collectées :

1) propriétés physiques (taille des grains, type des grains et densité) échantillonnées avec une carotteuse d'échantillonnage (Figure 3-2). 2) propriétés optiques (réflectance spectrale) mesurées avec une station d'acquisition proximale (Figure 3-3). Ces données ont été utilisées pour la calibration et la validation des modèles étudiés au cours de la présente thèse. Les mêmes équipements et techniques d'échantillonnage ont été utilisés tout au long de cette étude.

La carotteuse de neige rectangulaire portable est construite au sein de l'équipe de télédétection de l'INRS-ETE. Cet instrument permet d'extraire la stratigraphie verticale du manteau neigeux et par la suite d'analyser et de déterminer les caractéristiques physiques (densité, taille de grains et type de grains) et optiques (réflectance spectrale) récupérées. Les dimensions de la carotteuse (10×10×120 cm) permettent à ce que la stratigraphie verticale du manteau neigeux soit récupérée en entier et que la neige ne soit pas perdue. La carotteuse se compose de deux parties : 1) La partie intérieure est en métal et 2) La partie extérieure est en plastique, avec une extrémité de coupe triangulaire en dents de scie. La carotteuse est graduée avec des marques indiquant l'échelle de mesure (centimètres), ce qui permet de mesurer l'épaisseur et la position de couches de neige homogènes sélectionnées. Grâce à cette conception, le carottier assure l'extraction du profil vertical du manteau neigeux, avec ses variantes métamorphosées et sans perte de neige.






Figure 3-2 : La carotteuse d'échantillonnage de neige.

La station d'acquisition proximale est composée d'une caméra hyperspectrale à balayage de lignes PIKA NIR (société RESONON) embarquée sur une plaque de translation linéaire qui permet une acquisition rapide des images (5 seconds). Elle permet de mesurer la réflectance spectrale PIR à plusieurs longueurs d'ondes comprises entre 900 à 1700 nm, avec une résolution spectrale élevée de 5,5 nm, et 148 bandes spectrales. De plus, la station contient un ensemble de quatre lampes halogènes placées perpendiculairement à l'échantillon de neige pour un éclairage égal, un support de fixation, une plateforme mobile qui permet une acquisition rapide des images, un logiciel d'acquisition de données (Spectronon Pro (Resonon Inc., Bozeman MT, USA)) dédié à l'acquisition et à l'analyse des données hyperspectrales et des lentilles d'acquisition proximale (Figure 3-3).




Figure 3-3 : Dispositif d'acquisition d'images hyperspectrales proximales.

### 3.3 Analyse descriptive des données in situ

Le fonctionnement de la carotteuse est simple. Tout d'abord, la carotteuse est insérée dans la neige jusqu'à la profondeur voulue. Ensuite, une tranchée doit être effectuée afin d'avoir accès à la partie

inférieure de la carotteuse et y insérer une plaque qui empêchera la neige de tomber. La carotteuse est basculée horizontalement et elle est prête à être transportée jusqu'à un laboratoire mobile qui a été installé à quelques mètres du site d'échantillonnage. Le laboratoire mobile n'est pas chauffé afin de garder la même température que celle d'extérieur. De plus, les mesures (physiques et optiques) sont prises en seulement 10 minutes environ afin d'éviter toutes transformations possibles des grains de neiges extraits des manteaux neigeux. À cet endroit, il suffit de tirer sur la poignée et de retirer délicatement la partie intérieure avec toute la neige récupérée (Figure 3-4).



Figure 3-4 : La stratigraphie verticale à l'intérieur de la carotteuse, hiver 2018.

Une fois la stratigraphie verticale du manteau neigeux est récupérée, les propriétés physiques et optiques de la neige, ainsi que l'identification des couches de neige et leur épaisseur sont mesurées directement sur la carotteuse. La carotteuse est ensuite placée par rapport au champ de vision de la caméra (horizontalement) sur un banc métallique mobile de la station d'acquisition proximale pour être balayée ligne par ligne (Figure 3-5). Les facteurs de réflectance ont été calculés en mesurant la luminance réfléchie par la surface de la neige et la luminance réfléchie par une cible de référence. Cette dernière présente des propriétés de réflexion presque lambertiennes lorsqu'il est vu depuis le nadir. La vitesse de la plate-forme est ajustée pour que la résolution spatiale des axes vertical et horizontal soit égale, pour éviter toute distorsion de taille et pour s'adapter au temps d'exposition prédéterminé de la caméra.

Les images hyperspectrales sont acquises sous une forme 3D appelée hyper-cube composée de deux dimensions spatiales ( $x$ ,  $y$ ) et d'une dimension spectrale ( $\lambda$ ). Chaque cube hyperspectral est constitué de 148 points d'information spectrale à une résolution spectrale de 5,5 nm. Chaque pixel de l'image hyperspectrale contient le spectre de cette position spécifique caractérisant les propriétés physiques dans ce pixel. Une fois que la carotteuse est scannée avec la caméra hyperspectrale PIR, l'image générée est ensuite analysée avec le logiciel Spectronon Pro.




Figure 3-5 : Acquisition hyperspectrale de la stratigraphie verticale du manteau neigeux.

L'identification des couches de neige est effectuée par observation visuelle des grains de neige à partir de la surface de la carotteuse. Ensuite, chaque couche jugée homogène est soigneusement retirée du carottier afin de caractériser ses propriétés physiques à des fins de classification. Les types des grains et la taille des grains de chaque couche identifiée ont été classés manuellement selon la classification internationale de la neige saisonnière au sol (Fierz *et al.*, 2009). Pour ce faire, la taille et le type de grains de neige ont été identifiés à l'aide d'une carte à grille millimétrique et observés à l'aide d'une loupe grossissant 10 fois. Pour finir, chaque couche homogène a été isolée et pesée pour calculer sa densité.

Pour assurer la cohérence de l'analyse, toutes les observations et les mesures de neige ont été réalisées par le même observateur. La base de données récupérée comportait des mesures collectées de 24 carottes de neige totalisant ainsi 114 échantillons (Tableau 3-3), comprenant plusieurs formes morphologiques (particules de précipitation, particules de précipitation décomposées, fragmentées, grains arrondis, etc.) qui correspondent à la neige faiblement, moyennement, et fortement métamorphosée.

Tableau 3-3 : Distribution de la densité de la neige en fonction du type et de la taille des grains de neige (données de terrain : 2018, 2019 et 2020), avec leurs symbologies correspondantes. (RG) Grains fins ; (FC) Grains à face planes ; (DH) Givre de profondeur (gobelets) ; (MF) Grains ronds (Grains de fonte). Les différentes nuances de gris montrent les niveaux de métamorphose (faible, modéré, élevé) de chaque couche de neige récupérée.

Type des grains	Taille des grains	Nombre d'échantillons	Densité (kg m <sup>-3</sup> )								
			< 100	100 - 150	150 - 200	200 - 250	250 - 300	300 - 350	350 - 400	400 - 450	450 - 500
+ (CNF)	< 1 mm	9									
Λ (PR)	< 1 mm	10									
□ (CFP)	1-2 mm	25									
• (GFS)	1-2 mm	35									
Λ (GP)	> 2 mm	16									
○ (GR, GFE)	> 2 mm	20									

### 3.4 Indices d'évaluation statistiques

La performance des modèles a été évaluée en utilisant la technique de la validation croisée leave-one-out et des données de validation indépendantes. La validation croisée consiste à enlever temporairement une mesure de la densité de la base de données et d'utiliser le reste de la base comme données de calibration, pour ensuite estimer la densité de la mesure enlevée. Cette opération se répète pour l'ensemble de la base de données pour aboutir à une estimation de toutes les mesures

de la densité permettant une comparaison entre valeurs estimées/mesurées via des indices d'évaluation. Pour la présente thèse, quatre indices d'évaluation statistique (le coefficient de détermination ( $R^2$ ), le critère de Nash (NASH), l'erreur quadratique moyenne (EQM) et le Biais (BIAIS)) ont été utilisés dont les formules sont représentées par les équations (3-1 à 3-4). Le critère du NASH évalue la performance des modèles en comparant les valeurs estimées avec la moyenne de celles mesurées. Pour un NASH négatif, il serait préférable d'utiliser la moyenne des valeurs mesurées que celles estimées par le modèle, ce qui est très peu performant. Le modèle commence à être satisfaisant à partir d'un NASH  $\geq$  à 0.8 ; le modèle est parfait pour un NASH=1 (Nash & Sutcliffe, 1970).

$$R^2 = \left[ \frac{\sum_{i=1}^n (M_i - \bar{M})(Es_i - \bar{Es})}{\sqrt{\sum_{i=1}^n (M_i - \bar{M})^2} \sqrt{\sum_{i=1}^n (Es_i - \bar{Es})^2}} \right]^2 \quad (3-1)$$

$$EQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (Es_i - M_i)^2} \quad (3-2)$$

$$BIAIS = \frac{1}{n} \sum_{i=1}^n (Es_i - M_i) \quad (3-3)$$

$$NASH = 1 - \frac{\sum_{i=1}^n (M_i - Es_i)^2}{\sum_{i=1}^n (M_i - \bar{M})^2} \quad (3-4)$$

Où : n est la taille de l'ensemble de données, M et Es sont les valeurs mesurées et estimées, et  $\bar{M}$  et  $\bar{Es}$  sont les moyennes des valeurs mesurées et estimées.

La performance de la classification a aussi été évaluée avec des données ordinales qui ont servi aux calculs des matrices de confusion. Le principe de la matrice de confusion consiste à comparer les classes mesurées (mesures physiques) par rapport aux classes estimées (mesures optiques) et de quantifier la précision de l'approche utilisée via le calcul des taux de succès, des erreurs (commission et omission) et d'indices de précision, notamment l'indice Kappa. Ce dernier permet de quantifier le niveau de concordance entre les classes des caractéristiques physiques mesurées et celles estimées. Pour un Kappa négatif, la concordance est exécrationnelle ; la concordance est bonne pour un Kappa supérieur à 0.6 et elle est excellente à partir de 0.8. Le Tableau 3-4 résume tous les paramètres impliqués dans le calcul de la matrice de confusion et de l'indice Kappa (Cohen, 1960).

Tableau 3-4 : Paramètres utilisés dans la matrice de confusion et pour calculer l'indice de kappa : a et d sont le nombre de valeurs bien classées, b et c sont le nombre de valeurs mal classées, n1, n2, n3, et n4 sont les totaux de a + b, c + d, a + c, et b + d, respectivement, N est la taille de l'échantillon,  $Po = \frac{a+d}{N}$ , et  $PC = \frac{n_1 \times n_3 + n_2 \times n_4}{N^2}$ .

		Valeur mesurée				
		Vrai	Faux	Total	Taux de succès (%)	Erreur d'omission (%)
Valeur estimée	Vrai	a	b	n1	$(a/n1)$	$(b/n1)$
	Faux	c	d	n2	$(b/n2)$	$(c/n2)$
	Total	n3	n4	N		
	Taux de succès (%)	$(a/n3)$	$(d/n4)$			
	Erreur d'omission (%)	$(c/n1)$	$(b/n4)$			
	Succès global (%)					$(a + b)/n1$

## 4 SYNTHÈSE DES TRAVAUX DE RECHERCHE

---

4.1 Objectif 1 : Classification du manteau neigeux saisonnier basée sur les propriétés physiques à l'aide de données hyperspectrales proximales dans le proche infrarouge

### 4.1.1 Introduction

La neige est l'un des composants les plus importants de la cryosphère (Langlois *et al.*, 2010). Elle contribue de manière significative au bilan hydrique, au climat et à l'économie de nombreuses régions géographiques (Gray & Male, 1981; Kinar & Pomeroy, 2015; Marsh, 1991). La couverture neigeuse, également appelée manteau neigeux, est l'ensemble des couches de neige qui s'accumulent sur le sol pendant l'hiver (Fierz *et al.*, 2009). Cette couverture neigeuse est très variable en raison de la distribution complexe des précipitations, du vent et du rayonnement après le dépôt de la neige (Horton & Jamieson, 2017). Chaque couche est séparée de la précédente par un plan de superposition. Cette interface entre deux couches est de granulométrie et de densité inégale, ce qui permet de former un lien fort entre les couches en résistant aux contraintes de cisaillement (Fierz *et al.*, 2009).

Au début de la recherche sur la couverture neigeuse, il était nécessaire de classifier les manteaux neigeux en fonction de leurs propriétés physiques. En effet, la classification des propriétés physiques qui constituent la couverture neigeuse est un objectif louable (Kinar & Pomeroy, 2015). Il faut suivre l'évolution interne du manteau neigeux, d'où la nécessité d'effectuer des observations et des mesures, à fréquence hebdomadaire (Horton & Jamieson, 2017). Les techniques actuelles de classification des propriétés physiques de la neige nécessitent l'utilisation de l'échantillonnage in situ. Néanmoins, ces mesures perturbent le manteau neigeux, et modifient irrévocablement le manteau neigeux par des mesures invasives, et ne peuvent être répétées au même endroit (Vander Jagt *et al.*, 2015). De plus, compte tenu de la sensibilité de la morphologie du grain de neige aux changements de température et d'humidité locales, les mesures sur le terrain contiennent généralement des erreurs importantes (Dominé *et al.*, 2001; Hoff *et al.*, 1998). Par conséquent, il est temps de proposer une technique de classification des propriétés physiques de la neige (taille des grains, type des grains et densité) rapide, objective et non destructive.

L'imagerie hyperspectrale PIR est une technique basée sur l'analyse spectroscopique. C'est une technique rapide, et non destructive qui facilite les mesures en temps réel. Elle a prouvé son efficacité pour les applications de terrain, de laboratoire et industrielles (Chauchard *et al.*, 2004; Osborne, 2006). Pour l'étude de la neige, il a déjà été démontré que le spectre PIR est sensible aux propriétés physiques de la neige (Haq *et al.*, 2019; Kulkarni *et al.*, 2002; Negi *et al.*, 2010a; Nolin & Dozier, 2000). La taille des grains de neige a été corrélée avec la réflectance spectrale de petits échantillons de neige discrets en utilisant la méthode de la sphère intégrante (par exemple DUFISSS (Gallet *et*

*al.*, 2009), IceCube (Zuanon, 2013), et Infrasnöw (Gergely *et al.*, 2013)) ou en utilisant la photographie PIR à haute résolution spectrale (Donahue *et al.*, 2021; Matzl & Schneebeli, 2006). De même, la teneur en eau liquide de la neige a été modélisée sur la base des propriétés de la réflexion de la neige. Les résultats montrent que la teneur en eau liquide est inversement corrélée à la réflectivité PIR (Eppanapelli *et al.*, 2018b; Negi *et al.*, 2010a). En outre, Bohren and Beschta (1979) trouvent que la corrélation entre la réflectance spectrale et la densité de la neige est probablement le résultat d'autres changements qui se produisent dans le processus de vieillissement. Ils concluent qu'il existe une relation entre ce paramètre et la réflectance. La plupart des études précédentes se sont concentrées sur la relation entre une seule propriété physique de la neige (densité, taille des grains ou teneur en eau liquide) et la réflectance. La modélisation de leur effet combiné basée sur la réflectance n'est pas encore connue.

Le premier objectif de cette partie de la thèse était d'étudier le potentiel de l'imagerie hyperspectrale dans la région spectrale du PIR (900 à 1700 nm) pour la classification des couches homogènes du profil vertical des manteaux neigeux en termes de densité, taille des grains et type des grains de neige. Pour fins d'évaluation, un exercice de comparaison des données de terrain et des données spectrales correspondantes a été effectué.

#### 4.1.2 Approche méthodologique

Comme décrit dans le chapitre 2, la réflectance spectrale de la neige dépend des propriétés physiques de la neige dans la partie PIR du spectre. Dans les travaux de Negi *et al.* (2010a), ils démontrent qu'en raison du vieillissement et de la variation des propriétés physiques de la neige, les variations maximales de la réflectance spectrale sont observées dans la région PIR. Le processus naturel de vieillissement de la neige peut considérablement transformer la taille des grains, le type des grains et la densité du manteau neigeux (Colbeck, 1982). Au vu des résultats expérimentaux de Domine *et al.*, 2006; Eppanapelli *et al.*, 2018b; Horton & Jamieson, 2017 et Negi *et al.*, 2010a, il semble donc possible de classer les réflectances spectrales PIR issues des couches homogènes de la stratigraphie verticale du manteau neigeux en différents groupes ou classes de neige en fonction de l'évolution du processus de vieillissement du manteau neigeux. La stratégie d'échantillonnage utilisée ainsi que les bases théoriques de l'analyse de classification sont présentées en détail sur trois étapes :

- Mesures in situ hebdomadaires de la neige

Deux types de données ont été collectés : les propriétés physiques du manteau neigeux et ses propriétés optiques. Pour mener à bien cette étape, deux instruments sont utilisés :



1) Une carotteuse d'échantillonnage de neige rectangulaire portative. Cette carotteuse est utilisée pour extraire le profil vertical du manteau neigeux, afin de permettre un échantillonnage des propriétés physiques (la densité, les tailles des grains et les types des grains) et optiques (réflectance spectrale) de la neige. La conception générale ainsi que la méthode d'utilisation de la carotteuse sont expliquées dans le chapitre 3 (cf. section 3.2).

2) Une caméra hyperspectrale PIKA NIR de la compagnie RESONON, mesure la réflectance spectrale dans les bandes des longueurs d'onde PIR (900 à 1700 nm) à une résolution spectrale élevée de 5 nm.

Une fois que le profil de neige est récupéré (Figure 3-4), la carotteuse est placée horizontalement pour être scannée par la caméra hyperspectrale (Figure 3-5). Un laboratoire mobile utilisé pour recueillir les données physiques et optiques de la neige était situé près du site d'échantillonnage et le même degré de température extérieure a été maintenu dans le labo ce qui nous permet de recueillir les données physiques et optiques en 10 minutes environ. Les couches de neige ont été identifiées visuellement en observant les changements de taille et de type de grains à la surface de la carotteuse. Pour chaque couche identifiée, le type et la taille des grains de neige ont été mesurés et classés manuellement selon la classification internationale de la neige saisonnière au sol (Fierz *et al.*, 2009). La densité de chaque couche a été calculée en utilisant sa masse et son volume par rapport à la surface de l'échantillonneur de carottes. Une base de données de 114 couches a été établie (cf. Tableau 3-3). Pour toutes les acquisitions, les mêmes appareillages et techniques d'échantillonnage ont été utilisés tout au long de cette étude.

#### ➤ Analyse statistique des données in-situ

Dans le but de la réduction de la dimensionnalité spectrale, une analyse en composantes principales (ACP) a été appliquée aux données hyperspectrales PIR complètes pour déterminer la plage spectrale à exploiter dans la classification. Afin d'assurer une augmentation significative de la précision de la classification. Pour ce faire, les coefficients des composantes principales, également connus sous le nom des charges ont été étudiés pour leur utilité dans la réduction de la dimensionnalité des données hyperspectrales en se basant sur les coefficients les plus élevés. De plus amples détails sont disponibles dans le paragraphe 2.2.1 de l'article 1.

Par la suite, une classification non supervisée appelée classification ascendante hiérarchique (CAH) a été exécutée aux données spectrales PIR pour sélectionner le nombre des classes. Avec cette méthode de classification, on cherche à avoir des classes en supposant l'existence de ressemblances plus ou moins grandes entre les différents individus et en utilisant seulement les mesures hyperspectrales, et sans une reconnaissance préalable. Le spectre est donc utilisé pour classer les

échantillons de neige selon leurs similarités et ainsi obtenir des classes de neige homogènes (faiblement métamorphosée, modérément métamorphosée, et fortement métamorphosée).

➤ Évaluation des résultats

Une matrice de confusion a été utilisée afin d'évaluer la précision de la classification. L'objectif est de comparer les classes mesurées (mesures physiques) par rapport aux classes estimées (mesures optiques) et de quantifier la précision de l'approche utilisée via le calcul des taux de succès, des erreurs (commission et omission) et d'indices de précision, notamment l'indice Kappa.

#### 4.1.3 Résultats et discussion

Les premiers résultats obtenus montrent que les réflectances spectrales changent le long du spectre électromagnétique au fur et à mesure que la neige vieillit. En effet, les échantillons de neige nouvellement déposés sur le manteau neigeux (CNF et PR) et qui ont une densité faible à moyenne (entre 50-200 kg m<sup>-3</sup>) ont les valeurs de réflectance plus élevées. En revanche, les échantillons de neige métamorphosée (GP et GFE) ont des valeurs de réflectance plus faibles et les échantillons de neige de très forte densité (400-600 kg m<sup>-3</sup>). Les échantillons de densité moyenne à forte (150-450 kg m<sup>-3</sup>) et moyennement métamorphosés (GFS et CFP) ont des valeurs de réflectance intermédiaires (cf. Figure 1-10 de l'article 1).

Une ACP a été réalisée sur toutes les données spectrales, afin de réduire l'information enregistrée par les 148 bandes spectrales en deux composantes et pouvoir les projeter sur un diagramme de score 2D. Les deux premières composantes principales (CP) obtenues ont été utilisées pour générer un diagramme de score, car elles représentaient plus de 96% de la variance des données spectrales (Figure 4-1). Les résultats du diagramme de score permettent la distinction des classes de neige homogène en termes de densité, de type et de taille des grains. En effet, l'obtention de ces classes peut être expliquée par des phénomènes physiques affectant le manteau neigeux (le métamorphisme de la neige), influençant majoritairement la réponse spectrale de la neige. Le diagramme de score a donc l'avantage d'afficher des informations sur les regroupements d'échantillons en fonction de leurs caractéristiques physiques et du degré de transformation ou de métamorphose subi. Les différences entre la plupart des classes sont prononcées et certains types de neige sont mélangés, comme les grains arrondis et les grains à facettes, qui ne sont pas clairement séparés. Cela pourrait être lié à une taille ou une forme de grain similaire. Six groupes de neige peuvent être distingués (les points colorés dans la Figure 4-1). Aucun des groupes de neige ne peut être considéré comme atypique ou aberrant.

D'après les résultats de l'ACP (Figure 4-1), il a été constaté que les valeurs de réflectance spectrale peuvent être regroupées de préférence en trois groupes distincts en fonction de leurs propriétés

spectrales qui reflètent leurs compositions physiques. La coupure (lignes en gras) a été établie entre la neige faiblement métamorphosée (CNF et PR), la neige modérément métamorphosée (CFP et CFS) et la neige fortement métamorphosée (GP, GR et GFE) (Figure 4-1). Certes, quelques erreurs de classification subsistent entre les spectres de certaines classes, mais elles restent limitées. Par la suite, afin d'effectuer la réduction des dimensionnalités spectrales, les coefficients (Coeff) de la première composante principale ont été utilisés pour réduire le nombre de bandes spectrales (148 bandes spectrales) sur lesquelles le modèle de classification non supervisée (CAH) était basé. Seules les bandes dont le coefficient était supérieur à 0.085 ont été conservées (ligne rouge de 900 à 1400 nm (cf. Figure 1-12 de l'article 1)).

La CAH est réalisée en utilisant toutes les longueurs d'onde constituant le domaine spectral de 900 à 1400 nm afin de concentrer la classification uniquement sur les bandes les plus sensibles aux changements de taille et de type de grains de neige subis par les différents types de métamorphisme. La Figure 4-2 montre les spectres de réflectance d'échantillons de neige avec différentes gammes de taille de grain et de densité après la CAH. Le résultat de la CAH a conduit à une bonne différenciation des classes de manteau neigeux basée uniquement sur les données optiques. La méthode de classification utilisée est basée sur l'évolution continue des caractéristiques physiques de la neige, donc sur les conséquences de certains processus de métamorphose (destructeurs ou constructifs) (Pahaut, 1975), qui mettent davantage l'accent sur les causes qui provoquent ces différentes formes de grains (métamorphoses de gradients ou d'isothermes). Les grains de neige évoluent après avoir été déposés et les cristaux de neige passent de leur forme initiale (neige fraîche ou récente) à des formes granulaires (neige évoluée ou vieille neige). Cette séquence de transformation et de métamorphose continue jusqu'à ce que la neige disparaisse lors de la fonte.

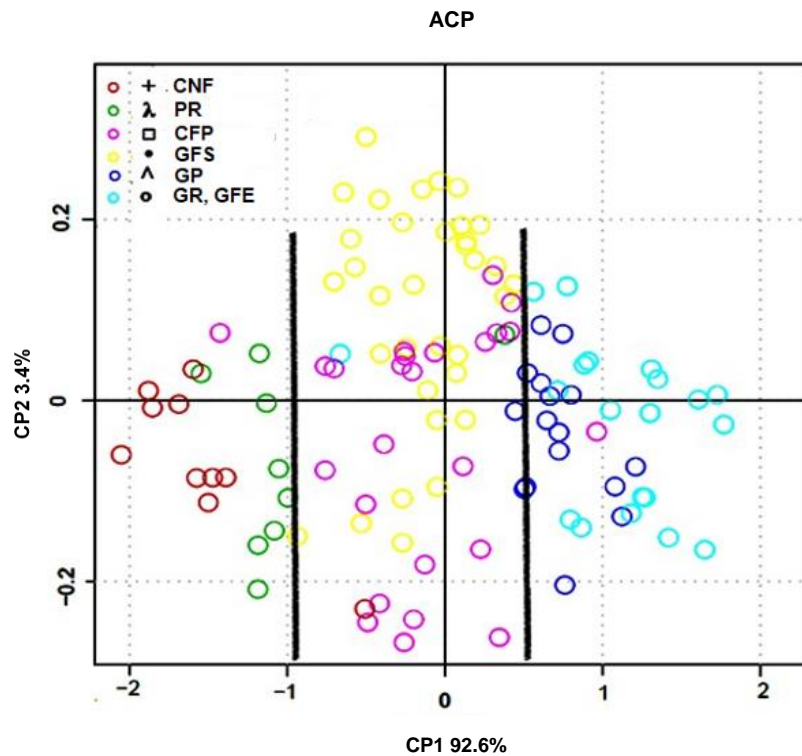


Figure 4-1 : Graphique de score pour la CP1 et la CP2 des valeurs de réflectance spectrale. Les lignes de séparation en gras permettent de distinguer visuellement les classes de neige en termes de degré de métamorphose (neige faiblement, modérément et fortement métamorphosée).

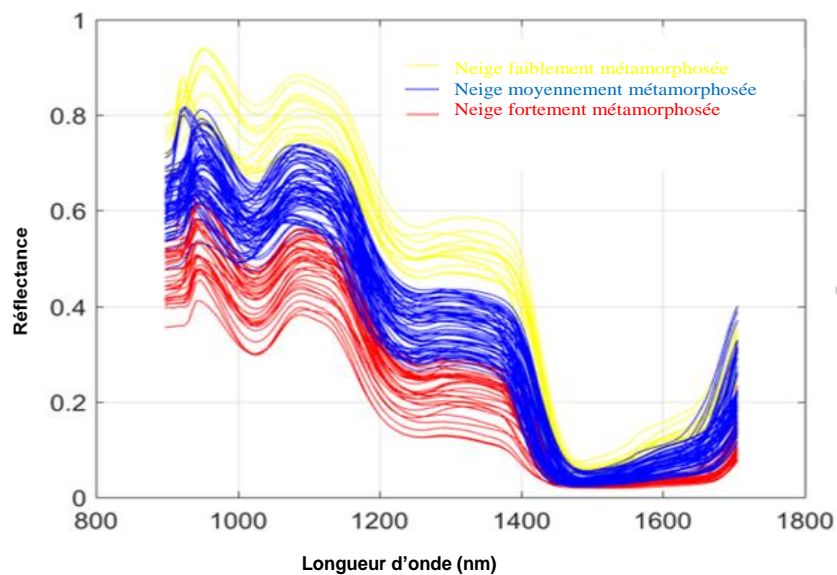


Figure 4-2 : Les valeurs de réflectance spectrale dans le PIR des trois classes de neige.

Les performances de classification sont évaluées à l'aide d'une matrice de confusion basée sur les données de terrain et les données optiques correspondantes. Le Table 1-4 de l'article 1 présente les résultats de la matrice de confusion pour les classes de neige. Les performances de la classification ont été très acceptables (indice de kappa = 0,75 et succès global = 0,85%).

#### 4.1.4 Conclusions

Le premier objectif de la thèse était de tester le potentiel de l'imagerie hyperspectrale PIR à distinguer et classer les couches du profil vertical du manteau neigeux saisonnier en fonction de leurs propriétés physiques (type et taille des grains, densité). Une analyse de classification non supervisée (CAH) a été réalisée sur la base des spectres de réflectance des différentes variétés de neige. Avec un succès global de 85%, la matrice de confusion a indiqué une performance acceptable de la classification des données, ce qui indique le potentiel de l'imagerie hyperspectrale PIR à sélectionner efficacement les classes de neige en fonction de leurs données spectrales.

Les techniques d'analyse statistique multivariée telles que l'ACP et la CAH ont l'avantage d'être des techniques objectives, rapides et non destructives pour l'identification et la classification de la neige au sol. Nous recommandons de tester cette méthode sur une grande variété de sites présentant un large éventail de manteaux neigeux (basse vs haute altitude, environnements fermés et ouverts, conditions côtières vs continentales, etc.) afin de valider davantage sa robustesse et si nécessaire de l'étalonner à nouveau en utilisant des observations supplémentaires pour une meilleure précision.

## 4.2 Objectif 2 : Modèle hybride d'estimation de la densité du manteau neigeux à partir de la réflectance spectrale proche infrarouge

### 4.2.1 Introduction

La technologie d'imagerie hyperspectrale est de plus en plus utilisée dans l'estimation des paramètres physiques de la neige. Elle est rapide, non invasive et facilite les mesures en temps réel (Chauchard *et al.*, 2004; Osborne, 2006), permettant d'être utilisée conjointement avec les méthodes de mesure traditionnelles. Cette technologie s'est avérée efficace pour des applications sur le terrain, en laboratoire et dans l'industrie (Lu & Fei, 2014). Elle fournit des informations détaillées sur les composants physiques et chimiques d'un échantillon scanné grâce à sa haute résolution spectrale et temporelle (Lorente *et al.*, 2012; Lu & Fei, 2014). D'ailleurs, des études ont démontré que le spectre PIR est sensible aux propriétés physiques de la neige (taille des grains, type des grains, et teneur en eau liquide) (Haq *et al.*, 2019; Negi *et al.*, 2010b) et des travaux ont déjà porté sur le développement de modèles permettant d'estimer les propriétés physiques de la neige dans cette gamme spectrale avec pour objectif ultime de quantifier la densité de la neige étant donné son importance à plusieurs niveaux (économique, environnemental, social, etc.).

Les études antérieures d'estimation de la densité supposent qu'il est possible de la modéliser à l'aide de la même fonction (Domine *et al.*, 2007; Li *et al.*, 2016). En effet, même si la réflectance spectrale PIR de la neige dépende de la densité, elle est également influencée par la taille des grains, le type de grain et la teneur en eau liquide de la neige (Bohren & Beschta, 1979). Par conséquent, les propriétés optiques et les propriétés physiques de la neige s'influencent mutuellement et créent une relation non-bijective (surjective) entre la densité de la neige et la réflectance PIR, ce qui entraîne de faibles corrélations. Au premier objectif, il a été démontré que trois classes optiques de neige avec différents degrés de métamorphose (faiblement à modérément métamorphosée (FMM), modérément à fortement métamorphosée (MFM) et fortement à très fortement métamorphosée (FFM)) peuvent être identifiées et discriminées sans reconnaissance préalable, basée uniquement sur les données hyperspectrales PIR (El Oufir *et al.*, 2021). Grâce à ces résultats, il est possible de former des estimateurs spécifiques aux classes homogènes identifiées, qui sont régies par une relation bijective entre la densité et la réflectance hyperspectrale PIR.

Ainsi, il a été question de développer un modèle hybride (MH) permettant d'estimer la densité qui se compose d'un classificateur et de trois estimateurs spécifiques (ES) correspondants à trois classes de neige (FMM, MFM et FFM) en utilisant l'imagerie hyperspectrale PIR. Le modèle a été calibré avec 75% des données collectées et validé avec les 25% restants. La performance du MH a été évaluée en utilisant la technique de validation croisée (leave-one-out cross-validation) et des données de validation indépendantes (25%).

#### 4.2.2 Approche méthodologique

L'analyse du comportement spectral des couches homogènes du profil vertical de la couverture neigeuse saisonnière a montré qu'elles ont un aspect spectral typique dans la partie PIR du spectre électromagnétique. En effet, chaque couche de neige qui constitue la stratigraphie verticale du manteau neigeux correspond à un stade de maturation ou de transformation. De ce fait, il a été décidé d'utiliser cette information afin de développer trois ES correspondant à trois différentes classes de neige (FMM, MFM et FFM) (El Oufir *et al.*, 2021). D'autre part, il a été démontré que les modèles calibrés par régression multiple améliorent significativement la qualité des estimations (Hodjaty *et al.*, 2010). Ainsi, l'utilisation structurée des ES calibrés par régression multiple devrait permettre d'atteindre une meilleure modélisation de la densité de la neige. La calibration des ES a été effectuée par la régression pas-à-pas (stepwise) en utilisant les différents rapports et différences de bandes (susceptibles de rehausser l'information physico-optique de la densité).

Avant de procéder à la classification, une classification visuelle des mesures in situ de la neige selon trois classes (FMM, MFM et FFM) définies ci-dessus a été effectuée. La Figure 4-3 présente les résultats de la classification visuelle des mesures in situ. On peut constater que la forme de la courbe de la réflectance spectrale de la neige change en fonction des caractéristiques physiques de la neige (densité, taille des grains et type des grains) dont les dimensions de ces caractéristiques dépendent de son état métamorphique. Toutefois, la séparation spectrale entre la neige faiblement, moyennement et fortement métamorphosée n'est, toutefois, pas une tâche facile. La méthode CART (Classification and Regression Tree (Leo. Breiman, 1984)), largement utilisée dans le domaine de classification de données a été appliquée à cette fin.

Les résultats de la méthode CART sont représentés sous la forme d'une illustration intuitive (Figure 4-4). Deux longueurs d'onde (1024 et 1161 nm) ont été les meilleures variables de discrimination. La variable 1024 nm permet de différencier la classe de neige fortement métamorphosée (composée de grains de neige de taille  $> 2\text{mm}$ ) des deux autres classes de neige faiblement et modérément métamorphosée (composée de grains de neige d'une taille comprise entre 1 et 2 mm) et, la longueur d'onde 1161 nm permet de discriminer la neige modérément et faiblement métamorphosée (composée de grains de neige de taille  $< 1\text{ mm}$ ).

Le classificateur développé par CART a permis ensuite de subdiviser spectralement la base de calibration en trois sous-groupes spécifiques, permettant alors la calibration de trois ES (Figure 4-5). Ainsi l'estimation de la densité de la neige pour un échantillon donné via cette approche s'effectue sur deux étapes : 1) la détermination a priori de la classe de neige à modéliser via le classificateur et 2) l'estimation de la densité de la neige par l'intermédiaire de l'ES de la classe de neige prédéterminée (Figure 4-3). D'où l'appellation MH.

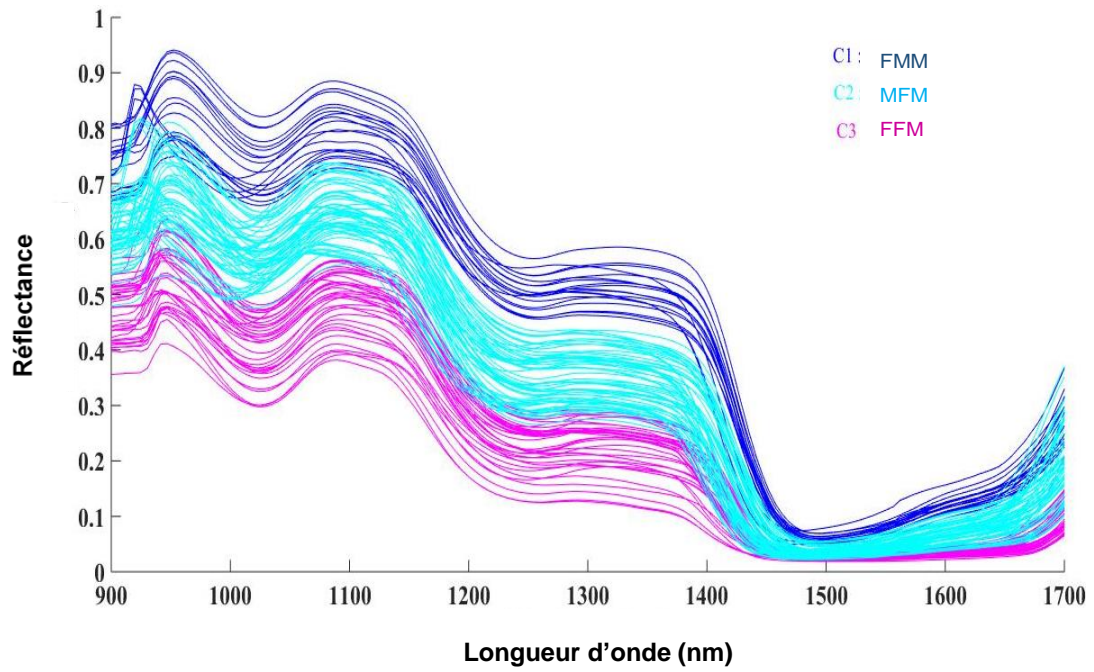


Figure 4-3 : Les réflectances spectrales PIR des trois classes de neige.

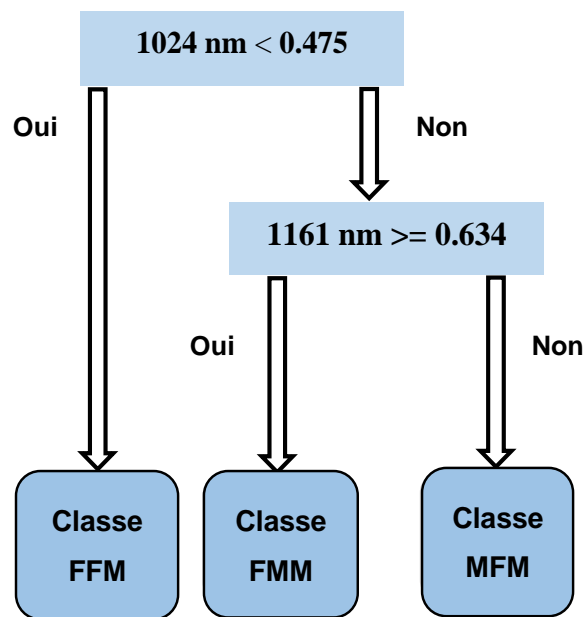


Figure 4-4 : Seuils utilisés pour distinguer les trois classes de neige à l'aide de la méthode CART.






Figure 4-5 : Résultats de la subdivision de la base de calibration en trois sous-groupes spécifiques. 1) le sous-groupe de données qui a été utilisé pour calibrer l'estimateur spécifique de la classe de neige FMM, 2) le sous-groupe de données qui a été utilisé pour calibrer l'estimateur spécifique de la classe de neige MFM, 3) le sous-groupe de données qui a été utilisé pour calibrer l'estimateur spécifique de la classe de neige FFM.

#### 4.2.3 Résultats et discussion

##### ➤ Dépendance statistique entre la densité et la réflectance spectrale

Des travaux antérieurs n'ont pas permis d'établir une forte corrélation entre la densité de la neige et la réflectance spectrale, que ce soit dans la partie visible (VIS) (Li *et al.*, 2016; Ling & Zhang, 2004) ou le PIR du spectre optique (Domine *et al.*, 2007; Li *et al.*, 2016; Ling & Zhang, 2004). Les mêmes faibles corrélations ont également été retrouvées dans cette étude lorsqu'il a été question de procéder par les méthodes usuelles ; corréler toutes les densités collectées avec la réflectance hyperspectrale. Ceci a été testé en corrélant bande par bande ou en corrélant des indices spectraux (rapport et différence normalisée et soustraction de bandes) avec la densité. (cf. Figures 8a, 8b, 8c, et 8d de l'article 2). La précision a augmenté un peu comparée à l'utilisation de bande par bande, mais elle est toutefois insatisfaisante tant au cours de la calibration ( $R_{\max}^2 = 0.64$ , Figure 4-6.a) qu'au cours de la validation par les données indépendantes (Figure 4-6.b).

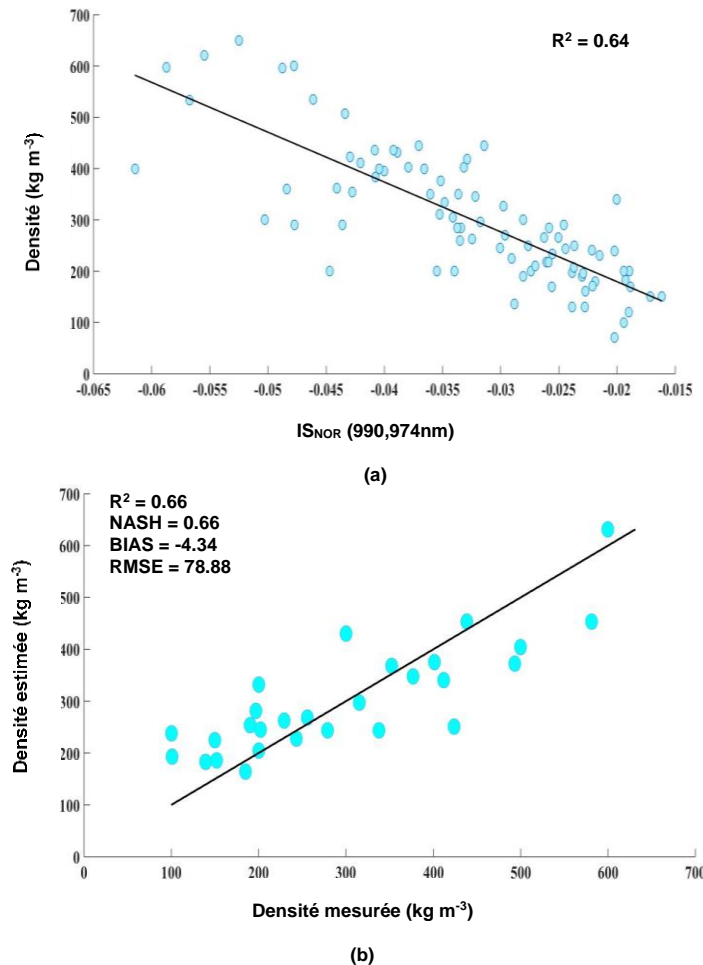


Figure 4-6 : (a) Résultat de calibration en utilisant des différences de bande normalisées (75% de la base de données); (b) Résultats de la validation par données indépendantes (25% de la base de données).

#### ➤ Le modèle hybride

Comme prévu, la corrélation entre la densité de la neige et la réflectance spectrale était plus élevée lorsque chaque classe était considérée séparément. Ces résultats soutiennent l'hypothèse selon laquelle la destruction de la relation surjective pourrait conduire à la création d'une relation bijective par classe et, par conséquent, à améliorer la précision de la modélisation de la densité de neige. Les trois classes de neige étaient corrélées linéairement et la fonction d'étalonnage était univariée (Tableau 4-1). L'indice spectral retenu pour la classe FMM était la différence entre les longueurs d'onde de 1265 et 941 nm avec un  $R^2$  de 0,91 (appelée ici indice spectral  $IS_{DIF}$ ). L'indice spectral retenu pour la classe MFM était la différence normalisée entre les longueurs d'onde de 1617 et 941 nm (appelée ici  $IS_{NOR}$ ) avec un  $R^2$  de 0,80. Et, l'indice spectral retenu pour la classe FFM était également la différence entre les longueurs d'onde de 1424 et 1188 nm ( $IS_{DIF}$ ) avec un  $R^2$  de 0,84. La forte corrélation obtenue illustre l'importance de diviser les données d'entrée en trois classes de neige, en fonction d'un certain degré de vieillissement. Pour les trois ES, l'estimation de la densité de

la neige a été limitée aux courtes et grandes longueurs d'onde du spectre PIR, qui sont les régions spectrales les plus sensibles à l'activité des propriétés physiques de la neige.

Tableau 4-1 : Equations des trois modèles calibrés (estimateurs spécifiques) utilisant la régression multivariée pas à pas pour estimer la densité de la neige.

Classe de neige	Estimateurs spécifiques
FMM	Densité = $-1035 * IS_{DIF} (1265 \text{ nm}, 941 \text{ nm}) - 148$
MFM	Densité = $-1377 * IS_{NOR} (1617 \text{ nm}, 941 \text{ nm}) - 838$
FFM	Densité = $2357 * SI_{DIF} (1424 \text{ nm}, 1188 \text{ nm}) + 1002$

La validation par les données indépendantes a démontré la bonne performance du MH ( $R^2 = 0.88$ , NASH = 0.88 et EQM =  $46,79 \text{ kg m}^{-3}$  (Figure 4-7)). La Figure 4-7 montre également la bonne dispersion du nuage de points par rapport à la ligne 1:1, des valeurs de densité très faibles aux valeurs élevées. Comme le montrent ces résultats, l'évaluation du MH est satisfaisante, avec un jeu de données indépendant, couvrant une période de trois hivers. Contrairement aux études précédentes qui prétendaient qu'il n'y avait pas de forte corrélation entre la réflectance spectrale et la densité de la neige, cette étude a montré qu'il est possible d'obtenir une haute performance des estimations de la neige si l'on trouve la bonne stratégie de modélisation.

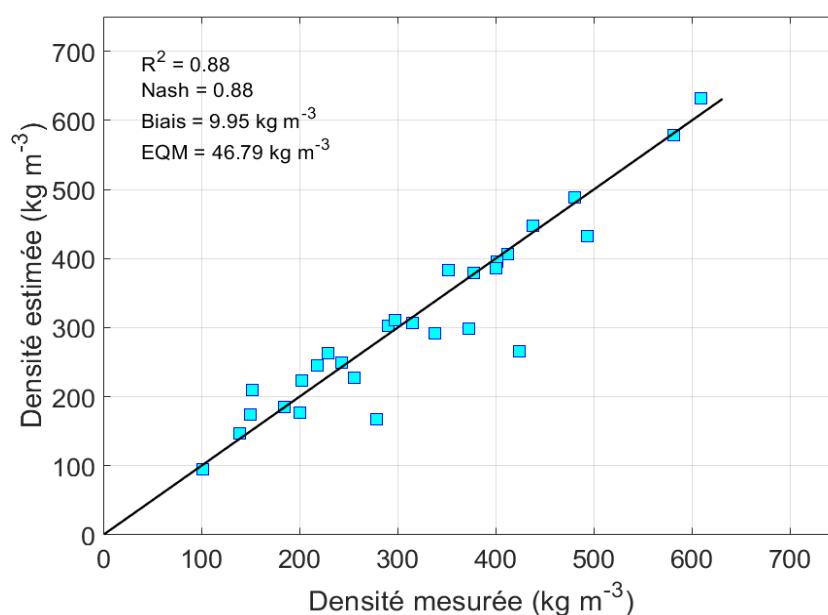


Figure 4-7 : Évaluation du MH à l'aide des données indépendantes.

**NB : Il est important à préciser qu'une erreur de calcul des Indices d'évaluation statistiques ( $R^2$ , NASH, BIAS et EQM) s'était glissée au moment de la présentation des résultats du deuxième article. Ceci n'a pas influencé sur les conclusions générales des travaux de cette partie de la thèse. Cette erreur a été corrigée pour la présente synthèse. De ce fait, les valeurs des Indices d'évaluation statistiques présentées dans cette section diffèrent de celles présentées dans l'article #2 (El-Oufir et al., 2021).**

#### 4.2.4 Conclusions

Le MH développé dans cette recherche est une combinaison d'un classificateur et de trois ES correspondant à trois classes de neige (FMM, MFM et FFM). En comparant les dépendances statistiques entre la densité et la réflectance spectrale, l'évaluation du MH par validation indépendante a montré des résultats satisfaisants avec un  $R^2 = 0.88$ , Nash = 0.88, EQM =  $46.79 \text{ kg m}^{-3}$  et un BIAIS de  $9.95 \text{ kg m}^{-3}$ .

L'étape critique dans l'estimation de la densité de la neige à l'aide du MH est la sélection de l'estimateur final. Une mauvaise sélection d'un échantillon donné, suite à une mauvaise classification d'un échantillon donné, pourrait conduire à une sur- ou sous-estimation de la densité. Cet inconvénient peut affecter de manière significative la précision de l'estimation de la densité à l'aide du MH. Par exemple, pour une densité mesurée de  $581 \text{ kg m}^{-3}$  (classée comme FFM), les erreurs relatives varient de 5%, 39% et 75% lorsqu'elles sont estimées en utilisant les estimateurs spécifiques de FFM, MFM et FMM, respectivement. D'autre part, un autre obstacle associé à cette méthode est la sélection correcte des couches de neige homogènes sur le terrain et sur l'image hyperspectrale récupérée. Pour cette raison, des campagnes de terrain supplémentaires doivent être menées pour collecter plus de données afin de surmonter cette faiblesse et permettre une mise en œuvre adéquate sur le terrain. Nous concluons que nos résultats constituent un premier pas important vers une solution permettant de mesurer et de surveiller les profils de densité de la neige sur le terrain.

### 4.3 Objectif 3 : Systèmes basés sur les méthodes d'ensembles pour estimation de la densité du manteau neigeux à partir de la réflectance spectrale proche infrarouge

#### 4.3.1 Introduction

L'étape déterminante lors de l'estimation de la densité de neige à l'aide du MH (El Oufir *et al.*, 2021) est la sélection de l'estimateur final. Une mauvaise sélection de ce dernier, suite à une mauvaise classification d'un échantillon donné, pourrait conduire à une sur- ou sous-estimation de la densité. En effet, plusieurs études ont démontré l'instabilité et la localisation des techniques de classification basées sur des décisions arborescentes (Timofeev, 2004), telles qu'utilisées pour calibrer le classificateur du MH. D'autre part, l'estimation finale de la densité avec le MH est basée sur la décision d'un seul des trois estimateurs. Cependant, dans des conditions de modélisation aussi complexes, il est souvent recommandé de s'appuyer sur plusieurs décisions avant de prendre la dernière. La combinaison de toutes ces décisions serait alors la plus précise. Cette technique connue sous le nom des méthodes d'ensemble est utilisable dans les deux contextes, classification et/ou estimation, et peut être considérée comme la « révolution » de la modélisation moderne par apprentissage automatique, connu également sous le nom anglais «machine learning».

Un des principaux éléments clés du développement d'un modèle basé sur les méthodes d'ensemble (MBME) est la diversité de ses éléments (estimateurs et/ou classificateurs (Polikar, 2006)). Une des méthodes les plus simples et les plus intuitives souvent utilisées pour développer un MBME est le bagging (Breiman, 1996). La diversité dans le bagging est obtenue en utilisant un rééchantillonnage avec remplacement sur les données de calibration. Cependant, la principale faiblesse du bagging est le temps de calcul dû au nombre souvent trop élevé d'éléments du MBME. L'utilisation de la formule de la quadrature gaussienne (QG) serait une bonne solution à ce problème. Cette méthode a le potentiel de convertir le problème de rééchantillonnage illustré mathématiquement sous forme d'intégration, qui est exigeant et complexe sur le plan informatique, en un problème de sommation de probabilités pondérées pour lequel les techniques de solution numérique sont plus simples, éprouvées et précises (Tørvi & Hertzberg, 1997).

Ainsi, notre troisième objectif de la thèse était d'optimiser les performances du MH en développant un MBME permettant d'estimer la densité saisonnière du manteau neigeux. Pour évaluer le MBME, un test de robustesse par la méthode de k-fold cross-validation sur 1K itération a été appliqué et sur le MH et sur le MBME. L'évaluation de la robustesse a été basé sur la variance des indices d'évaluation statistiques (NASH et EQM) ;

### 4.3.2 Approche méthodologique

Afin d'obtenir des estimations optimales de densité à l'aide du MH, les sources d'erreurs de classification et d'estimation doivent être contrôlées. Pour ce faire, nous avons développé un MBME mixte composé à la fois de classificateurs et d'estimateurs basés sur des ensembles.

#### ➤ Classificateurs basés sur les ensembles

Cette source d'erreur est liée aux nœuds du classificateur du MH (lignes grises de la Figure 4-5). Les seuils proposés par la méthode CART sont en effet optimaux pour la base d'apprentissage utilisée, mais pas uniques (El Oufir *et al.*, 2021). Un simple changement de la base d'apprentissage peut entraîner des changements considérables dans l'arbre de décision. Une manière intéressante de contrôler cette erreur serait de la quantifier pour la prendre en compte lors de l'estimation finale de la densité. La quantification de l'erreur du classificateur du MH a été possible en utilisant l'algorithme du bagging (rééchantillonnage par remplacement ;  $n_{\text{bag}}$  a été fixé à 25 000 pour cette étude) (Breiman, 1996). Cela a permis de générer deux vecteurs aléatoires ( $v_1$ ) et ( $v_2$ ) composés de milliers de seuils. L'occurrence des seuils dans les vecteurs aléatoires a permis de déterminer une distribution de probabilité de seuil pour chacune des variables de discrimination dans le classificateur du MH. Cette probabilité est caractérisée par une moyenne ( $\mu$ ) et une variance ( $\sigma$ ). Ces deux moments statistiques sont par la suite utilisés pour développer le classificateur d'ensemble composé d'un seuil nominal (N), d'un seuil minimum (L) et d'un seuil maximum (U). Sur la base de ces moments statistiques, il a été possible de quantifier l'incertitude de classification par les équations suivantes :

$$\text{Moyenne } \mu_{f(v)} = \int_V f(v) \cdot P(v) dv \quad (4.1)$$

$$\text{Variance } \sigma_{f(v)} = \int_V (f(v) - \mu)^2 \cdot P(v) dv \quad (4.2)$$

Où  $v$  est le vecteur aléatoire appartenant à  $V$ , qui représente l'espace des variables d'entrée du modèle,  $f(v)$  est la sortie du modèle et  $P(v)$  est la distribution conditionnelle des variables d'entrée.

La prise en compte de ce grand nombre de classificateurs, afin de prendre une décision, nécessitera certainement un temps de calcul énorme. Tørvi and Hertzberg (1997) ont proposé une approche basée sur la formule de la quadrature gaussienne (QG), qui peut potentiellement convertir ces intégrales probabilistes (équations (4-1) et (4-2)) à des sommations pondérées qui sont en fonction de  $n$ -nœuds ( $n$ -seuils optimaux ( $n_{\text{so}}$ ), qui a été fixé à 3 pour cette étude). Le Tableau 4-2 résume les abscisses et les poids liés à chaque SO tels que proposés dans les travaux de Tørvi and Hertzberg (1997), où les détails mathématiques de la démonstration de la FQG et de sa validation peuvent également être trouvés. Ainsi, les équations (4-1) et (4-2) prennent les formules suivantes :

$$\text{Moyenne } \mu = \sum_{i=1}^{n_{so}} \omega_i \times f(z_i) \quad (4.3)$$

$$\text{Variance } \sigma = \sum_{i=1}^{n_{so}} \omega_i \times f(z_i - \mu)^2 \quad (4.4)$$

$$SO_i = \mu + \sqrt{\sigma} \times Z_i \quad (4.5)$$

Où  $\mu$  et  $\sigma$  sont respectivement la moyenne et la variance empiriques du vecteur aléatoire standardisé  $f(z)$ .  $Z_i$  et  $\omega_i$  sont respectivement l'abscisse et le poids liés à chaque seuil optimal ( $SO_i$  ;  $i = 1:n_{so}$ ),  $n_{so} = 3$ .

Tableau 4-2 : Abscisses et poids de la distribution normal standard.

Seuils optimaux (SO)	Abscisses ( $Z_i$ )	Poids( $\omega_i$ )
1	0	1
2	-1, +1	$\frac{1}{2}, \frac{1}{2}$
3	$-\sqrt{3}, 0, +\sqrt{3}$	$\frac{1}{6}, \frac{2}{3}, \frac{1}{6}$

➤ Estimateurs basés sur les ensembles

En raison de la complexité du phénomène à modéliser, la moyenne de plusieurs estimations de densité réduit le risque d'utiliser une seule fonction d'estimation. En se basant sur ce principe, et sur les résultats du classificateur d'ensemble, il a été possible de développer un estimateur d'ensemble. En effet, à l'aide des différents seuils calculés, il est possible de diviser la base de données de calibration en plusieurs sous-bases, permettant la calibration de 15 estimateurs spécifiques. Trois (3) sous-groupes de la classe de neige FMM, qui sont composés d'échantillons supérieurs à SOV1L, SOV1N, SOV1U, neuf (9) sous-groupes de la classe de neige MFM, qui sont composés d'échantillons inférieurs à SOV1L, SOV1N, et SOV1U et supérieurs à SOV2L, SOV2N, et SOV2U, et trois (3) sous-groupes de la classe de neige FFM, qui sont composés d'échantillons inférieurs à SOV2L, SOV2N, et SOV2U (Figure 4-8). Par régression pas-à-pas (stepwise) et en utilisant l'ensemble des variables utilisées pour calibrer le MH, il a donc été possible de calibrer 15 estimateurs spécifiques. Cette étape marque le développement de l'estimateur d'ensemble. En utilisant ce schéma (4-3) et (4-4) prennent la forme suivante :

$$\mu = \sum_{i=1}^P \omega_i \times \text{Est}_{SOV1_i^\uparrow} + \sum_{i=1}^{n_{so}-P} \omega_i \times \left[ \sum_{j=0}^k \omega_i \times \left[ \text{Est}_{SOV1_i^\uparrow, SOV2_j^\uparrow} \right] + \sum_{j=0}^k \omega_i \times \left[ \text{Est}_{SOV2_j^\uparrow, SOV1_i^\uparrow} \right] \right]; j = 0 \quad (4.6)$$

pour  $k = 0$

$$\sigma = \sum_{i=1}^P [\omega_i \times \text{Est}_{SOV1_i^\uparrow} - \mu]^2 + \sum_{i=1}^{n_{so}-P} \omega_i \times \left[ \sum_{j=0}^k \omega_i \times \left[ \text{Est}_{SOV1_i^\uparrow, SOV2_j^\uparrow} - \mu \right]^2 + \sum_{j=0}^k \omega_i \times \left[ \text{Est}_{SOV2_j^\uparrow, SOV1_i^\uparrow} - \mu \right]^2 \right]; j = 0 \text{ pour } k = 0 \quad (4.7)$$

Où  $i$  et  $j$  sont, respectivement, les indices correspondants à un SOV1 et SOV2 particuliers ( $i = 1: n_{SO}$  et  $j = 1: n_{SO}$  et où 1 se réfère à minimal (L), 2 se réfère à nominal (N), et 3 se réfère au seuil maximal (U); Figure 4-8;  $\omega_i$  et  $\omega_j$  sont les poids associés à chaque seuil optimal particulier pour V1 et V2 ( $\omega_1 = \omega_3 = \frac{1}{6}$  et  $\omega_2 = \frac{2}{3}$ ; Tableau 4-2); V1 et V2 sont les variables de discrimination calculées par la méthode CART (El Oufir *et al.*, 2021). SOV1 $_i$  et SOV2 $_j$  sont les seuils optimaux calculés par la FQG pour V1 et V2 (équation 3 et 4); Est $_{SOV1_i^\uparrow}$  est l'ensemble des estimateurs ( $n_{SO}$ ) formés par les sous-groupes de la classe de neige FMM; Est $_{SOV1_i^\downarrow, SOV2_j^\uparrow}$  est l'ensemble des estimateurs ( $n_{SO}^2$ ) formés par les sous-groupes de la classe de neige MFM; Est $_{SOV2_j^\downarrow, SOV1_i^\uparrow}$  est l'ensemble des estimateurs ( $n_{SO}$ ) formés par les sous-groupes de la classe de neige FFM;  $k$  et  $p$  sont les indices des SO liés à V1 et V2, respectivement ( $k \leq n_{SO}$  et  $p \leq n_{SO}$ ). Pour plus de détails, consultez l'exemple de l'annexe A de l'article 3.




Figure 4-8 : Le schéma du FQG en deux dimensions utilisant deux variables (V1 et V2), et son application pour calibrer le MBME.

#### 4.3.3 Résultats et discussion

##### ➤ Calibration des estimateurs spécifiques

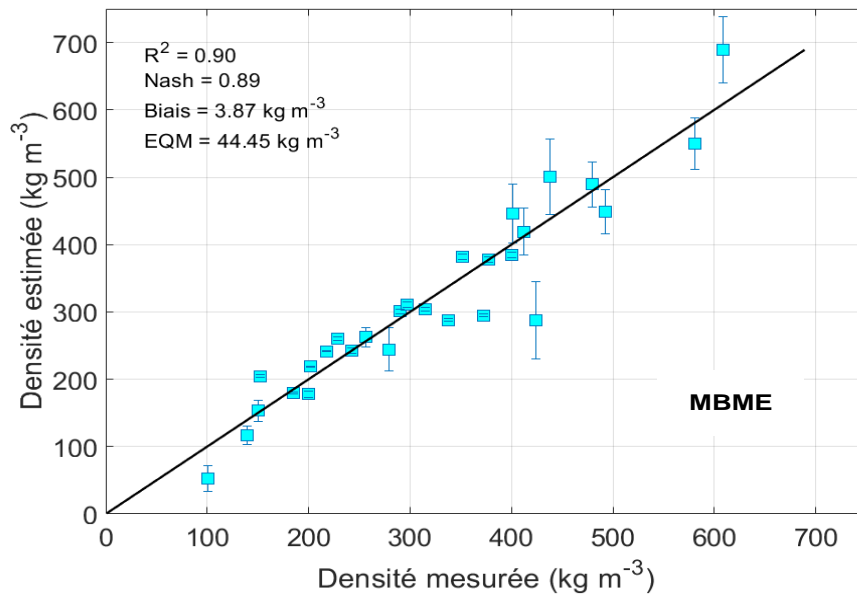
En combinant les résultats des classificateurs et des estimateurs basés sur les ensembles, il a été possible d'atteindre un bon niveau de diversité à la fois pour les classificateurs et les estimateurs. Une fois les 15 sous-groupes séparés, il a été possible de former les 15 estimateurs spécifiques (les



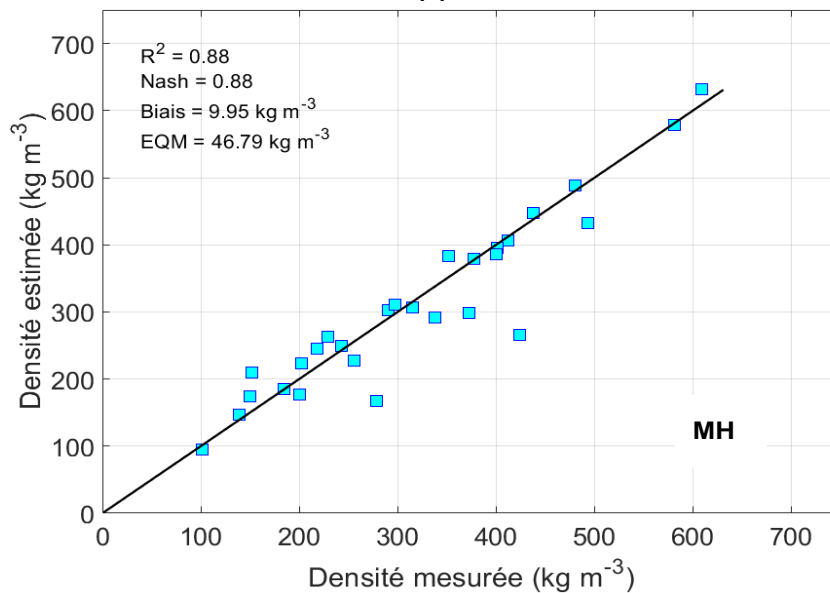
estimateurs fondés sur l'ensemble), en utilisant la technique de régression multivariée stepwise. Le Table 3-3 de l'article 3 présente les caractéristiques de calibration des estimateurs spécifiques. La corrélation entre les indices spectraux et les mesures in situ de la densité variait de modeste ( $R^2 = 0.77$  pour les estimateurs spécifiques numéro 13 et 14) à élevée ( $R^2 = 0,97$  pour l'estimateur spécifique numéro 3). Il est important de noter que les estimateurs spécifiques conçus pour estimer les trois classes de neige (FMM, MFM et FFM) ont été entraînés le plus efficacement possible en utilisant des fonctions linéaires. Pour la classe de neige FFM, en raison du vieillissement des grains de neige (métamorphose élevée), et la teneur en eau liquide élevée, les longueurs d'onde sensibles à cette classe de neige correspondent aux longueurs d'onde courtes du spectre PIR (979, et 974). Ces deux variables sont liées au pourcentage élevé de l'eau liquide dans la couche de neige identifiée, puisque la réflectance de longueurs d'onde courtes du spectre PIR montre une bonne corrélation avec le vieillissement des grains de neige et la teneur en eau liquide (Eppanapelli *et al.*, 2018a; Negi *et al.*, 2010a). Cependant, pour l'estimateur spécifique n°15 (Table 3-3 de l'article 3), qui représente la classe de transition de densités élevées à modérées, il utilise les deux variables 1122 et 1441 nm qui correspondaient aux longueurs d'onde moyennes et longues du spectre PIR. Pour les deux classes de neige de faible et moyenne densité (FMM et MFM), les longueurs d'onde sensibles à ces deux classes de neige correspondent au mélange des longueurs d'onde courte (968, 946 et 941nm), moyennes (1172 nm) et longues (1452, 1617 et 1589 nm) du spectre PIR. Ce résultat était en quelque sorte attendu, car les deux classes de neige FMM et MFM sont basées sur des mélanges de faible, moyenne et forte densité, ce qui veut dire un mélange du degré d'évolution des caractéristiques physiques de la neige soit en termes de métamorphose, de teneur en eau liquide, et de taille et forme des grains de neige.

➤ Évaluation et validation du modèle basé sur les méthodes d'ensembles

Les performances du MBME (Figure 4-9.a) et du MH (Figure 4-9.b) sont comparées. Les résultats du MBME sont été très satisfaisants avec un coefficient de détermination de 0.90, ce qui indique que le MBME peut expliquer jusqu'à 90% de la variance des données. Le NASH, qui est un indice d'évaluation plus exigeant, indique que le modèle est robuste avec un taux de réussite de 89%. Un EQM de  $44,45 \text{ kg m}^{-3}$  pour une telle plage de densités est une erreur très acceptable. Le BIAIS légèrement positif indique que le MBME a tendance à surestimer la densité de la neige. La robustesse du MBME a également été confirmée par le nuage de points des mesures in situ par rapport à leurs estimations, où tous les points sont bien répartis par rapport à la ligne 1: 1. En général, la MBME a des performances relativement élevées, comparables à celles du MH, sur la base de tous les indices statistiques.



(a)



(b)

Figure 4-9 : la densité de la neige estimée par les deux modèles a) MBME, et b) MH par rapport aux mesures in situ pour la base de données indépendante.

Les deux approches développées ont subi un test de robustesse en utilisant la méthode de la k-fold cross-validation avec 1K itération. L'objectif derrière ce test est de quantifier la stabilité et la fiabilité des deux approches à fournir une bonne estimation de la densité de la neige par la technique du bagging. Cette dernière est une méthode d'échantillonnage aléatoire itératif (1K fois par remise (50% des données utilisées pour la calibration et 50% pour le test)). Comme prévu, le MBME a montré une grande flexibilité à fournir des estimées de qualité de la densité de neige par rapport au MH. Les étalements des histogrammes (NASH et EQM) du MBME sont moins larges que ceux du MH (Figure 4-10). Ce comportement reflète la grande robustesse et fiabilité du MBME (écart-type<sub>NASH</sub> = 0,18 et écart-type<sub>RQM</sub> =  $15,04 \text{ kg m}^{-3}$  versus écart-type<sub>NASH</sub> = 0,02 et écart-type<sub>RQM</sub> =  $4,27 \text{ kg m}^{-3}$  pour le MH

et le MBME, respectivement). Également, les résultats des boîtes à moustache (box plot) viennent appuyer les résultats des histogrammes. Les boîtes à moustache (NASH et EQM) du MBME sont plus étroites avec moins de données qui sortent de la normale (de la boîte à moustache) ce qui signifie que les valeurs, qu'elles soient du NASH ou du EQM, appartiennent à la même population, autrement dit, les évaluations du MBME pour les 1K itérations ne varient pas beaucoup. Contrairement aux résultats du MH où on remarque plus de valeurs qui sortent de la boîte à moustache et par conséquent reflètent le caractère non robuste du MH (Figure 4-11).

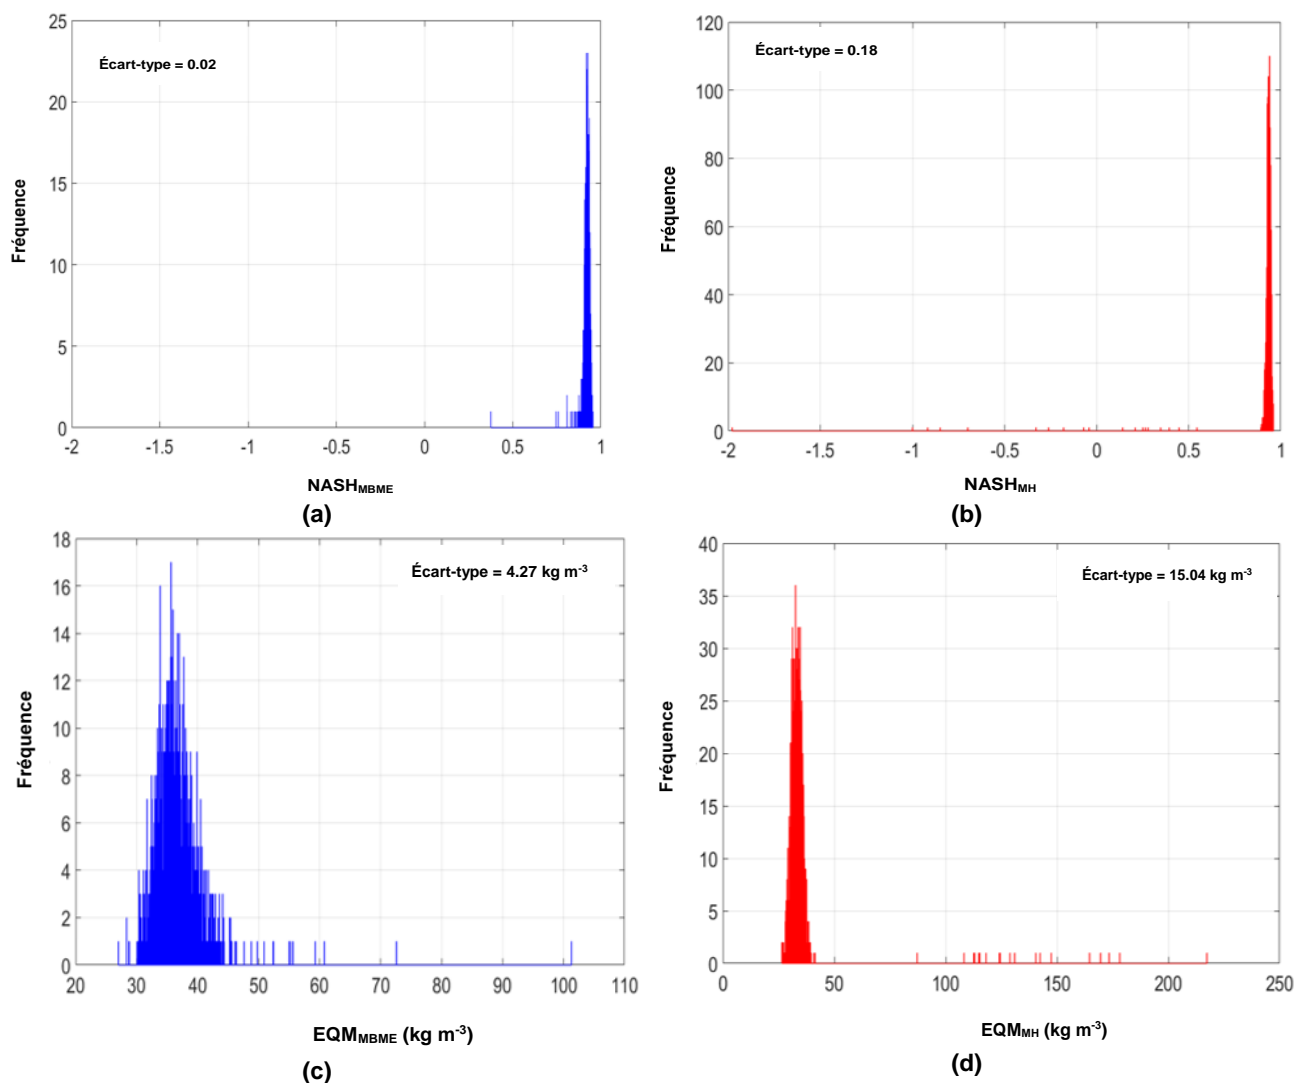


Figure 4-10 : Histogrammes du test de robustesse du MBME et du MH : a) écart-type ( $NASH_{MBME}$ ) = 0.02, b) écart-type ( $NASH_{MH}$ ) = 0.18, c) écart-type ( $EQM_{MBME}$ ) = 4.27  $kg\ m^{-3}$ , d) écart-type ( $EQM_{MH}$ ) = 16.04  $kg\ m^{-3}$ .




Figure 4-11 : Les boîtes à moustaches représentant la distribution des valeurs de densité de neige estimées exprimées en a) NASH et b) EQM, selon les deux modèles MBME et MH.

Le MBME est basé sur un classificateur plus général et sur une combinaison de plusieurs sorties d'estimateurs spécifiques entraînées par différentes régions spectrales PIR (courtes, moyennes et longues). Cette conceptualisation permet d'atténuer toute erreur potentielle de classification, contrairement à celle du MH, conduisant à sélectionner un mauvais estimateur spécifique, et par conséquent à une surestimation ou une sous-estimation de la densité. D'autre part, vue que les sorties du MBME sont basées sur un ensemble d'ES, il est également possible d'associer un intervalle de confiance pour chaque estimation, ce qui n'est ni le cas pour le MH, ni pour les modèles standards.

#### 4.3.4 Conclusions

Le MBME a été développé pour contrôler et atténuer les incertitudes de l'estimation de la densité des manteaux neigeux saisonniers liées au MH. Pour renforcer la fiabilité de notre approche, nous avons créé un ensemble de classificateurs et estimateurs. Plusieurs aspects innovants ont été développés dans cette approche : 1) l'utilisation des données in situ physiques et optiques hebdomadaires du manteau neigeux saisonnier le long de trois hivers (2018 à 2020) ; 2) l'utilisation d'un MBME à des fins de classification et de régression dans une application de télédétection proximale ; et 3) l'utilisation de la FQG pour l'optimisation du temps d'exécution. La combinaison de ces points a conduit au développement d'une méthode robuste capable d'estimer la densité des manteaux neigeux saisonniers avec précision. Les résultats de la validation avec la base de données indépendante ont été très satisfaisants, avec un  $R^2 = 0.90$  et  $NASH = 0.89$ . Le test de robustesse a également mis en évidence la fiabilité et la qualité des estimées de la densité de la neige par rapport au MH.

Les résultats ci-haut démontrent clairement la valeur de l'utilisation des méthodes d'ensemble qui ont conduit à un modèle d'estimation de la densité de la neige robuste et précis, et ce également grâce à la résolution spectrale très fine du capteur hyperspectral PIR utilisé. Cela pourrait être d'une grande aide pour les gestionnaires de l'eau de la province de Québec pour l'optimisation de l'estimation de l'équivalent en eau de la neige. Enfin, il pourrait aider les chercheurs à mieux comprendre la dynamique spatio-temporelle des manteaux neigeux saisonniers et leurs évolutions métamorphiques avec les propriétés physiques et optiques en les suivant en continu. Les résultats obtenus du MBME sont meilleurs que les résultats du MH, avec, plus de robustesse.



## 5 CONCLUSION GÉNÉRALE

---

### 5.1 Évaluation des hypothèses.

Le suivi et la surveillance des variations temporelles et de la distribution spatiale de la densité saisonnière du manteau neigeux présentent un grand intérêt pour la communauté scientifique et les gestionnaires de l'eau. Cet intérêt est justifié par les risques environnementaux et les perspectives économiques associés à l'évolution permanente du manteau neigeux, qui reste le plus souvent invisible de l'extérieur. En effet, le suivi de l'évolution permanente de la densité du manteau neigeux par des méthodes d'échantillonnage standard est un processus laborieux et limité dans le temps et l'espace. Par conséquent, l'objectif de cette thèse était de développer une approche permettant d'estimer la densité du manteau neigeux saisonnier en utilisant la télédétection hyperspectrale proximale dans l'infrarouge proche. Les principaux objectifs de cette recherche doctorale sont fondés sur un ensemble d'hypothèses, dont les deux premières sont les suivantes :

1. « Étant donné que la microstructure de la neige influence ses propriétés optiques, plus précisément dans le spectre PIR (900-1700 nm), il serait possible de classer la neige associée au manteau neigeux saisonnier en utilisant la réflectance spectrale ».
2. « L'évolution des processus métamorphiques des différentes propriétés physiques de la neige est similaire au sein d'une même classe optique et présente des différences significatives d'une classe optique à l'autre ».

En premier lieu, il s'agissait de tester le potentiel des bandes hyperspectrales de la caméra PIKA NIR de RESONON pour distinguer les classes optiques de neige qui présentent différents degrés de métamorphose. Pour ce faire, une approche d'analyse de données multivariée a été utilisée pour valider ces deux premières hypothèses. Une analyse en composantes principales (ACP) est d'abord appliquée aux données hyperspectrales PIR pour analyser la distribution des données et sélectionner la gamme spectrale à utiliser dans la classification. Ensuite, une classification non supervisée (CAH) est effectuée sur les données hyperspectrales PIR pour sélectionner le nombre optimal de classes. Les résultats permettent de distinguer trois classes de neige (neige faiblement, moyennement et fortement métamorphosée). Une matrice de confusion est ensuite calculée pour évaluer la précision de la classification. Celle-ci consiste à comparer les classes mesurées (mesures physiques) avec les classes estimées (mesures optiques). Les résultats de la classification sont satisfaisants et démontrent le potentiel de l'imagerie hyperspectrale PIR à distinguer trois classes de neige.

Ces résultats sont utiles pour le développement d'un modèle permettant d'estimer les propriétés physiques de la neige, plus précisément la densité. En effet, la relation entre la réflectance spectrale du manteau neigeux et la densité a été peu étudiée. Certains modèles ont été développés pour

estimer la densité de la neige à partir de l'information spectrale. Cependant, aucun d'entre eux n'a atteint des performances significatives. La mauvaise performance de ces modèles peut s'expliquer par deux facteurs : 1) La relation surjective entre la densité de la neige et la réflectance spectrale, c'est-à-dire que plusieurs amplitudes de réflectance peuvent être associées à la même densité et vice versa, et 2) La faible résolution spectrale des capteurs spectraux antérieurement utilisés. Ces deux constatations ont conduit à l'hypothèse suivante :

3. « Le développement d'un modèle spécifique à chaque niveau métamorphique ou classe de neige peut améliorer la précision des estimations de la densité ».

Afin de tester cette hypothèse, un modèle hybride (MH) d'estimation de la densité de neige basé sur des données hyperspectrales est développé dans ce travail. Ce modèle a pour principe de classer la densité de la neige avant son estimation au moyen d'un estimateur spécifique correspondant à une classe de densité de neige prédéterminée. Ces étapes supplémentaires permettent d'éliminer la relation surjective en la convertissant en trois relations bijectives entre la densité et la réflectance spectrale. Ce modèle se compose d'un classificateur, calibré à l'aide de la méthode d'apprentissage CART (Classification and Regression Tree), et de trois estimateurs spécifiques pour trois niveaux de neige métamorphique ou classes de neige (neige métamorphique faible et moyenne et élevée). Ces trois estimateurs ont été calibrés par la technique de régression multiple pas-à-pas (stepwise) en utilisant divers rapports et différences de bandes (susceptible de rehausser l'information physique et optique de la densité). Le MH procède sur deux étapes : 1) identification de la classe de neige à modéliser via son classificateur et 2) estimation de la densité de neige via l'estimateur correspondant à la classe pré-identifiée. Les résultats de l'étalonnage ont mis en évidence l'intérêt d'utiliser la régression pas-à-pas, qui a permis de sélectionner les régions spectrales appropriées pour chaque estimateur. La performance du MH était satisfaisante d'après les résultats des indices d'évaluation statistique ( $R^2$ , EMQ, BIAIS et NASH). Cette partie de l'étude a permis de mettre en évidence l'importance d'utiliser les régions spectrales les plus pertinentes pour modéliser une classe de neige donnée et que la reconnaissance a priori des classes à modéliser peut grandement améliorer les résultats de l'estimation de la densité.

Les algorithmes de classification sont connus pour être locaux et instables. Certes, de grandes améliorations ont été apportées, mais cette instabilité peut affecter de manière significative la précision et la robustesse d'estimation de la densité en utilisant le MH. Pour atteindre une modélisation optimale de la densité de la neige en utilisant le MH, deux sources d'erreurs devaient être contrôlées : 1) erreur de classification en raison de l'instabilité et de la localité des méthodes d'apprentissage par arbres de décision (tel utilisé pour étalonner le classificateur du MH) et 2) erreur d'estimation de la densité de la neige en raison de la complexité du phénomène à modéliser aux différentes valeurs de densités où les facteurs d'interférence prennent une plus grande importance relative. En effet, tous processus de modélisation (qu'il soit utilisé à des fins de classification ou de



régression) est une simplification de la réalité et est porteur d'incertitude. La prise en compte et le contrôle de ces sources d'erreurs pourraient réduire les incertitudes de la modélisation de la densité de la neige par le MH, spécifiquement au niveau des zones de transition d'une classe de neige à une autre. Ainsi, la dernière hypothèse de recherche de la thèse était :

4. « L'utilisation des méthodes statistiques avancées telles que les méthodes d'ensemble à des fins de classification et de régression peut contrôler les erreurs dues à la classification et à l'estimation et développer des résultats de densité plus robustes ».

Pour tester cette dernière hypothèse, un modèle basé sur les méthodes d'ensemble (MBME) a été développé et validé sur le même jeu de données et ses performances ont été comparées à celles du MH. La principale limite de l'application des méthodes d'ensemble, notamment en télédétection, est le temps de calcul dû au grand nombre d'éléments constituant l'ensemble (qu'il s'agisse de classificateurs ou d'estimateurs). Toutefois, afin d'éviter ce problème, on a utilisé la formule de la quadrature gaussienne, qui permet de transformer les problèmes de rééchantillonnage en problèmes numériques, ce qui réduit considérablement le temps de traitement tout en conservant les mêmes performances.

L'utilisation des méthodes d'ensemble a permis d'améliorer la qualité de l'estimation de la densité de la neige. Certes, pour les trois classes de neige, la performance des deux modèles (MBME et MH) a été relativement similaire, mais, le test de robustesse a mis en évidence la fiabilité des estimations de la densité de la neige par rapport au MH. Donc, le contrôle des sources d'erreurs (classification et estimation) par une approche statistique ainsi que leur prise en considération lors de l'estimation finale de la densité de la neige ont significativement amélioré la qualité de la modélisation, et ont également mis en évidence la valeur de l'utilisation des méthodes d'ensemble pour de telles applications. De plus, le MBME permet de calculer une variance (intervalle de confiance) pour chaque estimation de la densité de la neige, qui pourrait être bénéfique aux décideurs et gestionnaires de l'eau.

## 5.2 Limites

L'approche proposée a permis le développement d'un modèle d'estimation de la densité saisonnière du manteau neigeux saisonnier. Cependant, les principales limites associées à cette méthode sont le nombre réduit de couches de la classe faiblement métamorphosée, ainsi que le nombre réduit de la base de données compte tenu des contraintes de temps des études de doctorat. La première contrainte est due à la difficulté d'isoler ce type de couche, car les couches de neige faiblement métamorphosées sont très légères et souvent fines. La deuxième contrainte pourrait être surmontée en continuant à collecter davantage de mesures in situ pour les années à venir. Cet effort aura un double avantage par rapport aux approches développées dans cette thèse. D'une part, en

augmentant la taille de la base de données, il serait potentiellement possible d'identifier et de discriminer davantage de classes de neige. Cette étape conduirait sans doute à une modélisation plus optimale et plus précise de la densité de la neige. D'autre part, puisque les approches développées sont de type orientées données, les alimenter avec plus de données conduira également à des estimations de densité de neige plus robustes et plus fiables. Plus d'analyses sont nécessaires dans cette direction afin de surmonter ces inconvénients et conduire à une mise en œuvre optimale sur le terrain. Nous concluons que nos résultats constituent une première avancée vers le développement d'une méthode efficace pour le suivi continu des profils de densité saisonniers du manteau neigeux sur le terrain.

### 5.3 Aspects innovateurs, contributions et retombées

Une des innovations présentées dans cette thèse est la construction d'une carotteuse à neige rectangulaire portable (construite sur mesure) permettant un échantillonnage détaillé du manteau neigeux saisonnier. La carotteuse à neige rend possible 1) la récupération de la stratigraphie verticale du manteau neigeux, ce qui permet d'extraire la neige de surface et les couches plus profondes du profil vertical tout en conservant la neige; 2) l'évaluation visuelle de la stratigraphie verticale du manteau neigeux; 3) la mesure des propriétés physiques (densité, granulométrie et type) et optiques (réflectance spectrale) de la neige, tout en identifiant les couches de neige et leur profondeur.

Un autre aspect innovant de cette étude est l'utilisation d'une station d'acquisition proximale, équipée d'une caméra hyperspectrale PIR (RESONON PIKA NIR) permettant la mesure de la réflectance spectrale PIR à des longueurs d'onde comprises entre 900 nm et 1700 nm avec une haute résolution spectrale de 5.5 nm pour 148 bandes spectrales. La caméra hyperspectrale est montée sur une plateforme de translation linéaire permettant une acquisition rapide des données spectrales. La station d'acquisition permet de mesurer les propriétés optiques (réflectance spectrale) de la neige en positionnant la carotteuse horizontalement sur la plateforme mobile par rapport au champ de vision de la caméra.

Il est important de noter que l'approche développée peut être entièrement automatisée pour obtenir la densité de la stratigraphie verticale du manteau neigeux en temps quasi-réel directement sur le terrain. En effet, la mise en œuvre de l'approche en mode opérationnel apportera des avantages économiques importants en permettant de : 1) de bénéficier de la disponibilité quotidienne donnant la possibilité de suivre en temps quasi-réel l'évolution continue du manteau neigeux ; 2) de suivre simultanément l'équivalent en eau de la neige sur un territoire aussi vaste que le Québec. Le développement de cette approche n'avait pas pour but de remplacer les méthodes de mesure et de suivi standard, mais de développer un outil décisionnel fiable pour une meilleure gestion logistique. Les méthodes standard sont d'ailleurs nécessaires pour la calibration et la validation de ce type

d'approche, ainsi que pour mesurer d'autres variables du manteau neigeux, qui sont fondamentales dans le contexte général de la recherche sur les variations saisonnières de la neige.

#### 5.4 Perspectives

Cette approche peut constituer une véritable percée dans la détermination et le suivi des différents processus qui conduisent à l'évolution continue et au contrôle régulier des accumulations saisonnières de neige. En effet, une telle perspective ouvre la voie à la mise en œuvre future de systèmes PIR multispectraux ou hyperspectraux moins coûteux, capables de mesurer la densité de la stratigraphie verticale d'une grande variété de manteaux neigeux (basse et haute altitude, environnements fermés et ouverts, conditions côtières et continentales, montagnes, etc.) à haute résolution verticale, sans devoir creuser des fosses à neige. Le système peut également être utilisé pour une variété d'études scientifiques allant de la simple analyse comparative à des enquêtes statistiques plus approfondies.

L'exploitation des résultats de cette recherche est très prometteuse pour mettre en pratique la réalisation d'outils optiques capables de 1) déterminer une classification de la stratigraphie verticale du manteau neigeux saisonnier afin de distinguer des classes de neige optique avec différents degrés de métamorphose de la neige (faible, moyenne et forte métamorphose) et 2) de fournir simultanément une estimation de la densité de cette stratigraphie avec une haute résolution horizontale. Ceci est possible sans reconnaissance a priori, basée uniquement sur l'information spectrale. De tels outils auront sans doute des répercussions avantageuses sur le suivi des autres paramètres. À titre d'exemple, on peut envisager un suivi quotidien de l'équivalent en eau de la neige, c'est-à-dire des valeurs minimales, moyennes et maximales, etc. Elle peut également conduire à une analyse plus approfondie visant à optimiser le réseau de stations de neige, en remplaçant ou repositionnant les réseaux de stations de mesure optique.

Cette étude pourrait être également le socle de départ de plusieurs travaux quant aux quantifications et l'estimation des autres paramètres physiques de la neige. En effet, étant donné la nature complexe et interconnectée des paramètres clés des propriétés physiques de la neige, il est peu probable que cet effet surjectif soit spécifique seul à la densité. Les approches développées (MH et MBME) peuvent ainsi être testées sur les autres propriétés physiques de la neige. Ceci permettrait de profiter d'une seule source d'information afin d'effectuer une analyse plus complète du profil vertical du manteau neigeux avec moins d'efforts, des précisions acceptables et de façon non destructive.

Afin de lever toute ambiguïté, le présent travail développe une approche (algorithme de classification et évaluation) pour estimer la densité saisonnière du manteau neigeux en utilisant la télédétection hyperspectrale proche infrarouge. Nous utilisons le carottier pour récupérer les données utilisées pour développer l'algorithme qui sera ensuite intégrer dans une sonde fixe ou mobile.



## 6 RÉFÉRENCES

---

- Aoki T, Tadao, Fukabori M, Hachikubo A, Tachibana Y & Nishio F (2000) Effects of snow physical parameters on spectral albedo and bidirectional reflectance of snow surface. *Journal of Geophysical Research: Atmospheres* 105(D8):10219-10236.
- Armstrong RL & Brun E (2008) *Snow and Climate: Physical Processes, Surface Energy Exchange and Modeling*. Cambridge University Press,
- Arons E & Colbeck S (1995) Geometry of heat and mass transfer in dry snow: a review of theory and experiment. *Reviews of Geophysics* 33(4):463-493.
- Baba MW, Gascoin S & Hanich L (2018) Assimilation of Sentinel-2 data into a snowpack model in the High Atlas of Morocco. *Remote Sensing* 10(12):1982.
- Barnett TP, Adam JC & Lettenmaier DP (2005) Potential impacts of a warming climate on water availability in snow-dominated regions. *Nature* 438(7066):303.
- Bohren CF & Beshta RL (1979) Snowpack albedo and snow density. *Cold Regions Science and Technology* 1(1):47-50.
- Boyne HS & Fisk DJ (1990) A laboratory comparison of field techniques for measurement of the liquid water fraction of snow. (cold regions research and engineering lab hanover nh).
- Breiman L (1996) Bagging predictors. *Machine learning* 24(2):123-140.
- Brunauer S, Emmett PH & Teller E (1938) Adsorption of gases in multimolecular layers. *Journal of the American chemical society* 60(2):309-319.
- Bühler Y, Meier L & Ginzler C (2015) Potential of operational high spatial resolution near-infrared remote sensing instruments for snow surface type mapping. *IEEE Geoscience and Remote Sensing Letters* 12(4):821-825.
- Cabanes A, Legagneux Lc & Dominé F (2002) Evolution of the specific surface area and of crystal morphology of Arctic fresh snow during the ALERT 2000 campaign. *Atmospheric Environment* 36(15-16):2767-2777.
- Chauchard F, Cogdill R, Roussel S, Roger J & Bellon-Maurel V (2004) Application of LS-SVM to non-linear phenomena in NIR spectroscopy: development of a robust and portable sensor for acidity prediction in grapes. *Chemometrics and Intelligent Laboratory Systems* 71(2):141-150.
- Colbeck S (1982) An overview of seasonal snow metamorphism. *Reviews of Geophysics* 20(1):45-61.
- Colbeck S (1983) Theory of metamorphism of dry snow. *Journal of Geophysical Research: Oceans* 88(C9):5475-5482.
- Colbeck S (1991) The layered character of snow covers. *Reviews of Geophysics* 29(1):81-96.
- Colbeck S & Anderson EA (1982) The permeability of a melting snow cover. *Water Resources Research* 18(4):904-908.

- Colbeck SC (1973) Theory of metamorphism of wet snow.
- Davis RE, Dozier J & Perla R (1987) Measurement of snow grain properties. *Seasonal snowcovers: physics, chemistry, hydrology*, Springer. p 63-74.
- De Sève D, Bernier M, Fortin J-P & Walker A (1997) Preliminary analysis of snow microwave radiometry using the SSM/I passive-microwave data: the case of La Grande River watershed (Quebec). *Annals of Glaciology* 25:353-361.
- DeBeer C & Pomeroy J (2010) Simulation of the snowmelt runoff contributing area in a small alpine basin. *Hydrology and Earth System Sciences* 14(7):1205.
- Denoth A (1994) An electronic device for long-term snow wetness recording. *Annals of Glaciology* 19:104-106.
- Doherty SJ, Grenfell TC, Forsström S, Hegg DL, Brandt RE & Warren SG (2013) Observed vertical redistribution of black carbon and other insoluble light-absorbing particles in melting snow. *Journal of Geophysical Research: Atmospheres* 118(11):5553-5569.
- Dominé F, Cabanes A, Taillandier A-S & Legagneux L (2001) Specific surface area of snow samples determined by CH<sub>4</sub> adsorption at 77 K and estimated by optical microscopy and scanning electron microscopy. *Environmental science & technology* 35(4):771-780.
- Domine F, Salvatori R, Legagneux L, Salzano R, Fily M & Casacchia R (2006) Correlation between the specific surface area and the short wave infrared (SWIR) reflectance of snow. *Cold Regions Science and Technology* 46(1):60-68.
- Domine F, Taillandier AS & Simpson WR (2007) A parameterization of the specific surface area of seasonal snow for field use and for models of snowpack evolution. *Journal of Geophysical Research* 112:1-12.
- Donahue C, Skiles SM & Hammonds K (2021) In situ effective snow grain size mapping using a compact hyperspectral imager. *Journal of Glaciology* 67(261):49-57.
- Dozier J & Painter TH (2004) Multispectral and hyperspectral remote sensing of alpine snow properties. *Annu. Rev. Earth Planet. Sci.* 32:465-494.
- El Oufir MK, Chokmani K, El Alem A, Agili H & Bernier M (2021) Seasonal Snowpack Classification Based on Physical Properties Using Near-Infrared Proximal Hyperspectral Data. *Sensors* 21(16):5259.
- El Oufir MK, Chokmani K, El Alem A & Bernier M (2021) Estimating Snowpack Density from Near-Infrared Spectral Reflectance Using a Hybrid Model. *Remote Sensing* 13(20):4089.
- Eppanapelli LK, Lintzen N, Casselgren J & Wåhlin J (2018a) Estimation of Liquid Water Content of Snow Surface by Spectral Reflectance. *Journal of cold regions engineering* 32(1).
- Eppanapelli LK, Lintzen N, Casselgren J & Wåhlin J (2018b) Estimation of Liquid Water Content of Snow Surface by Spectral Reflectance. *Journal of Cold Regions Engineering* 32(1):05018001.

- Fassnacht S, Heun C, Moreno JL & Latron J (2013) Variability of snow density measurements in the Río Esera Valley, Pyrenees Mountains, Spain. *Cuadernos de investigación geográfica* 36(1):59-72.
- Fayad A, Gascoin S, Faour G, López-Moreno JI, Drapeau L, Le Page M & Escadafal R (2017) Snow hydrology in Mediterranean mountain regions: A review. *Journal of Hydrology* 551:374-396.
- Fierz C, Armstrong RL, Durand Y, Etchevers P, Greene E, McClung DM, Nishimura K, Satyawali PK & Sokratov SA (2009) *The international classification for seasonal snow on the ground*. UNESCO/IHP Paris,
- Flanner MG, Shell K, Barlage M, Perovich DK & Tschudi M (2011) Radiative forcing and albedo feedback from the Northern Hemisphere cryosphere between 1979 and 2008. *Nature Geoscience* 4(3):151.
- Flanner MG & Zender CS (2006) Linking snowpack microphysics and albedo evolution. *Journal of Geophysical Research: Atmospheres* 111(D12).
- Flanner MG, Zender CS, Randerson JT & Rasch PJ (2007) Present-day climate forcing and response from black carbon in snow. *Journal of Geophysical Research: Atmospheres* 112(D11).
- Flin F, Brzoska J-B, Lesaffre B, Coléou C & Pieritz RA (2003) Full three-dimensional modelling of curvature-dependent snow metamorphism: first results and comparison with experimental tomographic data. *Journal of Physics D: Applied Physics* 36(10A):A49.
- Gallet J-C (2010) *La neige du plateau antarctique. Surface spécifique et applications*. (Université Joseph-Fourier-Grenoble I).
- Gallet J-C, Domine F & Dumont M (2014) Measuring the specific surface area of wet snow using 1310 nm reflectance. *The Cryosphere* 8(4):1139-1148.
- Gallet J-C, Domine F, Zender C & Picard G (2009) Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm. *The Cryosphere* 3(2).
- Gergely M, Schneebeli M & Roth K (2010) First experiments to determine snow density from diffuse near-infrared transmittance. *Cold regions science and technology* 64(2):81-86.
- Gergely M, Wolfsperger F & Schneebeli M (2013) Simulation and validation of the InfraSnow: an instrument to measure snow optically equivalent grain size. *IEEE transactions on geoscience and remote sensing* 52(7):4236-4247.
- Goodison B, Ferguson H & McKay G (1981) Measurement and data analysis. *Handbook of snow* :191-274.
- Gray D, Norum D & Dyck G (1970) Snow measurement in the prairie environment. *Can. Agric. Eng* 12(1):38-41.
- Gray DM & Male DH (1981) *Handbook of snow: principles, processes, management & use*. Pergamon,

- Green RO, Dozier J, Roberts D & Painter T (2002) Spectral snow-reflectance models for grain-size and liquid-water fraction in melting snow for the solar-reflected spectrum. *Annals of Glaciology* 34:71-73.
- Green RO, Painter TH, Roberts DA & Dozier J (2006) Measuring the expressed abundance of the three phases of water with an imaging spectrometer over melting snow. *Water Resources Research* 42(10).
- Grenfell TC & Warren SG (1999) Representation of a nonspherical ice particle by a collection of independent spheres for scattering and absorption of radiation. *Journal of Geophysical Research: Atmospheres* 104(D24):31697-31709.
- Haq MA, Ghosh A, Rahaman G & Baral P (2019) Artificial neural network-based modeling of snow properties using field data and hyperspectral imagery. *Natural Resource Modeling* 32(4):e12229.
- Hodjaty M, Saradjian M & Jamshidi S (2010) Chlorophyll-a estimation in Sefidrud estuarine using MODIS images. *FIG Congr.*
- Hoff JT, Gregor D, Mackay D, Wania F & Jia CQ (1998) Measurement of the specific surface area of snow with the nitrogen adsorption technique. *Environmental science & technology* 32(1):58-62.
- Horton S & Jamieson B (2017) Spectral measurements of surface hoar crystals. *Journal of Glaciology* 63(239):477-486.
- Kerbrat M, Pinzer B, Huthwelker T, Gäggeler H, Ammann M & Schneebeli M (2008) Measuring the specific surface area of snow with X-ray tomography and gas adsorption: comparison and implications for surface smoothness. *Atmospheric chemistry and physics* 8(5):1261-1275.
- Kinar N & Pomeroy J (2015) Measurement of the physical properties of the snowpack. *Reviews of Geophysics* 53(2):481-544.
- Kokhanovsky A, Lamare M, Danne O, Brockmann C, Dumont M, Picard G, Arnaud L, Favier V, Jourdain B & Le Meur E (2019) Retrieval of snow properties from the Sentinel-3 Ocean and Land Colour Instrument. *Remote Sensing* 11(19):2280.
- Kuipers Munneke P (2009) *Snow, ice and solar radiation*. (Utrecht University).
- Kulkarni A, Srinivasulu J, Manjul S & Mathur P (2002) Field based spectral reflectance studies to develop NDSI method for snow cover monitoring. *Journal of the Indian Society of Remote Sensing* 30(1-2):73-80.
- Langham E (1981) Physics and properties of snowcover. *Handbook of snow* :275-337.
- Langlois A, Royer A, Montpetit B, Picard G, Brucker L, Arnaud L, Harvey-Collard P, Fily M & Goïta K (2010) On the relationship between snow grain morphology and in-situ near infrared calibrated reflectance photographs. *Cold Regions Science and Technology* 61(1):34-42.



- Legagneux L, Cabanes A & Dominé F (2002) Measurement of the specific surface area of 176 snow samples using methane adsorption at 77 K. *Journal of Geophysical Research: Atmospheres* 107(D17).
- Lesaffre B, Pougatch E & Martin E (1998) Objective determination of snow-grain characteristics from images. *Annals of Glaciology* 26:112-118.
- Li H, Wang A, Guan D, Jin C, Wu J, Yuan F & Shi T (2016) Empirical model development for ground snow sublimation beneath a temperate mixed forest in Changbai mountain. *Journal of Hydrologic Engineering* 21(11):04016040.
- Li R-H & Belford GG (2002) Instability of decision tree classification algorithms. *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining*. p 570-575.
- Libois Q, Picard G, Arnaud L, Dumont M, Lafaysse M, Morin S & Lefebvre E (2015) Summertime evolution of snow specific surface area close to the surface on the Antarctic Plateau. *The Cryosphere Discussions* 9:2383-2398.
- Liljequist GH (1956) Energy exchange of an antarctic snow-field: A. *Short-wave radiation*; B. *Long-wave radiation and radiation balance*. *Norwegian-British-Swedish Antarctic Expedition 1949-1952, Scientific Results* 2(1):1-184.
- Ling F & Zhang T (2004) A numerical model for surface energy balance and thermal regime of the active layer and permafrost containing unfrozen water. *Cold Regions Science and Technology* 38(1):1-15.
- Lorente D, Aleixos N, Gómez-Sanchis J, Cubero S, García-Navarrete OL & Blasco J (2012) Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment. *Food and Bioprocess Technology* 5(4):1121-1142.
- Lu G & Fei B (2014) Medical hyperspectral imaging: a review. *Journal of biomedical optics* 19(1):010901.
- Lyapustin A, Tedesco M, Wang Y, Aoki T, Hori M & Kokhanovsky A (2009) Retrieval of snow grain size over Greenland from MODIS. *Remote Sensing of Environment* 113(9):1976-1987.
- Male DH (1981) *Handbook of snow: principles, processes, management & use*. Pergamon,
- Marbouty D (1983) La Neige : propriétés physiques.
- Marbouty D (1984) Les propriétés physiques de la neige. *La houille blanche* (8):557-567.
- Marsh P (1991) Water flux in melting snow covers. In-Advances in Porous Media, Vol. 1. MY Corapcioglu. *Elsevier, Amsterdam* 6:1-124.
- Matzl M & Schneebeli M (2006) *Measuring specific surface area of snow by near-infrared photography*.
- McKay G & Findlay B (1971) Variation of snow resources with climate and vegetation in Canada.
- Molnau MP (1971) *Comparison of runoff from a catchment snow pillow and a small forested watershed*. University of Idaho,

- Montpetit B, Royer A, Langlois A, Chum M, Cliche P, Roy A, Champollion N, Picard G, Domine F & Obbard R (2011) In-situ measurements for snow grain size and shape characterization using optical methods. *Proc. Eastern Snow Conf.* p 173-188.
- Narita H (1969) Specific surface of deposited snow, 1(Specific surface of deposited snow). 1969. :77-86.
- Nash JE & Sutcliffe JV (1970) River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology* 10(3):282-290.
- Negi H, Jassar H, Saravana G, Thakur N, Snehmani & Ganju A (2013) Snow-cover characteristics using Hyperion data for the Himalayan region. *International journal of remote sensing* 34(6):2140-2161.
- Negi H, Singh S, Kulkarni A & Semwal B (2010a) Field-based spectral reflectance measurements of seasonal snow cover in the Indian Himalaya. *International Journal of Remote Sensing* 31(9):2393-2417.
- Negi HS, Singh S, Kulkarni A & Semwal B (2010b) Field-based spectral reflectance measurements of seasonal snow cover in the Indian Himalaya. *International Journal of Remote Sensing* 31(9):2393-2417.
- Nolin AW & Dozier J (2000) A hyperspectral method for remotely sensing the grain size of snow. *Remote sensing of Environment* 74(2):207-216.
- O'Brien HW & Munis RH (1975) Red and near-infrared spectral reflectance of snow.
- Osborne BG (2006) Near-infrared spectroscopy in food analysis. *Encyclopedia of analytical chemistry: applications, theory and instrumentation.*
- Osterhuber R, Fehrke F & Condreva K (1998) Snowpack snow water equivalent measurement using the attenuation of cosmic gamma radiation. (Sandia National Labs.).
- Pahaut E (1975) *Les Cristaux de neige et leurs métamorphoses.* Direction de la Météorologie nationale,
- Painter TH, Molotch NP, Cassidy M, Flanner M & Steffen K (2007) Contact spectroscopy for determination of stratigraphy of snow optical grain size. *Journal of Glaciology* 53(180):121-127.
- Perla R, Dozier J & Davis R (1986) Preparation of serial sections in dry snow specimens. *Journal of Microscopy* 142(1):111-114.
- Pielmeier C & Schneebeli M (2003) Stratigraphy and changes in hardness of snow measured by hand, ramsonde and snow micro penetrometer: a comparison with planar sections. *Cold Regions Science and Technology* 37(3):393-405.
- Polikar R (2006) Ensemble based systems in decision making. *IEEE Circuits and systems magazine* 6(3):21-45.
- Pomeroy J & Gray D (1995) Snowcover accumulation, relocation and management. *Bulletin of the International Society of Soil Science* no 88(2).

- Roy V, Goïta K, Royer A, Walker AE & Goodison BE (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* 42(9):1850-1859.
- Sommerfeld RA (1983) A branch grain theory of temperature gradient metamorphism in snow. *Journal of Geophysical Research: Oceans* 88(C2):1484-1494.
- Sturm M, Taras B, Liston GE, Derksen C, Jonas T & Lea J (2010) Estimating snow water equivalent using snow depth data and climate classes. *Journal of Hydrometeorology* 11(6):1380-1394.
- Taillandier AS, Domine F, Simpson WR, Sturm M & Douglas TA (2007) Rate of decrease of the specific surface area of dry snow: Isothermal and temperature gradient conditions. *Journal of Geophysical Research: Earth Surface* 112(F3).
- Timofeev R (2004) Classification and regression trees (CART) theory and applications. *Humboldt University, Berlin* :1-40.
- Tørvi H & Hertzberg T (1997) Estimation of uncertainty in dynamic simulation results. *Computers & chemical engineering* 21:S181-S185.
- Vander Jagt B, Lucieer A, Wallace L, Turner D & Durand M (2015) Snow depth retrieval with UAS using photogrammetric techniques. *Geosciences* 5(3):264-285.
- Viviroli D, Dürr HH, Messerli B, Meybeck M & Weingartner R (2007) Mountains of the world, water towers for humanity: Typology, mapping, and global significance. *Water resources research* 43(7).
- Warren SG (1982) Optical properties of snow. *Reviews of Geophysics* 20(1):67-89.
- Warren SG & Brandt RE (2008) Optical constants of ice from the ultraviolet to the microwave: A revised compilation. *Journal of Geophysical Research: Atmospheres* 113(D14).
- Wright M, Kavanaugh J & Labine C (2011) Performance analysis of GMON3 snow water equivalency sensor. *Proceedings of the Western Snow Conference*. p 105-108.
- Zuanon N (2013) IceCube, a portable and reliable instruments for snow specific surface area measurement in the field. *International Snow Science Workshop Grenoble-Chamonix Mont-Blance-2013 proceedings*. p 1020-1023.



## **PARTIE 2 : LES ARTICLES**

---



## Avant-propos

Cet article a été publié dans le journal *Sensors* du *MDPI*. Les co-auteurs qui ont participé à la rédaction de ce manuscrit sont :

### **1. Mohamed Karim El Oufir :**

Responsable de la conception de recherches, la méthodologie, prétraitements et traitements des données, l'analyse et l'interprétation des résultats et à la rédaction du manuscrit.

### **2. Karem Chokmani :**

Responsable également de la conception de recherches et a contribué à l'édition, l'analyse, et à l'examen du manuscrit.

### **3. Anas El Alem :**

Responsable également de la conception de recherches et a contribué à l'édition, l'analyse, et à l'examen du manuscrit.

### **4. Hachem El Agili:**

Responsable à la révision du manuscrit.

### **5. Monique Bernier**

Responsable à la révision du manuscrit.





## Abstract

This paper proposes an innovative method for classifying the physical properties of the seasonal snowpack using near-infrared (NIR) hyperspectral imagery to discriminate the optical classes of snow at different degrees of metamorphosis. This imaging system leads to fast and non-invasive of snow properties. Indeed, the spectral similarity of two samples indicates the similarity of their chemical composition and physical characteristics. This can be used to distinguish, without a priori recognition, between different classes of snow solely based on spectral information. A multivariate data analysis approach was used to validate this hypothesis. A principal component analysis (PCA) is first applied to the NIR spectral data to analyze field data distribution and to select the spectral range to be exploited in the classification. Next, an unsupervised classification is performed on the NIR spectral data to select the number of classes. A confusion matrix is finally calculated to evaluate the accuracy of the classification. The results allowed to distinguish three snow classes of typical shape and size (weakly, moderately, and strongly metamorphosed snow). The evaluation of the proposed approach showed that it is possible to classify snow with a success rate of 85% and a kappa index of 0.75. This illustrates the potential of NIR hyperspectral imagery to distinguish between three snow classes with satisfactory success rates. This work will open new perspectives for the modelling of physical parameters of snow using spectral data.

**Keywords:** Seasonal snowpack, Metamorphosis, Classification, Hyperspectral Imaging, Near-infrared.

## Résumé

Cet article propose une méthode innovante de classification des propriétés physiques du manteau neigeux saisonnier en utilisant l'imagerie hyperspectrale proche infrarouge (PIR) afin de distinguer des classes optiques de neige à différents degrés de métamorphose. Ce système d'imagerie permet une évaluation rapide et non invasive des propriétés de la neige. En effet, la similarité spectrale de deux échantillons indique la similarité de leur composition chimique et de leurs caractéristiques physiques. Ceci peut être utilisé pour distinguer, sans reconnaissance priori, différentes classes de neige uniquement sur la base de l'information spectrale. Une approche d'analyse de données multivariée a été utilisée pour valider cette hypothèse. Une analyse en composantes principales (ACP) est d'abord appliquée aux données spectrales PIR pour analyser la distribution des données sur le terrain et sélectionner la gamme spectrale à exploiter dans la classification. Ensuite, une classification non supervisée est effectuée sur les données spectrales PIR pour sélectionner le nombre de classes. Une matrice de confusion est enfin calculée pour évaluer la précision de la classification. Les résultats ont permis de distinguer trois classes de neige de forme et de taille typiques (neige faiblement, moyennement et fortement métamorphosée). L'évaluation de l'approche proposée a montré qu'il est possible de classer la neige avec un taux de réussite de 85% et un indice de kappa de 0,75. Ceci illustre le potentiel de l'imagerie hyperspectrale PIR pour distinguer trois classes de neige avec des taux de réussite satisfaisants. Ce travail ouvre de nouvelles perspectives pour la modélisation des paramètres physiques de la neige à l'aide de données spectrales.

**Mots clés :** Manteau neigeux saisonnier, métamorphose, classification, imagerie hyperspectrale, proche infrarouge.

# 1 PREMIER ARTICLE: SEASONAL SNOWPACK CLASSIFICATION BASED ON PHYSICAL PROPERTIES USING NEAR-INFRARED PROXIMAL HYPERSPECTRAL DATA

---

Mohamed Karim El Oufir \*, Karem Chokmani, Anas El Alem, Hachem Agili and Monique Bernier

Citation: El Oufir, M.K.; Chokmani, K.; El Alem, A.; Agili, H.; Bernier, M.

<https://doi.org/10.3390/s21165259>

Received: 5 May 2021; Accepted: 31 July 2021; Published: 4 August 2021

INRS-Institut National de la Recherche Scientifique (INRS), Québec, QC G1K 9A9, Canada;

[karem.chokmani@ete.inrs.ca](mailto:karem.chokmani@ete.inrs.ca) (K.C.);

[anas.el\\_alem@ete.inrs.ca](mailto:anas.el_alem@ete.inrs.ca) (A.E.A.);

[hachem.agili@ete.inrs.ca](mailto:hachem.agili@ete.inrs.ca) (H.A.);

[monique.bernier@ete.inrs.ca](mailto:monique.bernier@ete.inrs.ca) (M.B.)

\* Correspondance: [mohamed\\_karim.el\\_oufir@ete.inrs.ca](mailto:mohamed_karim.el_oufir@ete.inrs.ca); Tel.: +1-418-264-1950

Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland.

## 1. INTRODUCTION

Snow is one of the most important components of the cryosphere (Langlois *et al.*, 2010). It significantly contributes to the water balance, the climate, and the economy of many geographic regions (Gray & Male, 1981; Kinar & Pomeroy, 2015; Marsh, 1991). The snow cover, also called snowpack, is the set of snow layers that pile up on the ground throughout the winter (Fierz *et al.*, 2009). This snow cover is highly variable due to the complex distribution of precipitation, wind, and radiation after snow deposition (Horton & Jamieson, 2017). Each layer is separated from the previous one by a superposition plane. This interface between two layers is of unequal granulometry and density, and forms a strong link between the layers by resisting to shear stress (Fierz *et al.*, 2009).

The snow on the ground undergoes a continuous transformation process, known as metamorphism that controls the physical properties of snow (Colbeck, 1982; Schneebeli & Sokratov, 2004). Indeed, snow grain size and snow density, which are used to define snow grain types, change over time due to different metamorphic mechanisms (Colbeck, 1983; Dominé *et al.*, 2003; Gubler, 1985). This continuous variation in the physical properties of snow along the vertical structure of the snowpack allows to objectively characterize the metamorphic state of snow (Fierz *et al.*, 2009; Flin *et al.*, 2004; Taillandier *et al.*, 2007).

The terms used to describe the spatial and temporal evolution of snow are important for all aspects of snow studies and applications (Colbeck, 1986). Indeed, a simple description is sufficient to characterize the vertical structure of snowpack. That is why, in the early research on snow cover, it was necessary to classify the seasonal snowpack according to its physical properties. In the seventies, Pahaut (1975) noted that snow is compacted over time and proposed to classify densities based on the type of snow. In response to the growing need for standardization, an international classification system was subsequently proposed by Colbeck (1985) and later revised by Fierz (Fierz *et al.*, 2009) in their book entitled "International Classification for Seasonal Snow on the Ground." The classification system based on visual recognition and the related techniques have since then been used by snow physics practitioners to classify snow on the ground (Jamieson & Johnston, 2001).

Despite the improvements in the measurement of the physical properties of snow, the classification of snow on the ground remains one of the most challenging issues. Indeed, the classification of measured data on the vertical profile of snowpack is a laudable objective for several reasons (Kinar & Pomeroy, 2015). In economic and social terms, permission for many winter recreational activities depends on knowledge of the vertical structure of the snowpack, which makes this task paramount and valuable (Schweizer & Jamieson, 2001). Also, meteorological conditions and solid precipitation data remain insufficient to predict avalanche risks (Horton & Jamieson, 2017). To do so, it is necessary to document the internal evolution of the snowpack, hence the need for frequent and regular observations and measurements (Horton & Jamieson, 2017). These measurement techniques are often based on direct observations using a magnifying glass to classify granulometry stratigraphy and

snow grain shape, and a snow sampler to measure density. Such direct measurements makes it possible to improve existing snow cover models which are used to quantitatively simulate changes over time for hydrological applications such as the snow water equivalent (Kinar & Pomeroy, 2015). However, these classification techniques require the use of in situ sampling for hydrological and avalanche studies. Previous experimental results have shown that traditional methods used for the classification of snow samples have undeniable weaknesses (laborious methods requiring several hours of work) (Vander Jagt *et al.*, 2015). These methods rely on manual measurements of the physical characteristics of snow and are not suitable for the evaluation of individual samples in large-scale, fast-paced production (Fierz & Baunach, 2000; Painter *et al.*, 2007). Also, because of the sensitivity of snow grain morphology to changes in local temperature and humidity, field measurements generally contain significant errors (Dominé *et al.*, 2001; Hoff *et al.*, 1998). Therefore, a fast, objective and non-invasive classification technique of the physical properties of snow is long overdue.

Hyperspectral imaging is a new technique based on spectroscopic analyses. It is fast, non-destructive, facilitates real-time measurements and is widely used in various fields, namely agriculture (Berger *et al.*, 2018; Cubero *et al.*, 2011), pharmacy (Roggo *et al.*, 2005), and the food industry (Caporaso *et al.*, 2018; Karimi *et al.*, 2012). It has proven its effectiveness in field, laboratory, and industrial applications (Chauchard *et al.*, 2004; Osborne, 2006). Indeed, it has already been demonstrated that the near infrared (NIR) spectrum is sensitive to the physical parameters of snow (Haq *et al.*, 2019; Kulkarni *et al.*, 2002; Negi *et al.*, 2010; Nolin & Dozier, 2000). In fact, snow granulometry is clearly visible in the NIR and the short waves of infrared regions (SWIR) (Dozier, 1989; Warren & Wiscombe, 1980). Eppanapelli *et al.* (2018) found that the spectral reflectance of snow in the NIR is inversely proportional to the liquid water content in the snow. In addition, the absorption of ice in the NIR is very high (Warren & Brandt, 2008), so the effect of impurities such as mineral dust and soot is negligible beyond 1000 nm wavelength.

The above results highlight the potential of NIR hyperspectral data to gather information on the physical properties of snow. In fact, many studies and research have been done for this type of application, but they have treated each parameter individually. For example, snow grain size has been correlated with reflectance of small discrete snow samples using either the integrating sphere method (e.g. DUFISSS (Gallet *et al.*, 2009), IceCube (Zuanon, 2013), and Infrasnw (Gergely *et al.*, 2013)) or a high spectral resolution NIR photography method (Donahue *et al.*, 2021; Matzl & Schneebeli, 2006). Similarly, the liquid water content of the snow was modeled based on the reflective properties of the snow. The results show that liquid water content is inversely correlated with NIR reflectance (Eppanapelli *et al.*, 2018; Negi *et al.*, 2010). Density was also correlated with this part of the spectrum. Bohren and Beschta (1979) find that the correlation between spectral reflectance and snow density is probably the result of other changes that occur in the aging process. They conclude that there is a relationship between this parameter and reflectance. As stated, most previous studies have focused

on relating a single physical property of snow (density, grain size, or liquid water content) to reflectance. Reflectance-based modeling of their combined effect is not yet known.

This research aims at assessing the potential of hyperspectral imaging in the NIR for the classification of homogeneous layers of the vertical profile of snowpack's in terms of density, grain size, and snow grain shape. An exercise comparing field data and the corresponding spectral data is also carried out for evaluation purposes.

## 2. Materials and Methods

### 2.1 In situ measurements

In order to be able to carry out this study, two types of data had to be collected: the physical properties of the snowpack and its optical properties. The same equipment and sampling techniques were used throughout the study. The weekly physical and optical measurements of the snow pit were carried out on land owned by the National Institute for Scientific Research (INRS) in the City of Québec (Figure 1-1). Measurements were taken between 08h00 and 12h00 on windless sunny days. The City of Québec is characterized by winter temperatures ranging between  $-10\text{ }^{\circ}\text{C}$  and  $-25\text{ }^{\circ}\text{C}$ , with significant snow accumulations. The snowpack in this region is dry from January to mid-February due to low temperatures and becomes wet in March as the temperature rises. An open area of approximately  $20\text{ m} \times 5\text{ m}$  was selected as the study site. Major roughness characteristics and slopes were avoided by sampling only smooth and flat surfaces. Surfaces containing impurities were also avoided in order to retrieve as much representative information on the seasonal snowpack as possible. The sampled snow depth ranged between 54 cm and 105 cm.

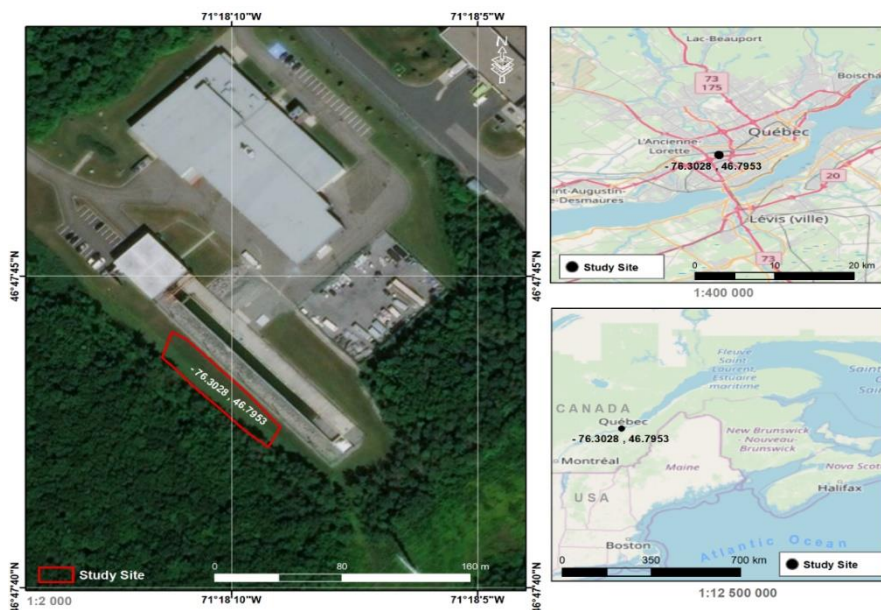


Figure 1-1 : Geographical location of the sampling site.

### 2.1.1 Physical properties of snow

Figure 1-2 shows the portable rectangular snow core sampler used to sample the snowpack (custom-built). This instrument is used to extract snow cores and retrieve the vertical profile of the snowpack, allowing a visual assessment of the vertical stratigraphy of the snow cover. Both the physical (density, grain sizes, and grain types) and optical (spectral reflectance) properties of snow were assessed on the snow core. The snow corer is composed of a metallic inner component and a plastic cover with a triangular sawtooth cutting part at the end. The corer allows to measure the height (cm) of the profile and to differentiate the homogeneous layers composing the vertical profile. The dimensions of the core sampler (10×10×120 cm) allow the entire vertical profile of the snowpack to be recuperated and the snow to be retained. The first step in collecting a snow sample is to dig out the snow pit (Figure 1-3a). To do this, the snow sampler is inserted through the surface of the snow (Figure 1-3b) so as to extract both the surface snow and the deeper layers of snow. The physical and optical properties of the snow, as well as the identification of the snow layers and their thickness are measured directly on the core. The core sampler is graduated with marks indicating the measurement scale (centimeters); this allows to measure the thickness and position of homogeneous layers of snow. The vertical profile is extracted by pushing the core through the snowpack until the serrated cutting end reaches the ground surface. Finally, the sampler is carefully removed and placed horizontally on the snowpack to measure the physical characteristics (Figure 1-4).



Figure 1-2 : Snow core sampler.



(a)



(b)

Figure 1-3 : (a) Snow pit, HP: height of the pit; (b) Snow pit after profile extraction, winter 2018.



Figure 1-4 : The vertical profile within the snow corer, winter 2018.



## 2.1.2 Optical properties of snow

Figure 1-5 shows the Pika NIR hyperspectral imaging line-scanning camera (RESONON Company), used to measure the optical properties of the snowpack. It measures the reflected light at NIR wavelengths ranging from 900 nm to 1700 nm. Reflectance spectra were calculated by measuring the radiance reflected by the snow surface and the radiance reflected by a reference target (Spectralon 99%); the latter having near-Lambertian reflection properties when viewed from the nadir. In addition to the camera, the device is equipped with a mobile platform (metal bench) of linear translation stage allowing rapid image acquisition, a mounting tower, a set of four halogen lights (500 watt each) placed perpendicular ( $90^\circ \pm 5^\circ$ ) to the snow sample for equal illumination, and a Spectronon Pro (Resonon Inc., Bozeman MT, USA) software dedicated to the acquisition and analysis of hyperspectral data.

The optical properties are measured by placing the snow core horizontally on the mobile platform relative to the camera's field of view (nadir) to be scanned line by line (Figure 1-6). The speed of the platform is adjusted for the spatial resolution of the vertical and horizontal axes to be equal, to avoid any size distortion and to fit with the predetermined exposure time of the camera. Using the proprietary Resonon Spectronon software, the snow core is scanned in a short time of 5 seconds. Hyperspectral images are created by gathering the image line by line while the sample is interpreting relative to the camera. Hyperspectral images are acquired in a 3D form called hyper-cube composed of two spatial dimensions ( $x, y$ ) and one spectral dimension ( $\lambda$ ). Each hyperspectral cube consists of 148 spectral information points at a spectral resolution of 5.5 nm. Each pixel in the hyperspectral image contains the spectrum of that specific position characterizing the physical properties within that pixel.




Figure 1-5 : Proximal hyperspectral image acquisition device.



Figure 1-6 : Hyperspectral acquisition of the snow samples vertical profile.

## 2.2 Statistical analysis of data

Hyperspectral data are characterized by their high dimensionality and collinearity. A statistical approach is therefore needed to extract useful information from the NIR spectrum. Dimensionality reduction methods have the advantage of being fit to process spectral data by reducing their high dimensionality while minimizing the loss of useful information. In the present study, a principal component analysis (PCA) is used for data visualization and spectral dimensionality reduction. A PCA-based hierarchical ascending classification (HAC) is used thereafter to classify the reflectance into different groups according to snow type, grain size, and density.

### 2.2.1 Principal component analysis (PCA) of NIR spectra

Due to the complexity of high dimensionality problems, several dimensional reduction methods are suggested in the literature, such as the PCA (Wold *et al.*, 1987). This technique is used to interpret spectral data by identifying the most important directions of variability in the multivariate data space and expressing the spectral data in such a way as to highlight their similarities and differences. The PCA is a mathematical procedure that decomposes spectral data into several main components which are linear combinations of the original spectral data and can represent the spectral variations common to all spectral data.

The PCA is the best spectral band selection method for dimensionality reduction without loss of useful information (Park *et al.*, 2001). In this paper, the principal component coefficients, also known as charges, are investigated for their usefulness in reducing the dimensionality of hyperspectral data. Thus, the factor maps can be interpreted on the principal planes, making it possible to differentiate snow classes on the basis of their spectrum. To do this, a PCA was applied to all spectral data

corresponding to the homogeneous snow layers extracted from the hyperspectral images (900 nm to 1700 nm). The first principal components (PC) resulting from the PCA are generally used to examine the common characteristics of the samples and their clustering. Thus, samples having similar spectral signatures tend to aggregate in the score diagram of the first two or three PCs.

### 2.2.2 Hierarchical ascending classification of near infrared spectra

The hyperspectral data matrix obtained after the PCA was studied using the hierarchical ascending classification (HAC) (Jambu & Lebeaux, 1978; Randriamihamison *et al.*, 2019). It is a powerful unsupervised classification method that allows to build tree structures from data similarities and to see how different subclasses are related to each other (Pope & Rees, 2014). The HAC analyzes the distance between points of the multidimensional space using progressive clustering and results in the representation of the two closest successive points in the form of a classification tree. To do this, data points are grouped into  $n$  subclasses by testing their relative proximity. Successive classes are grouped in the same way into  $n - 1$ ,  $n - 2$ ,  $n - 3$ , etc. classes, until one single class is reached. Each given class is included in the next class and the set of these classes is presented in the form of a classification tree. The level of aggregation is given by the ordinate axis with a relative scale from 0% to 100%. The abscissa axis represents only a qualitative order according to the progressive increase of the aggregation criterion of the main subsets.

The aim of this classification method is to group data into classes by assuming the existence of more or less similarities between the different points, using only hyperspectral data, and without prior knowledge. The spectrum is therefore used to classify snow samples according to their similarity in terms of metamorphosis degree (weakly, moderately, and strongly metamorphosed snow), and consequently to obtain homogeneous optical classes.

### 2.3 Accuracy assessment

To evaluate the performance of the classification, a confusion matrix was analyzed (Cohen, 1960). It consists of comparing measured classes (physical measures) with estimated classes (optical measures) and quantifying the precision of the approach used by calculating success rates, errors (commission and omission), and precision indices, namely the kappa index (Cohen, 1960). The latter permits to quantify the level of agreement between the classes of the physical characteristics measured and those estimated. Concordance is considered to be good for kappa values greater than 0.6 and excellent for values above 0.8. The flowchart in Figure 1-7 illustrates the methodological approach adopted.

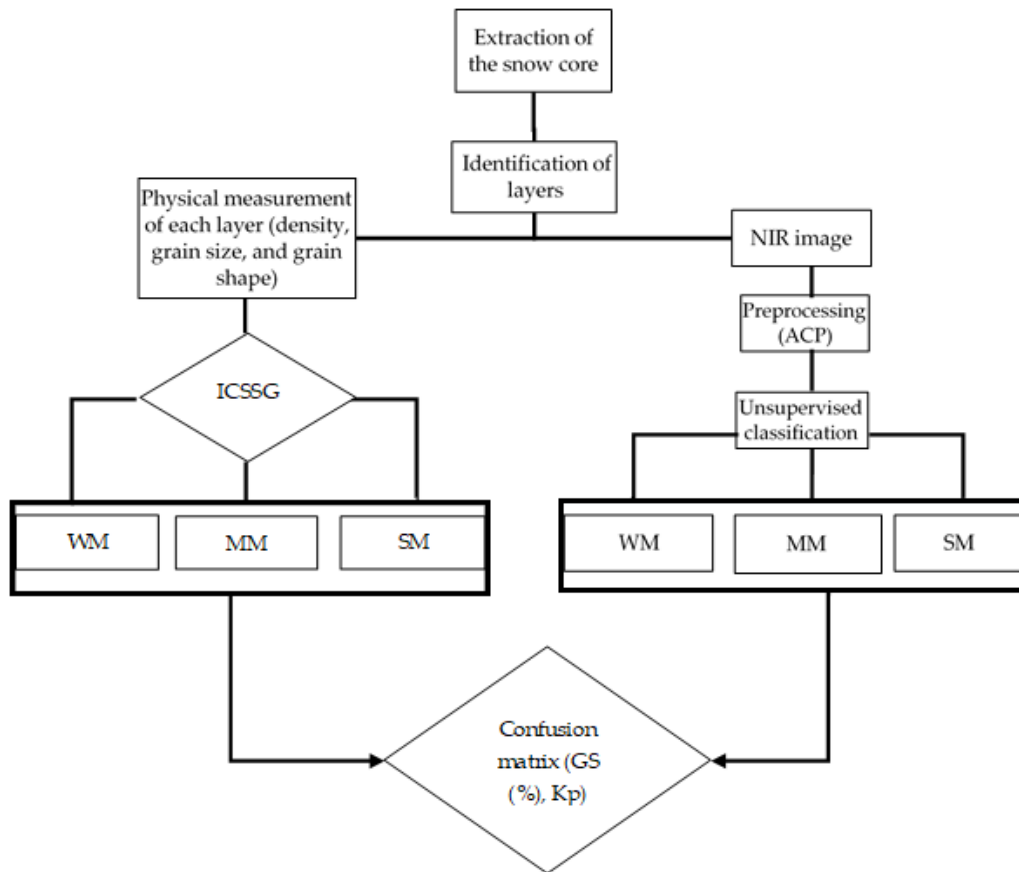


Figure 1-7 : Flowchart of the methodological approach. WM: Weakly metamorphosed; MM: moderately metamorphosed; SM: Strongly metamorphosed; GS: Global success; Kp Kappa index; ICSSG: International Classification for Seasonal Snow on the Ground.

### 3. Results and discussion

#### 3.1 Descriptive analysis

Each layer of the snowpack has its own history, which can be very different from that of its upper or lower layers and results in very different evolution patterns (Libois, 2014). Thus, all the different values and dimensions of physical properties can coexist simultaneously on the same vertical axis of the snowpack. In this regard, it is necessary to classify the physical properties of each snow layer. In a snowpack, the density, type, and size of grains in each snow layer usually increase with depth, but exceptions are very frequent and generally correspond to instabilities (Marbouty, 1984). In this work, in situ sampling of the physical properties of snow was inspired by the work of Pahaut (1975) and the snowpack is treated as a succession of layers. Twenty-four snow cores were collected for this study (January 19 to March 27 in 2018, January 10 to April 3 in 2019, and January 29 to March 9 in 2020). Indeed, we collected weekly data during three winter seasons, in order to obtain data as diverse as possible and to guarantee a wide range degree of metamorphism. Table 1-1 Table 1-2 show the report of data for temperature and snow accumulation on the ground for the winters of 2018, 2019, and 2020 according to <https://climate.weather.gc.ca/>, accessed on 15 July 2021. For each snow profile, a serie

of physical and optical measurements were made and recorded. A mobile laboratory exposed near the sampling site that keeps the same degree of outside temperature allows us to take physical and optical data in about 10 minutes. Snow layers were visually identified by observing the changes in the size and type of grains on the core's surface. For each identified layer, the type and size of snow grains were measured and manually classified according to the International Classification of Seasonal Ground Snow (Fierz *et al.*, 2009). The disaggregated grains were placed on a grid millimeter map and observed with a 10 times magnifying glass. The density of each layer was calculated using its mass and volume relative to the surface area of the core sampler (Table 1-3). In addition to the information collected on the physical parameters shown, a photo of each layer was visually associated to a general group of density, grain size, and type. The different shades of gray used in the bar graphs show the metamorphosis levels (low, moderate, high) of each recuperated snow layer. To ensure analysis coherence, all snow observations and measurements were made by the same individual.

Table 1-1 : Temperature data report for the winters of 2018, 2019, and 2020.

Winter Season	Temperature (°C)							
	January		February		March		April	
	Max	Min	Max	Min	Max	Min	Max	Min
2018	-7.7	-18.3	-2.1	-15.2	1.6	-7.1	5.5	-4
2019	-8.2	-19	-6.2	-18.7	-0.2	-12.7	6.2	-1.6
2020	-4.5	-13.2	-3.2	-17.1	1.8	-8.6	7.1	-2.8

Table 1-2 : Ground snow accumulation data report for the winters of 2018, 2019, and 2020.

Winter Season	Snow on the ground (cm)							
	January		February		March		April	
	Max	Min	Max	Min	Max	Min	Max	Min
2018	67	24	81	58	80	48	56	2
2019	79	35	105	64	105	70	71	7
2020	49	14	76	47	85	61	64	0

Based on the texture of the false-color RGB image (R = 1500nm, G = 1300nm, B = 1200nm), it was possible to distinguish the different homogeneous layers of snow (Figure 1-8b). Layers estimated to be heterogeneous were removed from the initial database. The samples removed were those with a standard deviation (std) greater than 0.15 of the spectral reflectance, such as presented in Figure 1-9. In total, 5 layers were removed. A high std reflect a heterogeneity in the composition snow structure of the correspond layer due to presence of large air pockets which could lead to classification uncertainties. The mean spectral reflectance of each retained layer (Figure 1-8c), and the corresponding physical characteristics (Figure 1-8a) were measured. It can be observed that for a given layer of snow and between 900 nm and 1400 nm, the highest spectral reflectance values are generally observed for the largest physical characteristics (density, grain size and grain type (Figure 1-8c)).

Figure 1-10 shows the spectral reflectance (114 samples) of the homogeneous layers of the snowpack's vertical profile sampled in winters 2018, 2019, and 2020. It can be seen in Figure 1-10 that the spectra share the same shape but have different amplitudes (reflectance values). All spectra show a similar spectral behaviour in the 1400-1700 nm bands, rendering band separation difficult. However, it is possible to detect a small difference between certain spectral bands, such as in the 1000-1100 nm and 1200-1300 nm bands, in which different groups of snow with close or homogeneous physical characteristics can be distinguished.

Table 1-3 : Distribution of snow density in terms of type and size of snow grains (field data: 2018, 2019 and 2020), with their corresponding symbologies. (PP) Precipitation particles; (DF) Decomposing and fragmented precipitation particles; (RG) Rounded grains; (FC) Faceted crystals; (DH) Depth hoar (goblets); (MF) Melt Forms. The different shades of gray show the levels of metamorphosis (low, moderate, high) of each recuperated snow layer.

Grain type	Grain size	Number of samples	Density (kg m <sup>-3</sup> )									
			< 100	100 - 150	150 - 200	200 - 250	250 - 300	300 - 350	350 - 400	400 - 450	450 - 500	> 500
+ (PP)	< 1 mm	9										
λ (DF)	< 1 mm	10										
□ (FC)	1-2 mm	25										
• (RG)	1-2 mm	35										
^ (DH)	> 2 mm	16										
° (MF)	> 2 mm	20										

These spectral reflectance values show that the reflectance changes throughout the wavelength regions as snow ages (Horton & Jamieson, 2017; Negi *et al.*, 2010). Indeed, snow samples that are newly deposited on the snowpack (precipitation particles, decomposing, and fragmented precipitation particles) and that have a low to medium density (between 50-200 kg m<sup>-3</sup>) had higher reflectance values. On the other hand, samples of metamorphosed snow (goblets and melt forms) had lower reflectance values and very high density snow samples (400-600 kg m<sup>-3</sup>). Samples with medium to high density (150-450 kg m<sup>-3</sup>) and moderately metamorphosed (rounded grains and faceted crystals) had intermediate reflectance values.

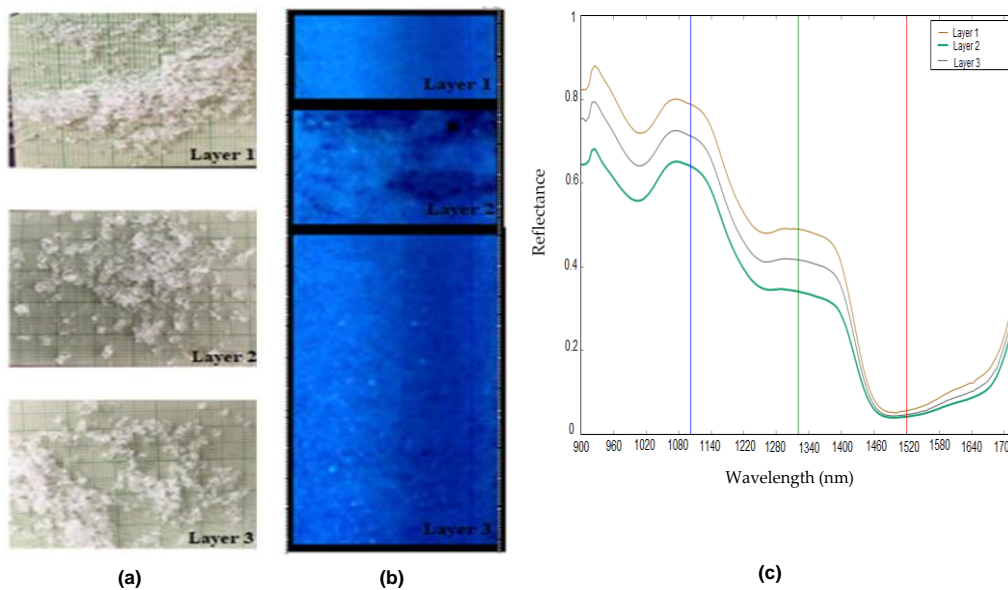


Figure 1-8 : (a) Snow grains of each layer of the vertical stratigraphy; (b) false-color RGB image; (c) NIR spectral reflectance of each layer of the vertical stratigraphy (the red, green, and blue vertical lines in the spectral plot show the location of the bands used to generate the false-color RGB image).

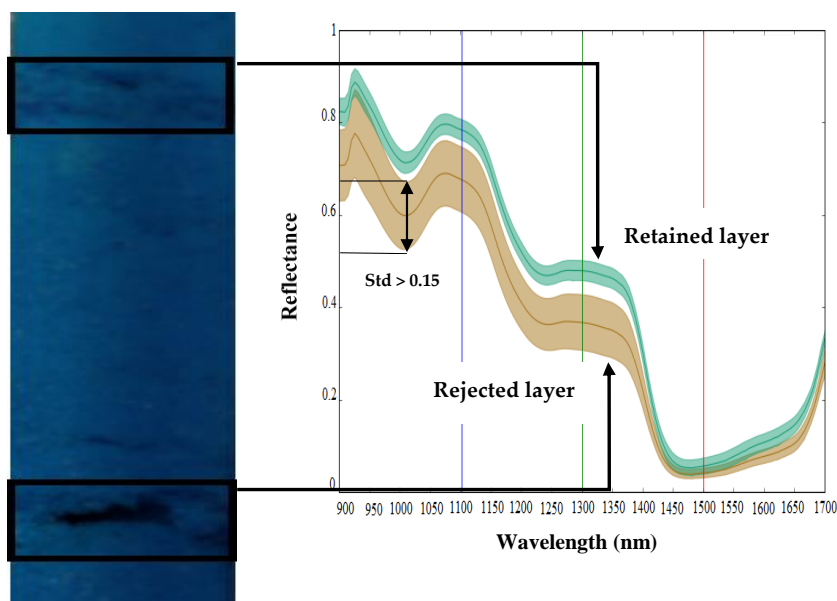


Figure 1-9 : Snow layer retained (homogeneous), snow layer rejected (heterogeneous).






Figure 1-10 : NIR spectral reflectance values of different homogeneous snow layers.

### 3.2 Visualization and Reduction of Spectral Dimensionality by Principal Components Analysis

A PCA was carried out on all spectral data. The first two principal components (PC) obtained were used to generate a score diagram, as they represented more than 96% of the variance of the spectral data. Figure 1-11 shows the score plot for PC1 and PC2, which seem to provide the best distinction between homogeneous snow groups in terms of grain type and size. Initially, the PCA was used to reduce the information recorded by the 148 spectral bands into two components so that it would be possible to project them onto a 2D score plot. Six snow groups can be distinguished (colored dots in Figure 1-11). None of these snow classes or snow groups can be considered atypical or aberrant.




Figure 1-11 : Score plot for PC1 and PC2 of spectral reflectance values. The cut-off bold lines help to visually distinguish among the snow classes in terms of metamorphosis degree (weakly, moderately, strongly metamorphosed snow).



The physical properties of snow of the same species were grouped together in each region of the PC1–PC2 space. Differences between most classes were pronounced and some snow types were mixed, such as rounded grains and faceted grains, which have not been clearly separated. This could be related to a similar grain size or shape. In short, PC1 and PC2 provide a good picture of the discrimination for the different physical characteristics of each snowpack. This implies that it is possible to optically classify snow layers based on their physical properties. Therefore, the score plot has the advantage of displaying information on sample groupings based on their physical characteristics and the degree of transformation or metamorphosis undergone by the snowpack.

Great similarities exist between the visualization of spectral data by PCA (optical data) (Figure 1-11) and the snow metamorphosis cycle formerly presented by Pahaut (1975). The origin of these snow groupings based on physical properties lie in the metamorphic processes undergone by snow grains after being deposited on top and incorporated into the snowpack, which continuously influence the snow's spectral response. These processes operate in different ways depending on temperature, temperature gradient, and the amount of water in the snow (Pahaut, 1975). Like other natural systems, the snowpack not only displays extreme examples of the phenomenon, but also intermediate stages and conditions of metamorphism. Metamorphism is the dominant factor in the physical evolution of the snow cover and it affects its stability (e.g., avalanche) and chemical composition. Consequently, detailed studies of the reflectance related to each physical attribute could lead to an important revolution in optical measurements.

The coefficients (Coeff) of the first PCA component were afterwards used to reduce the number of spectral bands on which the unsupervised classification model (HAC) was based; only bands with a Coeff greater than 0.085 were kept (above the red line from 900 to 1400 nm in Figure 1-12). HAC-based results were thereafter challenged using the corresponding field data for assessing the classification accuracy using the confusion matrix technique.




Figure 1-12. The coefficients of PC1 as a function of wavelengths.

### 3.3 Unsupervised Spectral Reflectance Classification

According to the results of the PCA (Figure 1-11), it was found that spectral reflectance values can be preferably grouped into three distinct groups according to their spectral properties that reflect their physical compositions. The cut-offs (bold lines) were established between lightly metamorphosed snow (PP and DF), moderately metamorphosed snow (RG and FC), and strongly metamorphosed snow (DH and MF) (Figure 1-11). Admittedly, some misclassification remains between the spectra of certain classes, but this remains limited. This result is explained by the fact that the physical properties of these two groups of snow have undergone a very similar degree of metamorphosis, resulting in similar grain sizes and shapes.

The classification was carried out using all the wavelengths constituting the spectral range from 900 nm to 1400 nm in order to focus the classification only on those bands that are most sensitive to changes in the size and type of snow grains undergone by the different types of metamorphism. The classification is ascending and hierarchical, as it produces increasingly larger classes or groups of snow, including subgroups (Figure 1-13). According to the resulting dendrogram, the snow classes have been separated at a relative distance of 6.29 (cut-off height (CH)), which produces the desired partition of three snow classes, corresponding to three degrees of snow metamorphosis (Figure 1-13).




Figure 1-13 Dendrogram obtained using a hierarchical ascending classification; CH—cut-off height; C1—weakly metamorphosed, C2—moderately metamorphosed, and C3—strongly metamorphosed.

Figure 1-14 shows the reflectance spectra of snow samples with different grain size and density ranges after the HAC. The three snow classes show separability in the 1000–1050 nm, 1150–1200, and 1350–1400 band ranges. As a result, the unsupervised HAC classification confirmed the results of the PCA (Figure 1-11), highlighting the spectral ranges where the three snow classes are most efficiently separated. The effect of the physical properties of snow on spectral reflectance can be

explained by the negative relationship existing between the physical data and the optical properties of snow. This can be useful for the development of a model estimating the physical parameters of snow, such as the density. The result of the HAC classification led to a good differentiation between snowpack classes based only on optical data. By comparing Figure 1-15 and Figure 1-17, which respectively correspond to weakly, moderately, and strongly metamorphosed snow, a morphological evolution of snow grain shapes and sizes can be observed. The classification method used is based on the continuous evolution of the physical characteristics of snow, and thus on the consequences of certain metamorphosis processes (destructive or constructive) (Pahaut, 1975), which place greater emphasis on the causes that provoke these different grain shapes (gradient or isothermal metamorphoses). Snow on the ground is not inert over time. From the moment it is deposited, it is subject to the combined effects of several factors, the most decisive of which are meteorological conditions (Armstrong & Brun, 2008). Snow grains evolve after being deposited, and snow crystals change from their original form (fresh or recent snow) to granular forms (evolved snow or old snow). This sequence of continuous transformation and metamorphosis continues until the snow disappears during melting.




Figure 1-14 : The near-infrared spectral reflectance values of the three snow classes.




Figure 1-15 : Snow grains from the weakly metamorphosed class.




Figure 1-16 : Snow grains from the moderately metamorphosed class.






Figure 1-17 : Snow grains from the strongly metamorphosed class.

### 3.4 Method Assessment Using a Confusion Matrix

Classification performance was evaluated using a confusion matrix based on field data and corresponding optical data. Table 1-4 presents the results of the confusion matrix for the snow classes. The moderately metamorphosed snow class obtained the best result, followed by the strongly metamorphosed snow class and the weakly metamorphosed snow class, with respective commission errors of 10%, 19%, and 21%. Commission and omission errors were significantly higher for the weakly metamorphosed class than for the moderately and strongly metamorphosed classes. Misclassification usually occurs at the extreme of each class (in the weakly–moderately and moderately–strongly class areas). In other words, the error due to in situ data sampling introduced various levels of uncertainty into the field database, which has inevitably affected the precision. These uncertainties are related to the sampling method used, especially when recovering layers of weakly metamorphosed snow. These are the most likely to have affected the accuracy of the values in the measured database, and therefore affect the ability to correctly classify snow samples. Despite the above limitations, the performance of the classification was very acceptable (kappa index = 0.75 and overall success = 0.85%).

Table 1-4. Confusion matrix results; C1—weakly metamorphosed, C2—moderately metamorphosed, C3—strongly metamorphosed.

		Observed				Commission error (%)	Success rate (%)
		C1	C2	C3	Total		
Estimated	C1	15	3	1	19	21%	83
	C2	3	52	3	58	10%	90
	C3	3	4	30	37	19%	81
	Total	21	59	34	114	-	-
	Error omission (%)	29	12	12	-	-	-
	Success rate (%)	71	88	88	-	-	-
	Global success (%)	-	-	-	-	-	0.85
	Kappa Index	-	-	-	-	-	0.75

#### 4. Conclusions

In this work, a hyperspectral imaging system in the NIR spectrum was used to discriminate and classify the snow layers of the vertical profile of the seasonal snowpack according to their physical properties. An unsupervised classification (HAC) analysis was performed based on the reflectance spectra of different snow varieties. The confusion matrix indicated acceptable performance of the data classification, with a global success of 85%. This showcases the potential of NIR hyperspectral imagery for selecting snow classes based on their spectral data. The proposed approach has proven to be an appropriate and effective method for distinguishing snow classes.

The results highlight the fact that hyperspectral NIR imaging between 900 nm and 1400 nm could be used to classify snow samples, even without any prior knowledge of physical properties. Multivariate statistical analysis techniques such as PCA and HAC have the advantages of being objective, rapid, and non-destructive techniques for the authentication and classification of snow on the ground. The distinctive spectral difference between snow grades could be explained in various wavelengths in the NIR range of the spectrum, since they are related to water and other physical and chemical components. However, we recommend that this method be tested on a wide variety of sites presenting a wide range of snowpacks (low vs. high altitude, close vs. open environments, coastal vs. continental conditions, etc.) in order to validate its robustness further, and if necessary, recalibrate it using these additional observations for better accuracy.

The main limitations associated with this method are the smaller number of layers in the weakly metamorphosed class, as well as homogeneous snow layer identification on the acquired hyperspectral image. The first constraint is due to the difficulty of isolating this type of layer, because weakly metamorphosed snow is very light and often thin. The second constraint could be overcome by validating the homogeneous snow layers on a field sampler before starting the optical processing. Additional studies are needed in this direction to eradicate these drawbacks and eventually lead to field implementation. In general, the results demonstrated by recent works have shown that this technology meets the scientific need for a fast and accurate classification method for discriminating snow samples on the ground, and furthermore, to estimate the physical characteristics of snow.

The contribution of this work is to present a rapid and non-destructive approach to discriminate between different types of snow on the ground that could be used in the near future. At present, there is no method that uses optical analysis for discriminating these varieties. The procedure proposed herein opens the window for the subsequent introduction of cheaper multi-spectral or hyperspectral NIR instruments that could be used for the desired application.

**Author Contributions:** Conceptualization, M.K.E.O. and K.C.; methodology, M.K.E.O. and K.C.; writing—original draft preparation, M.K.E.O.; writing—review and editing, M.K.E.O., A.E.A. and M.B.; visualization, H.A.; supervision, K.C. and A.E.A. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** Not applicable.

**Acknowledgments:** Many people reviewed and commented on the drafts of this document. The comments of Anas El Alem, Monique Bernier, and Hachem Agili were particularly appreciated. Karem Chokmani's encouragements were very helpful, as was his valuable guidance. The preparation of this manuscript; the retrieval, measurement, and photography of snow profiles; and the work on snow metamorphism have been supported over the years in developing this work. Many thanks to Sophie Roberge and David Ethier for their efficient coordination of the field campaign. Thanks also to Jimmy Poulin and Rachid Lhissou for their help and suggestions.

**Conflicts of Interest:** The authors declare that they are submitting the manuscript to the journal without any known conflict of interest.

## 5. REFERENCES

- Armstrong RL & Brun E (2008) *Snow and Climate: Physical Processes, Surface Energy Exchange and Modeling*. Cambridge University Press,
- Berger K, Wang Z, Danner M, Woche M, Mauser W & Hank T (2018) Simulation of Spaceborne Hyperspectral Remote Sensing to Assist Crop Nitrogen Content Monitoring in Agricultural Crops. *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, p 3801-3804.
- Bohren CF & Beschta RL (1979) Snowpack albedo and snow density. *Cold Regions Science and Technology* 1(1):47-50.
- Caporaso N, Whitworth MB & Fisk ID (2018) Near-Infrared spectroscopy and hyperspectral imaging for non-destructive quality assessment of cereal grains. *Applied Spectroscopy Reviews* 53(8):667-687.
- Chauchard F, Cogdill R, Roussel S, Roger J & Bellon-Maurel V (2004) Application of LS-SVM to non-linear phenomena in NIR spectroscopy: development of a robust and portable sensor for acidity prediction in grapes. *Chemometrics and Intelligent Laboratory Systems* 71(2):141-150.
- Cohen J (1960) A coefficient of agreement for nominal scales. *Educational and psychological measurement* 20(1):37-46.
- Colbeck S (1982) An overview of seasonal snow metamorphism. *Reviews of Geophysics* 20(1):45-61.
- Colbeck S (1983) Theory of metamorphism of dry snow. *Journal of Geophysical Research: Oceans* 88(C9):5475-5482.
- Colbeck S (1986) Classification of seasonal snow cover crystals. *Water Resources Research* 22(9S):59S-70S.
- Colbeck SC (1985) *The international classification for seasonal snow on the ground*. Internat. Commission on Snow and Ice of the International Association of ...,
- Cubero S, Aleixos N, Moltó E, Gómez-Sanchis J & Blasco J (2011) Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables. *Food and bioprocess technology* 4(4):487-504.
- Dominé F, Cabanes A, Taillandier A-S & Legagneux L (2001) Specific surface area of snow samples determined by CH<sub>4</sub> adsorption at 77 K and estimated by optical microscopy and scanning electron microscopy. *Environmental science & technology* 35(4):771-780.
- Dominé F, Lauzier T, Cabanes A, Legagneux L, Kuhs WF, Techmer K & Heinrichs T (2003) Snow metamorphism as revealed by scanning electron microscopy. *Microscopy research and technique* 62(1):33-48.



- Donahue C, Skiles SM & Hammonds K (2021) In situ effective snow grain size mapping using a compact hyperspectral imager. *Journal of Glaciology* 67(261):49-57.
- Dozier J (1989) Spectral signature of alpine snow cover from the Landsat Thematic Mapper. *Remote sensing of environment* 28:9-22.
- Eppanapelli LK, Lintzén N, Casselgren J & Wåhlin J (2018) Estimation of Liquid Water Content of Snow Surface by Spectral Reflectance. *Journal of Cold Regions Engineering* 32(1):05018001.
- Fierz C, Armstrong RL, Durand Y, Etchevers P, Greene E, McClung DM, Nishimura K, Satyawali PK & Sokratov SA (2009) *The international classification for seasonal snow on the ground*. UNESCO/IHP Paris,
- Fierz C & Baunach T (2000) Quantifying grain-shape changes in snow subjected to large temperature gradients. *Annals of Glaciology* 31:439-444.
- Flin F, Brzoska J-B, Lesaffre B, Coléou C & Pieritz RA (2004) Three-dimensional geometric measurements of snow microstructural evolution under isothermal conditions. *Annals of glaciology* 38:39-44.
- Gallet J-C, Domine F, Zender C & Picard G (2009) Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm. *The Cryosphere* 3(2).
- Gergely M, Wolfsperger F & Schneebeli M (2013) Simulation and validation of the InfraSnow: an instrument to measure snow optically equivalent grain size. *IEEE transactions on geoscience and remote sensing* 52(7):4236-4247.
- Gray DM & Male DH (1981) *Handbook of snow: principles, processes, management & use*. Pergamon,
- Gubler H (1985) Model for dry snow metamorphism by interparticle vapor flux. *Journal of Geophysical Research: Atmospheres* 90(D5):8081-8092.
- Haq MA, Ghosh A, Rahaman G & Baral P (2019) Artificial neural network-based modeling of snow properties using field data and hyperspectral imagery. *Natural Resource Modeling* 32(4):e12229.
- Hoff JT, Gregor D, Mackay D, Wania F & Jia CQ (1998) Measurement of the specific surface area of snow with the nitrogen adsorption technique. *Environmental science & technology* 32(1):58-62.
- Horton S & Jamieson B (2017) Spectral measurements of surface hoar crystals. *Journal of Glaciology* 63(239):477-486.
- Jambu M & Lebeaux M-O (1978) *Classification automatique pour l'analyse des données*. Dunod Paris,
- Jamieson B & Johnston CD (2001) Evaluation of the shear frame test for weak snowpack layers. *Annals of Glaciology* 32:59-69.

- Karimi Y, Maftoonazad N, Ramaswamy HS, Prasher SO & Marcotte M (2012) Application of hyperspectral technique for color classification avocados subjected to different treatments. *Food and bioprocess technology* 5(1):252-264.
- Kinar N & Pomeroy J (2015) Measurement of the physical properties of the snowpack. *Reviews of Geophysics* 53(2):481-544.
- Kulkarni A, Srinivasulu J, Manjul S & Mathur P (2002) Field based spectral reflectance studies to develop NDSI method for snow cover monitoring. *Journal of the Indian Society of Remote Sensing* 30(1-2):73-80.
- Langlois A, Royer A, Montpetit B, Picard G, Brucker L, Arnaud L, Harvey-Collard P, Fily M & Goïta K (2010) On the relationship between snow grain morphology and in-situ near infrared calibrated reflectance photographs. *Cold Regions Science and Technology* 61(1):34-42.
- Libois Q (2014) *Evolution des propriétés physiques de neige de surface sur le plateau Antarctique. Observations et modélisation du transfert radiatif et du métamorphisme.* (Grenoble).
- Marbouty D (1984) Les propriétés physiques de la neige. *La houille blanche* (8):557-567.
- Marsh P (1991) Water flux in melting snow covers. In-Advances in Porous Media, Vol. 1. MY Corapcioglu. *Elsevier, Amsterdam* 6:1-124.
- Matzl M & Schneebeli M (2006) *Measuring specific surface area of snow by near-infrared photography.*
- Negi H, Singh S, Kulkarni A & Semwal B (2010) Field-based spectral reflectance measurements of seasonal snow cover in the Indian Himalaya. *International Journal of Remote Sensing* 31(9):2393-2417.
- Nolin AW & Dozier J (2000) A hyperspectral method for remotely sensing the grain size of snow. *Remote sensing of Environment* 74(2):207-216.
- Osborne BG (2006) Near-infrared spectroscopy in food analysis. *Encyclopedia of analytical chemistry: applications, theory and instrumentation.*
- Pahaut E (1975) *Les Cristaux de neige et leurs métamorphoses.* Direction de la Météorologie nationale,
- Painter TH, Molotch NP, Cassidy M, Flanner M & Steffen K (2007) Contact spectroscopy for determination of stratigraphy of snow optical grain size. *Journal of Glaciology* 53(180):121-127.
- Park B, Chen Y-R, Hruschka WR, Shackelford SD & Koohmaraie M (2001) Principal component regression of near-infrared reflectance spectra for beef tenderness prediction. *TRANSACTIONS-AMERICAN SOCIETY OF AGRICULTURAL ENGINEERS* 44(3):609-616.
- Pope A & Rees WG (2014) Impact of spatial, spectral, and radiometric properties of multispectral imagers on glacier surface classification. *Remote Sensing of Environment* 141:1-13.
- Randriamihamison N, Neuvial P & Vialaneix N (2019) Classification ascendante hiérarchique, contrainte d'ordre: conditions d'applicabilité, interprétabilité des dendrogrammes.

- Roggo Y, Edmond A, Chalus P & Ulmschneider M (2005) Infrared hyperspectral imaging for qualitative analysis of pharmaceutical solid forms. *Analytica Chimica Acta* 535(1-2):79-87.
- Schneebeli M & Sokratov SA (2004) Tomography of temperature gradient metamorphism of snow and associated changes in heat conductivity. *Hydrological Processes* 18(18):3655-3665.
- Schweizer J & Jamieson J (2001) Snow cover properties for skier triggering of avalanches. *Cold Regions Science and Technology* 33(2-3):207-221.
- Taillandier AS, Domine F, Simpson WR, Sturm M & Douglas TA (2007) Rate of decrease of the specific surface area of dry snow: Isothermal and temperature gradient conditions. *Journal of Geophysical Research: Earth Surface* 112(F3).
- Vander Jagt B, Lucieer A, Wallace L, Turner D & Durand M (2015) Snow depth retrieval with UAS using photogrammetric techniques. *Geosciences* 5(3):264-285.
- Warren SG & Brandt RE (2008) Optical constants of ice from the ultraviolet to the microwave: A revised compilation. *Journal of Geophysical Research: Atmospheres* 113(D14).
- Warren SG & Wiscombe WJ (1980) A model for the spectral albedo of snow. II: Snow containing atmospheric aerosols. *Journal of the Atmospheric Sciences* 37(12):2734-2745.
- Wold S, Esbensen K & Geladi P (1987) Principal component analysis. *Chemometrics and intelligent laboratory systems* 2(1-3):37-52.
- Zuanon N (2013) IceCube, a portable and reliable instruments for snow specific surface area measurement in the field. *International Snow Science Workshop Grenoble-Chamonix Mont-Blance-2013 proceedings*. p 1020-1023.



## Avant-propos

Cet article a été publié dans le journal *Remote Sensing* du *MDPI*. Les co-auteurs qui ont participé à la rédaction de ce manuscrit sont :

### **1. Mohamed Karim El Oufir :**

Responsable de la conception de recherches, la méthodologie, prétraitements et traitements des données, le développement des modèles mathématiques, l'analyse et l'interprétation des résultats et à la rédaction du manuscrit.

### **2. Karem Chokmani :**

Responsable également de la conception de recherches et a contribué à l'édition, l'analyse, et à l'examen du manuscrit.

### **3. Anas El Alem :**

Responsable également de la conception de recherches et a contribué à l'édition, responsable des interprétations mathématiques et statistiques, et à l'examen du manuscrit.

### **5. Monique Bernier**

Responsable à la révision du manuscrit.



## Abstract

Improving the estimation of snow density is a key task in current snow research. Characterization of the variability of density in time and space is essential for the estimation of water equivalent, hydroelectric power production, assessment of natural hazards (avalanches, floods, etc.). Hyperspectral imaging is proving to be a promising and reliable tool for monitoring and estimating this physical property. Indeed, the spectral reflectance of snow is partly controlled by changes in its physical properties, particularly in the near-infrared (NIR) part of the spectrum. For this purpose, several models have been designed to estimate snow density from spectral information. However, none has yet achieved significant performance. One of the major difficulties is that the relationship between snow density and spectral reflectance is non-bijective (surjective). Indeed, several reflectance amplitudes can be associated with the same density and vice versa, so the correlation between density and spectral reflectance can be very poor. To resolve this issue, a hybrid snow density estimation model based on spectral data is proposed in this work. The principle behind this model is to classify the snow density prior to its estimation by means of a specific estimator corresponding to a predetermined snow density class. These additional steps eliminate the surjective relation by converting it into three bijective relations between density and spectral reflectance. The calibration step showed that the densities included within the three classes are sensitive to different spectral regions, with  $R^2 > 0.80$ . The results of the cross-validation for the specific estimators were also satisfactory with  $R^2 > 0.78$  and  $RMSE < 36.36 \text{ kg m}^{-3}$ . The overall performance of the hybrid model (HM), when tested with independent data, demonstrated the effectiveness of using proximal NIR hyperspectral imagery to estimate snow density ( $R^2 = 0.88$  and  $NASH = 0.88$ ).

**Keywords:** snowpack; snow density; spectral reflectance; near-infrared; hybrid model; Hyperspectral imagery

## Résumé

Les méthodes traditionnelles de mesure utilisées pour surveiller les propriétés physiques de la neige sont longues et laborieuses, notamment la densité. Or, il est essentiel de surveiller les changements de densité de la couverture neigeuse pour l'estimation de l'équivalent en eau et les prévisions d'avalanches. L'imagerie hyperspectrale s'avère être un outil prometteur et fiable pour surveiller et estimer cette propriété physique. En effet, la réflectance spectrale de la neige est en partie contrôlée par les changements de ses propriétés physiques, notamment dans la partie proche infrarouge (PIR) du spectre. Dans ce but, plusieurs modèles ont été conçus pour estimer la densité de la neige à partir d'informations spectrales. Cependant, aucun n'a encore atteint des performances significatives. L'une des principales difficultés est que la relation entre la densité de la neige et la réflectance spectrale est non bijective (surjective). En effet, plusieurs amplitudes de réflectance peuvent être associées à une même densité et vice versa, de sorte que la corrélation entre la densité et la réflectance spectrale peut être très faible. Pour résoudre ce problème, un modèle hybride (MH) d'estimation de la densité de la neige basé sur les données spectrales est proposé dans ce travail. Le principe de ce modèle est de classer la densité de la neige avant son estimation au moyen d'un estimateur spécifique correspondant à une classe de densité de neige prédéterminée. Ces étapes supplémentaires permettent d'éliminer la relation surjective en la convertissant en trois relations bijectives entre la densité et la réflectance spectrale. L'étape de calibration a montré que les densités incluses dans les trois classes sont sensibles à différentes régions spectrales, avec  $R^2 > 0,80$ . Les résultats de la validation croisée pour les estimateurs spécifiques étaient également satisfaisants avec  $R^2 > 0,78$  et  $RMSE < 36,36$ . La performance globale du modèle hybride, lorsqu'il a été testé avec des données indépendantes, a démontré l'efficacité de l'utilisation de l'imagerie hyperspectrale PIR pour estimer la densité de la neige ( $R^2 = 0,88$  et  $NASH = 0,88$ ).

**Mots clés** : manteau neigeux; densité de la neige; réflectance spectrale; proche infrarouge; modèle hybride; imagerie hyperspectrale



## 2 DEUXIÈME ARTICLE: ESTIMATING SNOWPACK DENSITY FROM NEAR- INFRARED SPECTRAL REFLECTANCE USING A HYBRID MODEL

---

Mohamed Karim El Oufir\*, Karem Chokmani, Anas El Alem, and Monique Bernier

Citation : El Oufir, M.K.; Chokmani, K.; El Alem, A.; Bernier, M.

<https://doi.org/10.3390/rs13204089>

Received: 5 August 2021; Accepted: 7 October 2021; Published: 13 October 2021

Institut National de la Recherche Scientifique (INRS), Québec, QC G1K 9A9, Canada;

[karem.chokmani@ete.inrs.ca](mailto:karem.chokmani@ete.inrs.ca) (K.C.)

[anas.el\\_alem@ete.inrs.ca](mailto:anas.el_alem@ete.inrs.ca) (A.E.A.)

[monique.bernier@ete.inrs.ca](mailto:monique.bernier@ete.inrs.ca) (M.B.)

\* Correspondence: [mohamed\\_karim.el\\_oufir@ete.inrs.ca](mailto:mohamed_karim.el_oufir@ete.inrs.ca); Tel.: +1-418-264-1950

Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland.



## 1. Introduction

The spatiotemporal evolution of seasonal snowpack's is an important indicator of climate (Kropacek *et al.*, 2010). The measurement, monitoring, and management of this water resource are of great interest to governments and the scientific community. Snow cover is the set of snow layers that accumulate on the ground throughout the winter (Marbouty, 1984). Each of these layers has a given density. Quantifying the variability of density in time and space is essential for estimating the water equivalent (Davis *et al.*, 1999; Fassnacht *et al.*, 2001), hydroelectric power production (Brown & Armstrong, 2008; Dutra *et al.*, 2012), and assessing natural hazards (avalanches, floods, etc.) (Castebrunet *et al.*, 2014; Lehning *et al.*, 1999). Indeed, this variable varies with changes in other physical properties such as grain size, grain shape, and liquid water content during the metamorphic transformation of the snowpack (Langham, 1981). The density of newly deposited snow is expected to have the lowest values and to increase and reach its highest values during the maturation phase. According to Pomeroy *et al.* (Pomeroy *et al.*, 2001), the typical seasonal density of the snowpack ranges between  $80 \text{ kg m}^{-3}$  and  $600 \text{ kg m}^{-3}$ .

For a country like Canada, which covers a very large area with a vast expanse of snow cover, regular monitoring of snow density is important (Roy *et al.*, 2004; Sturm *et al.*, 2010). The density is measured using a variety of methods and technologies. These include manual measurements by taking core samples from the snowpack (such as 'federal' snow tubes, e.g., ESC-30) (Farnes *et al.*, 1980), or the installation of devices that lie flat on the ground and weigh the snow as it accumulates on top (such as snow pillows) (Farnes, 1967; Kinar & Pomeroy, 2015). However, each of these methods has several drawbacks (Kinar & Pomeroy, 2015; Zuanon, 2013). Snow core measurements are labor intensive, time-consuming, not feasible for 24-h data collection, and subject to human error. Snow pillows have measurement errors, logistical and transport problems for their installation, and can only measure an area of about  $10 \text{ m}^2$  (Kinar & Pomeroy, 2015). There are also other methods for measuring snow density, including proximal remote sensing (such as the GMON (GammaMONitor) snow water equivalent probe (Campbell Scientific Canada, Edmonton, Alberta)) (Wright *et al.*, 2011), spatial remote sensing (microwave remote sensing) (Cui *et al.*, 2016). However, these methods have some drawbacks; for example, they do not measure the density of each snow layer that makes up the vertical stratigraphy of the snowpack, but only the average density of the snowpack. Recently, optical sensor data have been used as an alternative to monitor snow cover over large areas and have led to improved monitoring and management of this water resource (Negi *et al.*, 2013). To optimize the modeling process of the physical properties of snow and to develop new efficient models, a high spectral resolution is essential (Gergely *et al.*, 2010).

Hyperspectral imaging technology is an innovative approach based on spectroscopic analyses. It is fast, non-invasive, and facilitates real-time measurements (Chauchard *et al.*, 2004; Osborne, 2006), which can be used in conjunction with traditional measurement methods. This technology has proven

to be effective for field, laboratory, and industrial applications (Gallet, 2010; Lu & Fei, 2014). It provides detailed information about the physical and chemical components of a scanned sample due to its high spectral and temporal resolution (ElMasry *et al.*, 2012; Lorente *et al.*, 2012; Lu & Fei, 2014). It has already been demonstrated that the near-infrared (NIR) spectrum is sensitive to the physical parameters of snow (Haq *et al.*, 2019; Kulkarni *et al.*, 2002; Negi *et al.*, 2010b; Nolin & Dozier, 2000). In fact, snow granulometry is clearly visible in the NIR and the short waves of infrared regions (SWIR) (Dozier, 1989; Warren & Wiscombe, 1980). Eppanapelli *et al.* (2018) found that the spectral reflectance of snow in the NIR is inversely proportional to the liquid water content in the snow. In addition, the absorption of ice in the NIR is very high (Warren & Brandt, 2008), so the effect of impurities such as mineral dust and soot is negligible beyond 1000 nm wavelength. The above findings highlight the potential of hyperspectral NIR data to gather information on the physical properties of snow for modeling purposes (Dozier & Painter, 2004).

Indeed, several models and approaches designed to model snow density based on spectral data are now available, but none has yet achieved a satisfactory performance (Domine *et al.*, 2007; Li *et al.*, 2016). This is probably due to the fact that most models are based on the assumption that density measurements can be modeled using the same function. Even though the spectral reflectance of snow in the NIR depends on density, it is expressed by the size and shape of the grains (granulometry) and the liquid water content in the snow (Bohren & Beschta, 1979). Consequently, the optical properties of the physical parameters of snow influence one another and create a non-bijective (surjective (In mathematics, a surjective function (also known as surjection, or onto function) is a function  $f$  that maps an element  $x$  to every element  $y$ ; that is, for every  $y$ , there is an  $x$  such that  $f(x) = y$ .) relationship between snow density and reflectance in the NIR, resulting in poor correlations.

Recently, it has been demonstrated that three optical classes of snow with different degrees of metamorphosis (weakly to moderately metamorphosed (WMM), moderately to highly metamorphosed (MHM), and highly to very highly metamorphosed (HVM)) can be identified and discriminated against without prior recognition, based only on NIR hyperspectral data (El Oufir *et al.*, 2021). This study showed that the spectra of snow density are similar within the same optical class and significantly different from one optical class to another. In other words, densities expressed in terms of grain size, shape, and spectral response were discriminated and grouped into three different homogeneous subclasses (El Oufir *et al.*, 2021). With this finding, it is possible to train estimators specific to the identified homogeneous classes, which are governed by a bijective (In mathematics, a bijection, bijective function, one-to-one correspondence, or invertible function, is a function between the elements of two sets, where each element of one set is paired with exactly one element of the other set, and each element of the other set is paired with exactly one element of the first set. There are no unpaired elements.) relation between the density and the hyperspectral NIR reflectance.

The objective of this study is to develop a hybrid model (HM) to estimate the snow density using proximal NIR hyperspectral data. The HM is a combination of a classifier and specific estimators

associated with three density classes (WMM, MHM, and HVM). The HM was calibrated and validated using a data set collected from a sampling site located in Quebec City, Canada. The performance of the HM was assessed using the leave-one-out cross-validation technique and independent validation data using a systematic data splitting technique. Four statistical evaluation indices (the coefficient of determination ( $R^2$ ), root mean square error (RMSE), the bias (BIAS), and Nash-criterion (NASH)) were used to assess the model's performance.

## 2. Materials and Methods

### 2.1 Study area

An extensive field campaign was conducted during the winter of 2018 (19 January-27 March), 2019 (10 January-3 April), and 2020 (29 January-10 March). The sampling zone is located in Quebec City (Canada) on the premises of INRS's (National Institute of Scientific Research) technology park (46°47'43.22" north latitude and -71°18'10" west longitude; Figure 2-1). An open area of approximately 20 m × 5 m located in a hardwood forest was selected as a sampling site. Measurements were collected in the morning between 8:00 a.m. and 12:00 p.m. on sunny and windless days. The climate in Quebec City is characterized by winter temperatures ranging between -10 °C and -25 °C, with significant snow accumulation. The snowpack in this region is dry from January to mid-February due to low temperatures and becomes wet in March as air temperature, day length, and radiation increase.




Figure 2-1 : Geographic location of the sampling area in the technology park in Quebec City, Canada.

## 2.2 In situ data collection

Two types of instruments were used to generate the calibration and validation database. Snow samples were collected using a rectangular core sampler designed and built by INRS's remote sensing team (Figure 2-2), and optical properties were measured using a proximal acquisition station (Figure 2-3). The data acquired with these two instruments were collected at the same place and time.



Figure 2-2. Snow core sampler.




Figure 2-3 : Proximal acquisition station from the company RESONON (Resonon Inc., Bozeman, MT, USA).



The rectangular core sampler (or corer) was used to extract the vertical stratigraphy of the snowpack (Figure 2-4a). The corer is composed of a metallic inner component and a plastic cover with a triangular sawtooth cutting part at the end. This design allows the extraction of the vertical profile of the snowpack with all its metamorphosed variants and no loss of snow (Figure 2-4b). The corer is graduated to measure the height (cm) of the profile and to differentiate the homogeneous layers composing the vertical profile.




Figure 2-4 : (a) Snow pit after profile extraction; (b) The vertical profile sampled by the snow corer, winter 2018 (El Oufir *et al.*, 2021).

The proximal acquisition station used in this work is equipped with a hyperspectral camera (PIKA NIR from RESONON Company) boarded on a linear translation plate which allows for fast acquisition of spectral data (Figure 2-3). The camera measures the NIR spectral reflectance for wavelengths between 900 nm and 1700 nm with a spectral resolution of 5.5 nm for 148 spectral bands. The station also contains a halogen lighting system, a mounting tower, a mobile platform, a data acquisition software (Spectronon Pro by Resonon Inc., Bozeman, MT, USA), and proximal acquisition lenses (Figure 2-3).

The snow sample is collected by pushing the corer through the surface of the snowpack until the serrated cutting end reaches the ground. This ensures the recovery of both surface snow and snow from deeper layers (Figure 2-4a). Once the snow is extracted (Figure 2-4b), it is scanned with the NIR hyperspectral camera (Figure 2-5a), and the generated image is analyzed by the Spectronon Pro software (Figure 2-5b) (El Oufir *et al.*, 2021). The latter identifies the homogeneous layers previously measured in the field and analyzes the spectral responses of each one. After this, each homogeneous layer is carefully removed from the corer, and its physical properties are characterized. The layers

are then classified according to the International classification of seasonal ground snow (Fierz *et al.*, 2009). To do so, the size and type of snow grains are identified using a millimeter grid map and observed with a magnifying glass (10×). Finally, the isolated layers are weighed, and the density of each one is calculated (El Oufir *et al.*, 2021). All observations and measurements were performed by the same person to ensure consistency.




Figure 2-5 : (a) Hyperspectral acquisition of a snow sample's vertical profile; (b) false-color RGB image of the spatial transitions of the vertical stratigraphy of the snowpack (El Oufir *et al.*, 2021).

### 2.3 Methodological Approach

The methodological approach adopted is based on three main phases that are summarized in the flow chart illustrated in Figure 2-6:

- ❖ The calibration of the classifier and the specific estimation of the HM

The calibration was carried out in two steps: (1) Development of a machine learning-based algorithms using CART (classification and regression tree) method to discriminate between three different snow classes (WMM, MHM, and HVM) based on the NIR spectral data; The CART algorithm is a tree-based decision process. It uses a training sample set composed of a historical data set with pre-assigned classes for all observations (density in our case) and splitting variables (spectral bands in our case). These decision trees are spectrally based thresholds that are then used to classify new data (Breiman *et al.*, 1984). And (2) Subdivision of the calibration database, based on the previously developed classifier, into three sub-data sets. These sub-data sets were then used to train three specific estimators. For each specific estimator, all possible band ratios were first calculated and correlated



with the snow density values. The correlation coefficients were then stored in a coefficient correlation matrix. The most highly correlated band ratios ( $R^2 > 0.5$ ) were then integrated into a stepwise algorithm to train the calibration function. This exercise was also applied to the band differences and the normalized differences independently. Whether based on ratios, differences, or normalized differences, the spectral index most highly correlated with each specific estimator was retained at the end of the calibration step.

- ❖ Evaluation of the specific estimators using the leave-one-out cross-validation (LOOCV) algorithm (Vehtari *et al.*, 2017);

The specific estimators were assessed using the LOOCV method. This method consists of temporarily removing an entry from the database and using the rest of the database as calibration data, and then estimating the density of the removed measurement. This operation is repeated for the entire database. The main objective of this step was to calculate the relative bias of each specific estimator.

- ❖ HM evaluation using independent data selected using the systematic split validation (SSV) technique.

Firstly, 25% of the data was removed from the initial database prior to the calibration of the MH for independent validation purposes. The validation data were systematically selected (the 4th data entries starting with low to high-density values) and set aside. This technique is known as systematic split validation (SSV). The remaining data (calibration database) was used to train the HM. Finally, to assess the overall accuracy of the HM, the independent dataset (the 25% removed by the SSV technique) was used. It is important to note, however, that it was necessary to go through both calibration steps to accurately assess the MH. Each sample was first assigned to one of three snow classes using the HM classifier. The snow density was then estimated using the specific estimator corresponding to the pre-assigned class.

Four statistical indices were used to assess both the specific estimators and the HM, which are presented in Equations (2-1)–(2-4). These are the coefficient of determination ( $R^2$ ), defined as the squared value of the correlation coefficient, the root means square error (RMSE), the bias (BIAS), and the Nash-criterion (NASH). The NASH criterion (Nash & Sutcliffe, 1970) compares the values estimated by the model to the mean in-situ measurements, yielding a result between  $-\infty$  and 1.0 (inclusive). A negative NASH result means that it would be preferable to use the mean in-situ measurements rather than the model estimates, whereas values between 0.0 and 0.6 are generally considered acceptable levels of model performance. Model performance is satisfactory for values above 0.8, and the model is perfect when  $NASH = 1.0$ . The mathematical equations for these indices are as follows:

$$R^2 = \left[ \frac{\sum_{i=1}^n (M_i - \bar{M})(E_{s_i} - \bar{E}_s)}{\sqrt{\sum_{i=1}^n (M_i - \bar{M})^2} \sqrt{\sum_{i=1}^n (E_{s_i} - \bar{E}_s)^2}} \right]^2 \quad (2-1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_{s_i} - M_i)^2} \quad (2-2)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n (E_{s_i} - M_i) \quad (2-3)$$

$$NASH = 1 - \frac{\sum_{i=1}^n (M_i - E_{s_i})^2}{\sum_{i=1}^n (M_i - \bar{M})^2} \quad (2-4)$$

Where: n is the size of the dataset, M and Es are the measured and estimated density values,  $\bar{M}$  and  $\bar{E}_s$  are the means of the measured and estimated values.

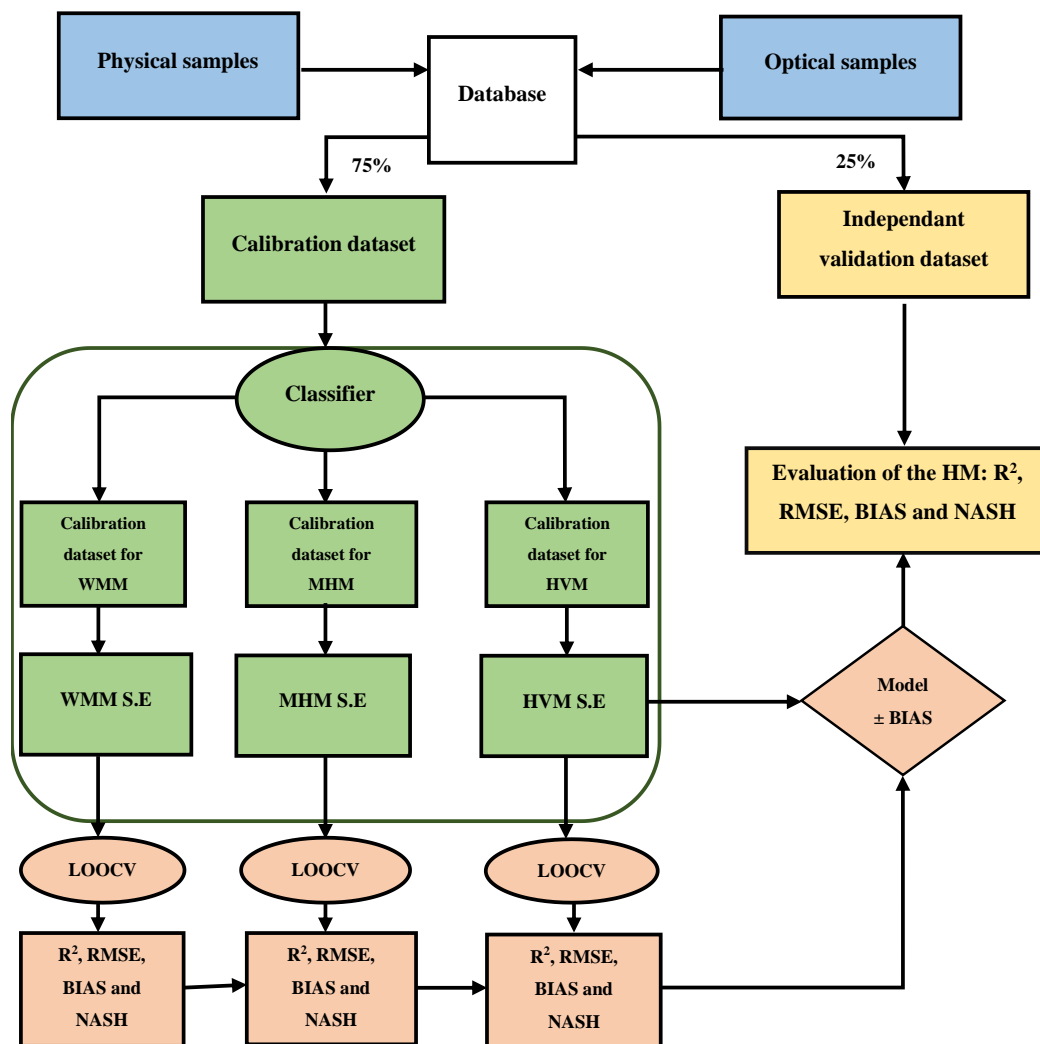


Figure 2-6 : Flowchart of the methodological approach. HM refers to hybrid model, S.E refers to specific estimator, and LOOCV refers to leave-one-out cross-validation.

### 3. Results and discussion

#### 3.1 Descriptive analysis of data

Domine *et al.* (2007) proposed snow grain size parameterizations based on snow density and grain shape, grouping snow samples into three main types (fresh, recent, and old). Based on this principle, we treated the snowpack as a succession of layers. Each layer is characterized by its own physical properties depending on its history and maturation stage of transformation (Libois, 2014). The layers are reported in Table 2-1 and are grouped by grain size, grain type, and layer density, as defined by Pahaut (1975). Based on these physical properties, each layer of snow has been assigned to one of three general predefined snow classes (WMM, MHM, and HVM) following the classification of Pahaut (1975) and the International classification of seasonal ground snow protocols (Fierz *et al.*, 2009). For inventory purposes, a description and pictures of snow grains with their corresponding dates were taken for each layer. These were used later as real in-situ data when verification was needed.

A database of 114 layers was established (Table 2-1). Snow densities varied between  $100 \text{ kg m}^{-3}$  and  $650 \text{ kg m}^{-3}$ , with an average of  $320 \text{ kg m}^{-3}$  and a standard deviation of  $130 \text{ kg m}^{-3}$ . According to the Pahaut (1975) classification, 19 layers (samples) were identified as WMM, 59 as MHM, and 36 as HVM. For WMM, MHM, and HVM, respectively, the minima were  $100 \text{ kg m}^{-3}$ ,  $150 \text{ kg m}^{-3}$ , and  $350 \text{ kg m}^{-3}$ ; the maxima were  $250 \text{ kg m}^{-3}$ ,  $400 \text{ kg m}^{-3}$ , and  $650 \text{ kg m}^{-3}$ ; the means were  $170 \text{ kg m}^{-3}$ ,  $280 \text{ kg m}^{-3}$ , and  $460 \text{ kg m}^{-3}$ ; the standard deviations were  $50 \text{ kg m}^{-3}$ ,  $78 \text{ kg m}^{-3}$ , and  $82 \text{ kg m}^{-3}$ . In Table 1, we consider newly deposited snow on the snowpack to be characterized by small grain size and low density, while moderately and heavily metamorphosed snow was characterized by moderate and large grain size and density, respectively. The smaller number of layers in the WMM class is due to the difficulty of isolating this type of layer because weakly metamorphosed snow is very light and often thin.

Table 2-1 : Distribution of snow density as a function of type and size of snow grains, for WMM, MHM, and HVM, respectively, (field data: 2018, 2019 and 2020). Precipitation particles (+), decomposing and fragmented precipitation particles ( $\lambda$ ), rounded grains ( $\bullet$ ), faceted crystals ( $\square$ ), depth hoar ( $\wedge$ ), melt forms ( $\circ$ ). The different shades of gray show the levels of metamorphosis (low, moderate, high) of each recuperated snow layer.

Snow class	Grain size (mm)	Grain type	Number of samples	Density ( $\text{kg m}^{-3}$ )										
				< 100	100 - 150	150 - 200	200 - 250	250 - 300	300 - 350	350 - 400	400 - 450	450 - 500	> 500	
WMM	$\begin{matrix} + \\ \lambda \end{matrix}$	< 1 mm	19	5	6	5	3							
MHM	$\begin{matrix} \square \\ \bullet \end{matrix}$	1 – 2 mm	59			9	6	15	12	12	5			
VHM	$\begin{matrix} \wedge \\ \circ \end{matrix}$	> 2 mm	36								7	10	7	12

Figure 2-7 shows the measured NIR reflectance spectrum of the 114 snow samples (layers) extracted from twenty-four snow cores (all field campaigns included). The shape of the spectral reflectance changes as a function of the physical properties of the snow (density, grain size, and grain shape), which depends on the state of transformation by the metamorphosis of each layer. In fact, each layer is characterized by its own spectral reflectance, which is characterized by the degree of reflection, absorption, and transmission in each wavelength of the NIR spectrum. This results in similarities between the reflectance spectra of layers with similar chemical composition and physical characteristics (ElMasry & Sun, 2010). This is translated by a decrease of reflectance as the snow layer ages; WMM, MHM, and HVM are colored dark blue, sky blue, and pink, respectively. These findings show that it is possible to discriminate between the three predefined classes based only on the reflectance spectra of the layers.




Figure 2-7 : The NIR spectral reflectance of the three snow classes.

### 3.2 Statistical dependence between density and spectral reflectance

Previous works have failed to establish a strong correlation between snow density and reflectance, neither in the visible (Li *et al.*, 2016; Ling & Zhang, 2004) nor in the NIR (Domine *et al.*, 2007; Li *et al.*, 2016; Ling & Zhang, 2004) parts of the spectrum. The same poor correlations (maximum correlation of  $R^2 = 0.53$ ) were also found in this study when using single bands, as shown by the graphical correlogram shown in Figure 2-8a. The  $R^2$  is also presented as a correlation matrix using three spectral indices: normalized band differences (Figure 2-8b), band ratios (Figure 2-8c), and band differences (Figure 2-8d). The accuracy was relatively increased, and the results are consistent with other published works (Eppanapelli *et al.*, 2018; Warren & Brandt, 2008). The best correlation for the normalized band differences, band ratios, and band differences was found with the spectral ranges



of 1034–1051 nm ( $R^2=0.64$ ), 1205–1309 nm ( $R^2=0.63$ ), and 1644–1655 nm ( $R^2=0.56$ ), respectively. The above results affirmed that the correlation between the snow density and the spectral indices is relatively moderate ( $R^2 \leq 0.64$ ).




Figure 2-8 : Correlogram and correlation matrix of the spectral reflectance and density for all measurements: (a) single bands; (b) normalized band differences; (c) band ratios; and (d) band differences.

Based on the above results, it was decided to go through the calibration and validation steps with the highest correlation, which was the normalized band differences. It is important to note, however, that these results are based on 75% of the initial database, as the remaining 25% was utilized for validation purposes. In order to avoid autocorrelation between independent variables, it was decided to correlate only the bands with the best associations (here called neo-variables for simplicity) with snow density. The result is shown in Figure 2-9a. The density is sensitive to wavelengths 974 nm and 990 nm, with an  $R^2$  of 0.64. When the model was validated using the independent data set (25% removed), all

statistical indices showed moderate accuracy in estimating snow density, particularly  $R^2$  and Nash ( $R^2 = 0.66$  et Nash = 0.66; Figure 2-9b).

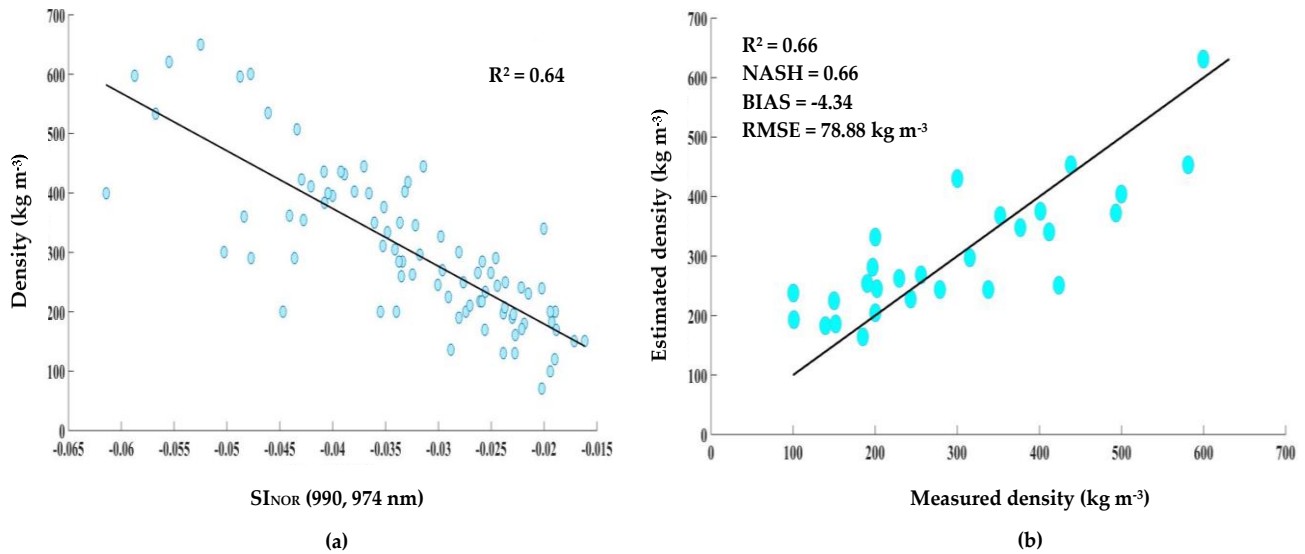


Figure 2-9 : Results of (a) calibration using normalized band differences (75% of the database); and (b) validation (25% of the database).

The aforementioned analysis confirms that the reciprocal correlation between the spectral reflectance in the NIR and snow density is probably the result of other changes in the aging process, such as temperature, day length, radiation, etc. (Dozier & Painter, 2004). Indeed, despite the strong correlation between the decrease in reflectance and the increase in density (Figure 2-7), it is difficult to evaluate the extent to which the decrease should be attributed to the underlying physical cause of densification, and this is where the difficulty of experimentally relating spectral reflectance (using single bands or based on neo-variables) to snow density lies.

### 3.3 Calibration of the hybrid model

#### 3.3.1 HM classifier calibration

Although several density models exist, most assume that snow density can be modeled using a single function (such as the one developed above). The use of a single function, even if it is multi-varied, is still confronted with the inherent surjective relationship between snow density and spectral reflectance. Therefore, replacing the surjective relation with several bijective relations could be the answer to increase the accuracy of snow density modeling. This could be achieved by establishing a strong correlation between the decrease in reflectance and the increase in density. To validate this hypothesis, a classification algorithm was applied to the calibration database to discriminate between the three predefined snow classes (WMM, MHM, and HVM) based on spectral reflectance and, hopefully, to increase the relationship between snow density and spectral reflectance in each class; converting this surjective relationship into three bijective relationships.

The results of in-situ measurement classification, presented in Table 2-1, were used to develop the HM's classifier using the CART algorithm. CART results are represented in the form of an intuitive illustration (Figure 2-10). Two wavelengths (1024 nm and 1161 nm) were selected as the best classifier thresholds, which allowed us to calibrate the classifier of the HM. Dozier and Painter (2004) demonstrated that the spectral reflectance of snow displays an ice absorption feature centered at 1030 nm that can be used to estimate snow grain size from hyperspectral data. Roy *et al.* (2006) used this ice absorption feature to distinguish natural snow from compacted or metamorphosed snow. The wavelengths identified by the CART are coherent with the works cited above. According to Figure 2-10, the band centered at 1024 nm allows to differentiate between the highly metamorphosed snow class (composed of snow grains of size > 2 mm) and the other two classes of weakly and moderately metamorphosed snow and the band centered at 1161 nm allows to discriminate between the moderately and weakly metamorphosed snow (composed of snow grains of size < 1 mm).

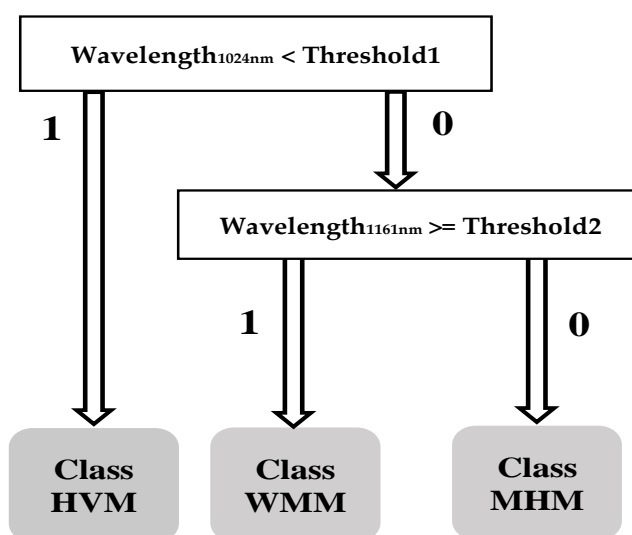


Figure 2-10 : Thresholds used to distinguish between the three classes of snow using the CART method. Threshold1 = 0.475 and threshold2 = 0.634.

### 3.3.2 Calibration of the specific models

The calibrated classifier was then used to subdivide the calibration database into three subclasses based on spectra. Fifteen samples were used as a training dataset for the WMM class, 44 for the MHM class, and 27 for the HVM class. Each subclass dataset was thereafter used to calibrate its own specific estimator. The calibration step was performed using multivariate stepwise regression in which the independent variables were selected using an automatic procedure that typically followed a sequence of F-tests. Stepwise regression was used in a direct selection mode, starting with none of the variables in the model, testing them one by one, and including only statistically significant variables (Wilkinson, 1979). For comparison purposes, the calibration and validation steps were performed exactly as indicated in the section above. However, only significant results are presented to alleviate the text. As expected, the correlation between snow density and spectral reflectance was higher when



each class was considered separately. Snow density showed a wider range of sensitivity to neo-variables, which was different for band differences and normalized band differences, depending on the class (Figure 2-11). These findings support the assumption that destroying the surjective relationship could lead to the creation of a bijective relationship in each class and consequently enhancing the model's accuracy. Also, the highest correlations are not necessarily centered at the same wavelength for each class. This is a demonstration that each class has its own response to the spectral reflectance and the optimal wavelengths to detect snow density shift depending on the class. This is to be expected since the density depends on the grain size, the grain type, and the liquid water content. In addition, it is known that water strongly absorbs in the NIR (Warren & Brandt, 2008). Hence, the higher the water content of snow, the smaller the returned signal (and vice versa).




Figure 2-11 : Results of correlation matrices with the different spectral indices studied. (a) band difference (WMM); (b) normalized ratio (MHM); and (c) band difference (HVM).

Results of the stepwise algorithm are presented in Figure 2-12. The three snow classes were linearly correlated, and the calibration functions were univariate (Table 2-2). The neo-variable retained for the



WMM class was the difference between 1265 nm and 941 nm wavelengths (referred to as the spectral index of subtraction;  $SI_{SUB}$ ) with an  $R^2$  of 0.91. The neo-variable retained for the MHM class was the normalized difference between 1617 nm and 941 nm wavelengths (referred here as the spectral index of normalized difference;  $SI_{NOR}$ ) with an  $R^2$  of 0.80. The neo-variable retained for the HVM class was also the difference between 1424 nm and 1188 nm wavelength ( $SI_{SUB}$ ) with an  $R^2$  of 0.84.

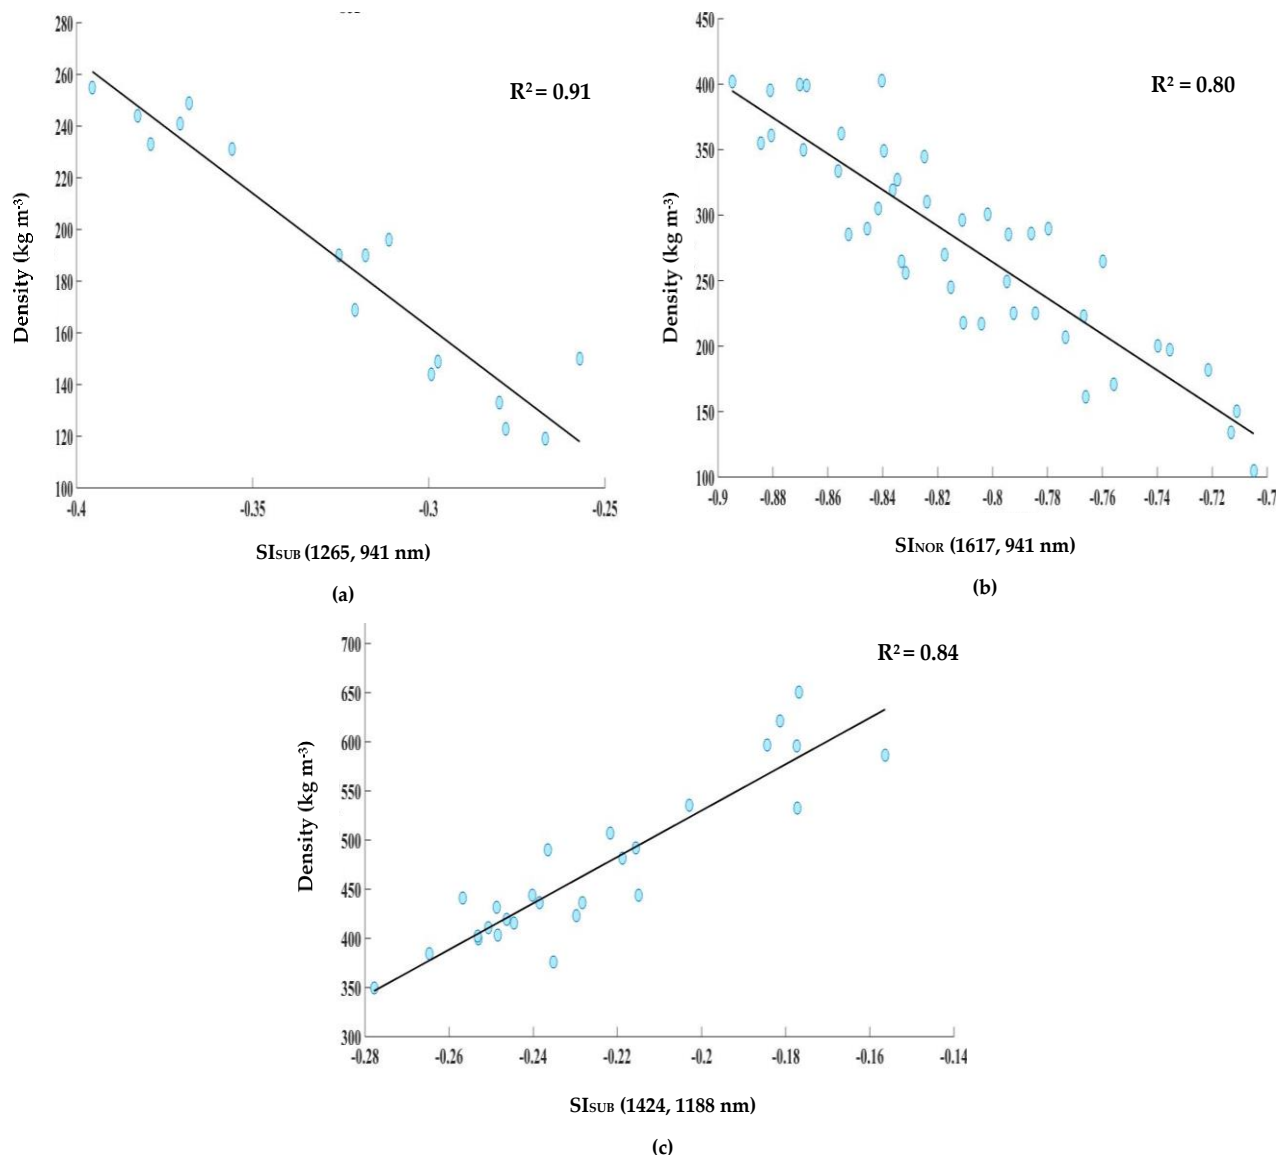


Figure 2-12 : Results of the hybrid model to estimate specific estimators. (a) class WMM; (b) class MHM; and (c) class HVM.

These results are coherent with other works. For example, Negi *et al.* (2010a) found that for changes in liquid water content, grain size, and metamorphosis level (aging) of snow, the maximum spectral variations are observed around the shorter wavelengths of the NIR spectrum. Gallet *et al.* (2014) used the NIR spectrum to determine the size of snow grains. They found that the band centered at 1310 nm, which corresponds to the central part of the NIR spectrum, is sensitive to small snow grains, which are usually of low to medium density, and that the band centered at 1550 nm, which

corresponds to the higher part of the NIR spectrum, is sensitive to large snow grains, where the snow is generally denser. The strong correlation between in situ density measurements and spectral indices ( $R^2 > 0.80$ ) for all three specific estimators illustrates the importance of dividing the input data into several classes of snow (three in this study), based on a certain degree of aging. For all specific estimators, the estimation of snow density was limited to short (941 nm, 1265 nm, and 1188 nm) and long (1424 nm and 1617 nm) NIR wavelengths, which are the spectral regions most sensitive to the physical properties of snow. The mathematical expressions of the three specific estimators are summarized in Table 2-2.

Table 2-2 : Equations of the three calibrated models (specific estimators) using stepwise multivariate regression to estimate snow density.

<b>Snow class</b>	<b>Specific estimator</b>
WMM	Density = $-1035 * SI_{SUB} (1265 \text{ nm}, 941 \text{ nm}) - 148$
MHM	Density = $-1377 * SI_{NOR} (1617 \text{ nm}, 941 \text{ nm}) - 838$
HVM	Density = $2357 * SI_{SUB} (1424 \text{ nm}, 1188 \text{ nm}) + 1002$

### 3.4 Evaluation and validation of the hybrid model

#### 3.4.1 Evaluation of the specific estimators using the LOOCV algorithm

The LOOCV is a technique that consists of temporarily removing certain entries from a database and using the rest as calibration data, and then estimating the value of the removed entry. This operation is repeated for the entire database, resulting in an estimate for the entire database, hence allowing the comparison between estimated and measured values (Equations (1)–(4)). Figure 2-13 shows the LOOCV results of the three specific estimators. The estimators' ability to model snow density is satisfactory for the WMM, MHM, and HVM classes with a respective value of  $R^2$  of 0.87, 0.78, and 0.81. The RMSE of the three specific estimators are  $17.26 \text{ kg m}^{-3}$ ,  $36.36 \text{ kg m}^{-3}$ , and  $36.04 \text{ kg m}^{-3}$ , respectively, for the WMM, MHM, and HVM classes, which is satisfactory as well. The BIAS is positive for all three classes.

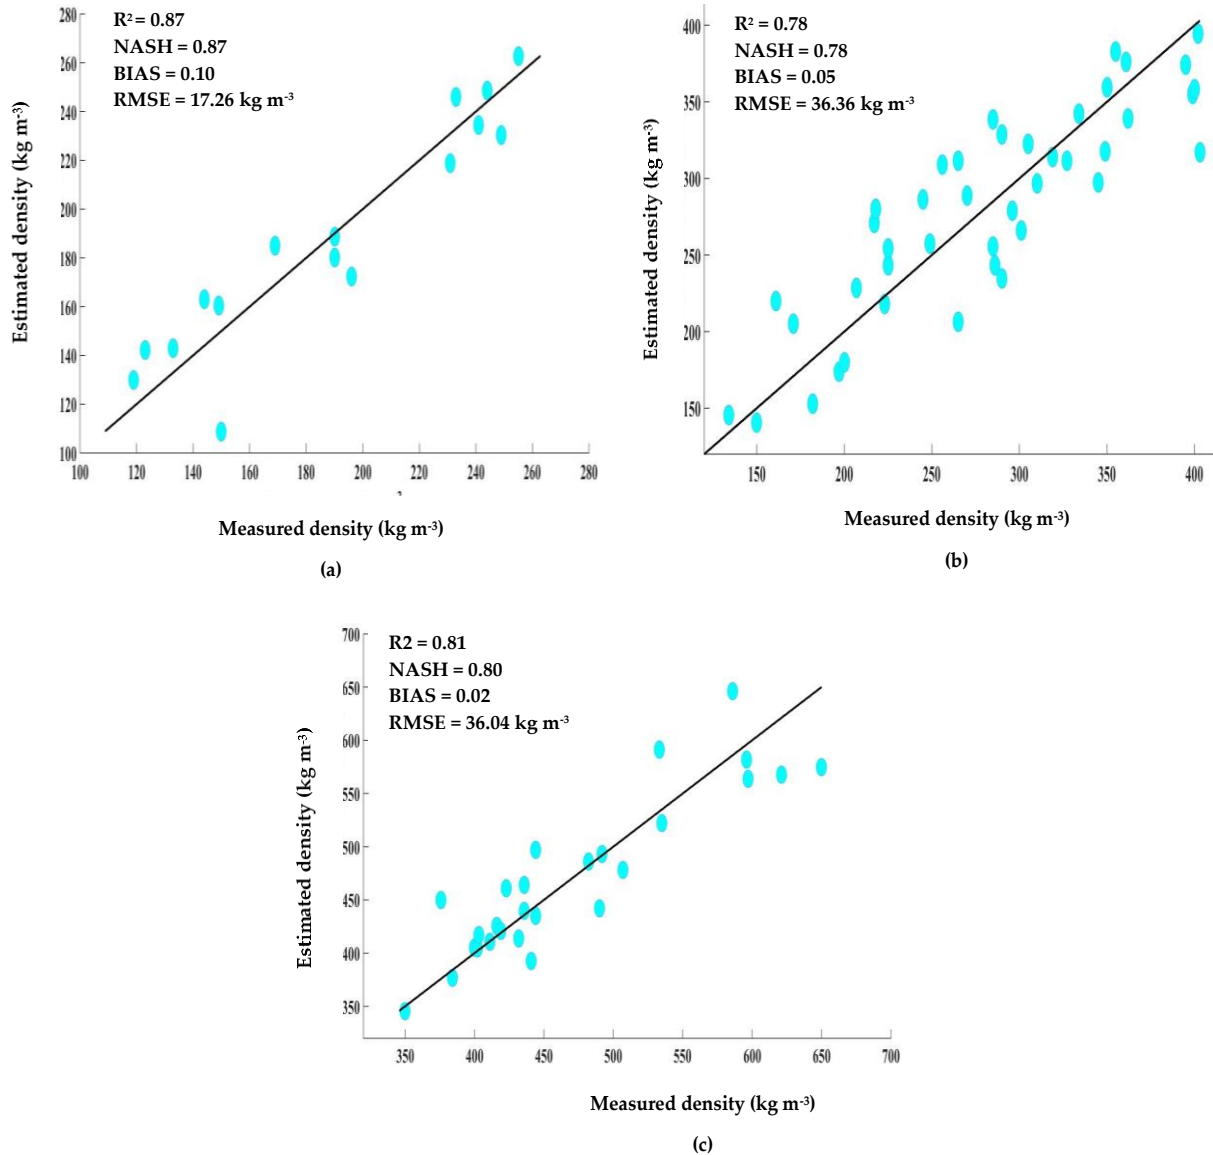


Figure 2-13 : Results of the LOOCV of the hybrid model specific estimators. (a) class WMM; (b) class MHM; and (c) class HVM.

The LOOCV was not intended to evaluate the HM's snow density estimates, and its main objective was to quantify the BIAS of each specific estimator. In fact, each modeling process is tainted by two sources of error: (1) a random error quantified by the RMSE, and (2) a systematic error quantified by the BIAS. The first one is not correctable, but the second one is adjustable and can be removed/added to the estimates during the modeling process. This part of the study was aimed at quantifying the systematic error and using it to adjust the final model.

### 3.4.2 Evaluation of the hybrid model using SSV

The HM was evaluated using independent data. However, it is important to note that in order to use SSV data for validation, it was necessary to go through all the calibration steps:

- ❖ Assign a given class using the HM classifier;

- ❖ Estimate the density using the specific estimators corresponding to the preassigned class;
- ❖ Correct the estimates' BIAS;

shows the results of the evaluation of the HM's ability to estimate the snow density. The points are well distributed along the 1:1 line, from very low to high-density values. The value of the NASH = 0.93 and  $R^2 = 0.93$  highlights the good performance of the model. A satisfactory value of RMSE ( $31.48 \text{ kg m}^{-3}$ ) is also achieved. As these results show, the performance of the HM is satisfactory, especially with a dataset covering a three-winter period. This period may seem long, but with global warming and climate change affecting climatic systems around the world, the seasonal snowpack is expected to also be changing from year to year. This is why finding an independent dataset to assess the performance of the HM was very challenging. Despite this, the evaluation shows that the HM accurately modeled the snow density using optical data. Contrary to previous studies claiming that there is no strong correlation between spectral reflectance and snow density, this study has shown that it is possible to estimate snow density if the right modeling strategy is found.

The implementation of the approach developed in this work can constitute a real advance in the determination and monitoring of the various processes that lead to the continuous evolution and regular monitoring of the density of the seasonal snow cover. The results also highlight many of the difficulties inherent in measuring the density of snow on the ground, which presents considerable lateral variability (accumulation of layers of different densities). This large lateral variability is common to all snowpacks, and measuring only the average density of the latter does not represent the overall vertical profile. The approach described here, when fully matured, provides a means of obtaining the necessary data for these purposes.




Figure 2-14 : Evaluation of the regional hybrid model using the SSV data.

## 4. Conclusion

The objective of this study was to test the performance of a hybrid model (HM) designed to estimate the density of the seasonal snowpack using hyperspectral NIR imaging (900–1700 nm) at a spectral resolution of 5.5 nm. The hybrid model is a combination of a classifier and three specific estimators (weakly to moderately metamorphosed snow (WMM), moderately to highly metamorphosed snow (MHM), and highly to very highly metamorphosed snow (HVM)). The hybrid model was evaluated at two levels: using the leave-one-out cross-validation (LOOCV) algorithm and using the systematic division validation technique (SSV). The LOOCV technique was used to assess the three specific estimators, and the SSV data were used to assess the performance of the HM.

The calibration step, based on a stepwise multivariate regression, showed that the three classes of snow are sensitive to different regions of the NIR spectrum, limited to the short and long wavelengths. The WMM was sensitive to the wavelengths at 1265 nm and 941 nm, the MHM was sensitive to wavelengths at 1617 nm and 941 nm, and the HVM was sensitive to wavelengths at 1424 nm and 1188 nm. The LOOCV technique highlighted that the specific estimators of all classes tend to slightly overestimate the snow density ( $\text{BIAS} < 0.1 \text{ kg}\cdot\text{m}^{-3}$ ). When the HM was challenged with SSV data, the modelling results were satisfactory with an  $R^2 = \text{Nash} = 0.93$ , and the snow density was slightly underestimated ( $\text{BIAS}=1.03 \text{ kg}\cdot\text{m}^{-3}$ ).

The objective of this study was to develop a method based on the optical properties of snow to be used conjointly with conventional density measurement methods with the aim of alleviating field operations. The critical step in estimating snow density using the HM is the selection of the final specific estimator. Indeed, classification algorithms (such as CART) are known to be local and unstable. This instability can significantly affect the accuracy of the density using the specific estimators of the HM. In other words, for an ideal modeling process using the HM, the sample to be modeled must be well classified so that the specific estimator corresponding to that class is used for optimal density estimation. Otherwise, a wrong specific estimator will be selected, and consequently, the estimation will not be optimal, which could affect the accuracy. For example, for a measured density of  $581 \text{ kg m}^{-3}$  (classified as HVM), the relative errors vary by 5%, 39%, and 75% when estimated using specific estimators of HVM, MHM, and WMM, respectively. On the other hand, another obstacle associated with this method is the correct selection of homogeneous snow layers in the field and on the recovered hyperspectral image. For this reason, additional field campaigns need to be conducted to collect more data to overcome this weakness and allow proper field implementation. The HM provides an improved tool to monitor the evolution of seasonal snowpacks, with a satisfactory level of performance even for low to moderate snow densities. We conclude that our results are an important first step toward the development of an effective method for continuous monitoring of snow density profiles in the field.

**Acknowledgments:** Many people have reviewed and commented on the drafts of this document. The comments of Anas El Alem, Monique Bernier were particularly appreciated. Karem Chokmani's encouragements were very helpful, as was his valuable guidance. The preparation of this manuscript, the retrieval, measurement and photography of snow profiles and my work on snow metamorphism have been supported over the years in developing this work. Many thanks to Sophie Roberge and David Ethier for their efficient coordination of the field campaign. Thanks also to Jimmy Poulin, Hachem Agili and Rachid Lhissou for their help and suggestions.

**Author Contributions:** Conceptualization, M.K.E.O. and K.C.; methodology, M.K.E.O., A.E.A. and K.C.; writing—original draft preparation, M.K.E.O.; writing—review and editing, M.K.E.O., A.E.A. and M.B.; supervision, K.C. and A.E.A. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Institutional Review Board Statement:** Not applicable.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** Not applicable.

**Acknowledgments:** Many people have reviewed and commented on the drafts of this document. The comments of Anas El Alem, Monique Bernier were particularly appreciated. Karem Chokmani's encouragements were very helpful, as was his valuable guidance. The preparation of this manuscript, the retrieval, measurement and photography of snow profiles and my work on snow metamorphism have been supported over the years in developing this work. Many thanks to Sophie Roberge and David Ethier for their efficient coordination of the field campaign. Thanks also to Jimmy Poulin, Hachem Agili and Rachid Lhissou for their help and suggestions.

**Conflicts of Interest:** The authors declare that they are submitting the manuscript to the journal without any known conflict of interest.

## 5. REFERENCES

- Bohren CF & Beschta RL (1979) Snowpack albedo and snow density. *Cold Regions Science and Technology* 1(1):47-50.
- Breiman L, Friedman J, Olshen R & Stone C (1984) Classification and Regression Trees. Monterey, CA: Wadsworth. Wadsworth Statistics/Probability Series. (Wadsworth Advanced Books and Software, Belmont, CA).
- Brown R & Armstrong R (2008) Snow-cover data: Measurement, products, and sources. (Cambridge University Press), p 181-216.
- Castebrunet H, Eckert N, Giraud G, Durand Y & Morin S (2014) Projected changes of snow conditions and avalanche activity in a warming climate: the French Alps over the 2020-2050 and 2070-2100 periods.
- Chauchard F, Cogdill R, Roussel S, Roger J & Bellon-Maurel V (2004) Application of LS-SVM to non-linear phenomena in NIR spectroscopy: development of a robust and portable sensor for acidity prediction in grapes. *Chemometrics and Intelligent Laboratory Systems* 71(2):141-150.
- Cui Y, Xiong C, Lemmetyinen J, Shi J, Jiang L, Peng B, Li H, Zhao T, Ji D & Hu T (2016) Estimating snow water equivalent with backscattering at X and Ku band based on absorption loss. *Remote Sensing* 8(6):505.
- Davis R, Pangburn T, Daly S, Ochs E, Hardy J, Bryant E & Pugner P (1999) Can satellite snow maps, ground measurements, and modeling improve water management and control in the Kings River Basin, California. *Efforts toward finding the answer. Western Snow Conference Proceedings*. p 54-61.
- Domine F, Taillandier AS & Simpson WR (2007) A parameterization of the specific surface area of seasonal snow for field use and for models of snowpack evolution. *Journal of Geophysical Research: Earth Surface* 112(F2).
- Dozier J (1989) Spectral signature of alpine snow cover from the Landsat Thematic Mapper. *Remote sensing of environment* 28:9-22.
- Dozier J & Painter TH (2004) Multispectral and hyperspectral remote sensing of alpine snow properties. *Annual Review of Earth and Planetary Sciences* 32.
- Dutra E, Viterbo P, Miranda PM & Balsamo G (2012) Complexity of snow schemes in a climate model and its impact on surface energy and hydrology. *Journal of Hydrometeorology* 13(2):521-538.
- El Oufir MK, Chokmani K, El Alem A, Agili H & Bernier M (2021) Seasonal Snowpack Classification Based on Physical Properties Using Near-Infrared Proximal Hyperspectral Data. *Sensors* 21(16):5259.

- ElMasry G & Sun D-w (2010) Principles of hyperspectral imaging technology. *Hyperspectral imaging for food quality analysis and control*, Elsevier. p 3-43.
- ElMasry G, Sun D-W & Allen P (2012) Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. *Journal of Food Engineering* 110(1):127-140.
- Eppanapelli LK, Lintzén N, Casselgren J & Wåhlin J (2018) Estimation of Liquid Water Content of Snow Surface by Spectral Reflectance. *Journal of Cold Regions Engineering* 32(1):05018001.
- Farnes P (1967) Criteria for determining mountain snow pillow sites. *Proc. 35th western snow conf.* p 59-62.
- Farnes P, Goodison B, Peterson N & Richards R (1980) Proposed metric snow samplers. *48th Western Snow Conference.* p 107-119.
- Fassnacht S, Helfrich S, Lampkin D, Dressler K, Bales R, Halper E, Reigle D & Imam B (2001) Snowpack modelling of the Salt Basin with water management implications. *Proc. Western Snow Conf.* p 65-76.
- Fierz C, Armstrong RL, Durand Y, Etchevers P, Greene E, McClung DM, Nishimura K, Satyawali PK & Sokratov SA (2009) *The international classification for seasonal snow on the ground.* UNESCO/IHP Paris,
- Gallet J-C (2010) *La neige du plateau antarctique. Surface spécifique et applications.* (Université Joseph-Fourier-Grenoble I).
- Gallet J-C, Domine F & Dumont M (2014) Measuring the specific surface area of wet snow using 1310 nm reflectance. *The Cryosphere* 8(4):1139-1148.
- Gergely M, Schneebeli M & Roth K (2010) First experiments to determine snow density from diffuse near-infrared transmittance. *Cold regions science and technology* 64(2):81-86.
- Haq MA, Ghosh A, Rahaman G & Baral P (2019) Artificial neural network-based modeling of snow properties using field data and hyperspectral imagery. *Natural Resource Modeling* 32(4):e12229.
- Kinar N & Pomeroy J (2015) Measurement of the physical properties of the snowpack. *Reviews of Geophysics* 53(2):481-544.
- Kropacek J, Feng C, Alle M, Kang S & Hochschild V (2010) Temporal and spatial aspects of snow distribution in the Nam Co Basin on the Tibetan Plateau from MODIS data. *Remote Sensing* 2(12):2700-2712.
- Kulkarni A, Srinivasulu J, Manjul S & Mathur P (2002) Field based spectral reflectance studies to develop NDSI method for snow cover monitoring. *Journal of the Indian Society of Remote Sensing* 30(1-2):73-80.
- Langham E (1981) Physics and properties of snowcover. *Handbook of snow* :275-337.



- Lehning M, Bartelt P, Brown B, Russi T, Stöckli U & Zimmerli M (1999) SNOWPACK model calculations for avalanche warning based upon a new network of weather and snow stations. *Cold Regions Science and Technology* 30(1-3):145-157.
- Li H, Wang A, Guan D, Jin C, Wu J, Yuan F & Shi T (2016) Empirical model development for ground snow sublimation beneath a temperate mixed forest in Changbai mountain. *Journal of Hydrologic Engineering* 21(11):04016040.
- Libois Q (2014) *Evolution des propriétés physiques de neige de surface sur le plateau Antarctique. Observations et modélisation du transfert radiatif et du métamorphisme.* (Grenoble).
- Ling F & Zhang T (2004) A numerical model for surface energy balance and thermal regime of the active layer and permafrost containing unfrozen water. *Cold Regions Science and Technology* 38(1):1-15.
- Lorente D, Aleixos N, Gómez-Sanchis J, Cubero S, García-Navarrete OL & Blasco J (2012) Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment. *Food and Bioprocess Technology* 5(4):1121-1142.
- Lu G & Fei B (2014) Medical hyperspectral imaging: a review. *Journal of biomedical optics* 19(1):010901.
- Marbouty D (1984) Les propriétés physiques de la neige. *La houille blanche* (8):557-567.
- Nash JE & Sutcliffe JV (1970) River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology* 10(3):282-290.
- Negi H, Jassar H, Saravana G, Thakur N, Snehmani & Ganju A (2013) Snow-cover characteristics using Hyperion data for the Himalayan region. *International journal of remote sensing* 34(6):2140-2161.
- Negi H, Singh S, Kulkarni A & Semwal B (2010a) Field-based spectral reflectance measurements of seasonal snow cover in the Indian Himalaya. *International Journal of Remote Sensing* 31(9):2393-2417.
- Negi HS, Singh S, Kulkarni A & Semwal B (2010b) Field-based spectral reflectance measurements of seasonal snow cover in the Indian Himalaya. *International Journal of Remote Sensing* 31(9):2393-2417.
- Nolin AW & Dozier J (2000) A hyperspectral method for remotely sensing the grain size of snow. *Remote sensing of Environment* 74(2):207-216.
- Osborne BG (2006) Near-infrared spectroscopy in food analysis. *Encyclopedia of analytical chemistry: applications, theory and instrumentation.*
- Pahaut E (1975) *Les Cristaux de neige et leurs métamorphoses.* Direction de la Météorologie nationale. <https://books.google.ca/books?id=9n9aNQAACAAJ>
- Pomeroy JW, Hanson S & Faria D (2001) Small-scale variation in snowmelt energy in a boreal forest: an additional factor controlling depletion of snow cover. *Proceedings of the Eastern Snow Conference.* p 85-96.

- Roy V, Goita K, Granberg H & Royer A (2006) On the use of reflective hyperspectral remote sensing for the detection of compacted snow. *Geoscience and Remote Sensing Symposium, 2006. IGARSS 2006. IEEE International Conference on*. IEEE, p 3263-3266.
- Roy V, Goita K, Royer A, Walker AE & Goodison BE (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* 42(9):1850-1859.
- Sturm M, Taras B, Liston GE, Derksen C, Jonas T & Lea J (2010) Estimating snow water equivalent using snow depth data and climate classes. *Journal of Hydrometeorology* 11(6):1380-1394.
- Vehtari A, Gelman A & Gabry J (2017) Practical Bayesian model evaluation using leave-one-out cross-validation and WAIC. *Statistics and computing* 27(5):1413-1432.
- Warren SG & Brandt RE (2008) Optical constants of ice from the ultraviolet to the microwave: A revised compilation. *Journal of Geophysical Research: Atmospheres* 113(D14).
- Warren SG & Wiscombe WJ (1980) A model for the spectral albedo of snow. II: Snow containing atmospheric aerosols. *Journal of the Atmospheric Sciences* 37(12):2734-2745.
- Wilkinson L (1979) Tests of significance in stepwise regression. *Psychological bulletin* 86(1):168.
- Wright M, Kavanaugh J & Labine C (2011) Performance analysis of GMON3 snow water equivalency sensor. *Proceedings of the Western Snow Conference*. p 105-108.
- Zuanon N (2013) IceCube, a portable and reliable instruments for snow specific surface area measurement in the field. *International Snow Science Workshop Grenoble-Chamonix Mont-Blanc-2013 proceedings*. p 1020-1023.

## Avant-propos

Cet article a été soumis pour une publication dans le journal *remote sensing* du *MDPI*. Les co-auteurs qui ont participé à la rédaction de ce manuscrit sont :

### **1. Mohamed Karim El Oufir :**

Responsable de la conception de recherches, la méthodologie, prétraitements et traitements des données, le développement des modèles mathématiques, l'analyse et l'interprétation des résultats et à la rédaction du manuscrit.

### **2. Karem Chokmani :**

Responsable également de la conception de recherches et a contribué à l'édition, l'analyse, et à l'examen du manuscrit.

### **3. Anas El Alem :**

Responsable également de la conception de recherches et a contribué à l'édition, responsable des interprétations mathématiques et statistiques, et à l'examen du manuscrit.

### **5. Monique Bernier**

Responsable à la révision du manuscrit.



## Abstract

Estimating the seasonal density of the snowpack has many financial and environmental benefits. Rapid assessment and daily monitoring of its evolution are therefore key to effective prevention. Traditionally, the physical characteristics of snow are measured directly in the field, which involves high costs and personnel mobilization. Hyperspectral imaging is a reliable and efficient technique to study and evaluate this physical property. The spectral reflectance of snow is partly defined by changes in its physical properties, particularly in the near infrared (NIR) part of the spectrum. Recently, a hybrid snow density estimation model allowing to retrieve density from NIR hyperspectral data was developed, based on an a priori classification of snow samples. However, in order to obtain optimal density estimates with the hybrid model (HM), the sources of classification and estimation error must be controlled. Following the same principle as the hybrid model, an ensemble-based system (EBS) was developed. This model reduces the number of misclassification errors produced by the HM. The general concept of EBS algorithms is based on the principle that getting more opinions before making a decision is part of human nature, especially when economic and environmental benefits are at stake. This approach has helped to reduce the risk of classification and estimation errors and to develop more robust density results. One hundred and fourteen snow samples collected during three winters (2018 to 2020) were used to calibrate and validate the EBS. The performance of the EBS was validated using an independent database and the results were satisfactory ( $R^2 = 0.90$ ,  $RMSE = 44.45 \text{ kg m}^{-3}$ ,  $BIAS = 3.87 \text{ kg m}^{-3}$  and  $NASH = 0.89$ ).

**Keywords:** hyperspectral; near-infrared; density; snowpack; Gaussian quadrature; ensemble-based system.

## Résumé

L'estimation de la densité saisonnière du manteau neigeux présente de nombreux avantages financiers et environnementaux. Une évaluation rapide et un suivi quotidien de son évolution sont donc essentiels pour une prévention efficace. Traditionnellement, les caractéristiques physiques de la neige sont mesurées directement sur le terrain, ce qui implique des coûts élevés et la mobilisation de personnel. L'imagerie hyperspectrale est une technique fiable et efficace pour étudier et évaluer cette propriété physique. La réflectance spectrale de la neige est en partie définie par les changements de ses propriétés physiques, en particulier dans la partie proche infrarouge (PIR) du spectre. Récemment, un modèle hybride d'estimation de la densité de la neige permettant de retrouver la densité à partir de données hyperspectrales PIR a été développé, basé sur une classification a priori des échantillons de neige. Cependant, afin d'obtenir des estimations de densité optimales avec le modèle hybride (MH), les sources d'erreur de classification et d'estimation doivent être contrôlées. Suivant le même principe que le modèle hybride, un modèle basé sur les méthodes d'ensemble (MBME) a été développé. Ce modèle réduit le nombre d'erreurs de classification produites par le MH. Le concept général de ces algorithmes est basé sur le principe que l'obtention d'un plus grand nombre d'opinions avant de prendre une décision fait partie de la nature humaine, surtout lorsque des avantages économiques et environnementaux sont en jeu. Ce modèle a permis de réduire le risque d'erreurs de classification et d'estimation ainsi que de développer des résultats de densité plus robustes. Cent quatorze échantillons de neige collectés pendant trois hivers (2018 à 2020) ont été utilisés pour calibrer et valider le MBME. Les performances du MBME ont été validées à l'aide d'une base de données indépendante et les résultats ont été satisfaisants ( $R^2 = 0.90$ , RMSE = 44.45 kg m<sup>-3</sup>, BIAS = 3.87 kg m<sup>-3</sup> et NASH = 0.89).

**Mots clés :** hyperspectral; proche infrarouge; densité; manteau neigeux; quadrature gaussienne; modèle basé sur les méthodes d'ensemble.

### 3 TROISIÈME ARTICLE: USING ENSEMBLE BASED SYSTEMS WITH NEAR INFRARED HYPERSPECTRAL DATA TO ESTIMATE SEASONAL SNOWPACK DENSITY

---

Mohamed Karim El Oufir\*, Karem Chokmani, Anas El Alem, and Monique Bernier

Citation: El Oufir, M.K.; Chokmani, K.; El Alem, A.; Bernier, M.

Institut National de la Recherche Scientifique (INRS), Québec, QC G1K 9A9, Canada;

[karem.chokmani@ete.inrs.ca](mailto:karem.chokmani@ete.inrs.ca) (K.C.)

[anas.el\\_alem@ete.inrs.ca](mailto:anas.el_alem@ete.inrs.ca) (A.E.A.)

[monique.bernier@ete.inrs.ca](mailto:monique.bernier@ete.inrs.ca) (M.B.)

\* Correspondence: [mohamed\\_karim.el\\_oufir@ete.inrs.ca](mailto:mohamed_karim.el_oufir@ete.inrs.ca); Tel.: +1-418-264-1950





## 1. Introduction

The measurement and modelling of the physical characteristics of snow, particularly its density, is important for financial and environmental purposes, as this property is essential when estimating the water equivalent of snow, predicting avalanche risk (Schweizer *et al.*, 2003), and it is often used to observe and understand the evolution of seasonal snowpacks (Gray & Landine, 1988; McKay & Blackwell, 1961). The physical characteristics of natural snow can vary vertically and horizontally in the snowpack (Matzl & Schneebeli, 2006; Pielmeier & Schneebeli, 2003). Daily monitoring and advances in measurement techniques for these features are key elements in controlling and reducing the risks related to measurement uncertainties (Kinar & Pomeroy, 2015), but they requires a significant effort in measuring and collecting samples in the field to ensure the accuracy of the measurements. It has also been shown that standard sampling methods, based on fixed sampling points, insufficiently cover large areas and the resulting temporal resolution is deficient (Berisford *et al.*, 2013; Kinar & Pomeroy, 2015; Zuanon, 2013). High resolution measurement techniques based on remote sensing can be used to validate and improve current physical measurement operations.

Due to its ability to provide information over a wide range of wavelengths, NIR hyperspectral technology is a promising tool to estimate the physical properties of snow (Domine *et al.*, 2006; Varade *et al.*, 2017). This innovative technique provides useful information on the physical and chemical components of a scanned sample (ElMasry *et al.*, 2012; Lorente *et al.*, 2012; Lu & Fei, 2014), which can be used for modelling purposes. Indeed, the NIR spectral range has been tested in the laboratory and in the field in several works aimed at estimating the physical properties of snow (Donahue *et al.*, 2021; El Oufir *et al.*, 2021a; Gallet *et al.*, 2009a; Matzl & Schneebeli, 2006; Painter *et al.*, 2007). This is made possible by relating the observed optical changes in the NIR spectral reflectance at specific wavelengths to the physical transformation processes of snow (Domine *et al.*, 2006; Eppanapelli *et al.*, 2018; Gallet *et al.*, 2009b; Negi *et al.*, 2010). A review of scientific literature has shown that few works have been dedicated to estimating snow density from optical data. Nonetheless, Gergely *et al.* (2010) demonstrated that snow density values can be estimated in a cold laboratory using NIR transmittance measurements if the size and shape of the snow grains are known in advance. Varade and Dikshit (2017) developed a new approach to estimate snow moisture and density using the infrared bands available with most spectral sensors. Their method based on using the NIR band led them to develop the normalized snow index (NDSI), called PIR-NDSI space.

Recently, a hybrid model (HM) based on NIR spectral data has been developed to estimate snow density (El Oufir *et al.*, 2021b). Density estimation using the HM is carried out in two steps: 1) The snow samples are classified into one of three snow classes (weakly to moderately metamorphosed [WMM], moderately to highly metamorphosed [MHM] and highly to very highly metamorphosed [HVM]); and 2) Specific estimators corresponding to the selected snow classes are used to estimate

the density. When using this model, the selection of the final estimator is critical because the selection of a wrong estimator could lead to the over- or underestimation of density. Moreover, classification algorithms, such as the one used to develop the HM (classification and regression tree), are known to be local and unstable (Alpak *et al.*, 2013). This instability significantly affects model reliability when used to estimate the density of snow.

In such complex modelling contexts, many authors suggest that the use of an ensemble-based system (EBS) could lead to more stable and robust results (Chan & Paelinckx, 2008; Hansen & Salamon, 1990; Ismail & Mutanga, 2010; Jacobs *et al.*, 1991; Jordan & Jacobs, 1994; Oza & Tumer, 2008; Wang *et al.*, 2009). Two conditions are necessary to build a stable and robust EBS: 1) reaching a high diversity between individual elements (classifiers and/or estimators) and 2) applying effective rules to combine individual elements in a way that good decisions are amplified and bad decisions are cancelled (Polikar, 2006).

To achieve the desired diversity, EBS are composed of thousands of different elements, which can be problematic when using remote sensing data. Researchers are often faced with a delicate situation: either reduce the number of features in the EBS which could reduce the solution space or develop a robust EBS with a very long running time. The Gaussian quadrature formula (GQF) could provide an interesting solution to this problem. This method, which is frequently used in uncertainty propagation analysis (Kelly & Krzysztofowicz, 1997), transforms the problem of a sample with a very large number of solutions (which require laborious integral calculations) into a weighted sum of optimal solutions through simple and accurate numerical solution techniques (Tørvi & Hertzberg, 1997).

The objective of our work is to develop an EBS on the foundation of the previously described HM and GQF to estimate the seasonal density of the snowpack using high-resolution NIR hyperspectral data. The EBS was evaluated by independent validation data and its performance was assessed using four statistical evaluation indices ( $R^2$ , root mean square error [RMSE], bias [BIAS], and Nash-criterion [NASH]).

## **2. Materials and methods**

### **2.1 In situ measurements for the calibration and validation database**

To achieve the objectives of this study, the calibration and validation databases were composed of two types of data: optical data (spectral reflectance) measured with a proximal acquisition station, and physical data (grain size, grain type, and density) sampled with a snow corer. For all acquisitions, the same equipment and sampling technique was used throughout the study. The study site was located at the INRS's (National Institute of Scientific Research) Technology Park in the City of Quebec (46°

47° 43.22'' north and -71 ° 18' 10'' west; Figure 3-1). The area selected for this study is approximately 20 m<sup>2</sup>, located in an open sector of the experimental site.




Figure 3-1: Geographical location of the sampling area (El Oufir *et al.*, 2021b).

The portable rectangular snow corer was designed and built by the INRS's remote sensing team (Figure 3-2). It is used to recover the vertical stratigraphy of the snowpack which allows to measure the physical and optical properties of the recovered profile. The dimensions of the corer make it possible to recover the entire vertical profile of the snowpack because of its simple operating principle. The corer is made up of two parts, the inner part is made of metal and the outer part of plastic, with a triangular saw-tooth cutting tip. The device is simply inserted into the snow at the required depth. A trench is then made to access the lower part of the corer and a plate is placed under to prevent the snow from falling. The corer is then tilted horizontally and transported to the measurement station. At this point, the handle is pulled and the inner part containing the snow is carefully removed. The snow is only minimally disturbed during the sampling process, resulting in accurate measurements.

The proximal acquisition station used in this work consists of a RESONON PIKA NIR line-scanning hyperspectral camera that allows the measurement of NIR spectral reflectance at several wavelengths between 900 nm and 1700 nm, with a spectral resolution of 5.5 nm and 148 spectral bands. The reflectance was calculated by measuring the radiance reflected from the snow surface and from a reference target. The latter has near-Lambertian reflection properties when viewed from

the nadir. The station is also equipped with a halogen lighting system, mounting tower, linear translation stage for rapid image acquisition, data acquisition software (Spectronon Pro [Resonon Inc., Bozeman MT, USA]), and proximal acquisition lenses (Figure 3-3).



Figure 3-2: Snow core sampler (El Oufir *et al.*, 2021a).




Figure 3-3: NIR spectral reflectance acquisition device for the vertical profile of snow samples from the company RESONON (Resonon Inc., Bozeman, MT, USA) (El Oufir *et al.*, 2021a).

Once the snow profile has been recovered, the core drill is then placed horizontally on the moving platform in relation to the camera's field of view (nadir) to record a high spectral resolution image, which is then analyzed with the Spectronon Pro software. This image is used to validate the identification of snow layers already measured in the field and to analyze the spectral response of each identified layer. The speed of the platform was selected to achieve equal spatial resolution of the vertical and horizontal axes to avoid distortion of the image size and to fit the predetermined exposure time of the camera.

In situ sampling of the physical properties of snow is carried out by treating the recovered snow profile as a succession of layers. Each visually homogeneous layer is carefully removed from the sampler and the size and type of snow grains are measured using a millimetre grid and a 10x magnifying glass. The sample is then classified according to the International Classification of Seasonal Snow on the Ground (Fierz *et al.*, 2009). Finally, the isolated layer was weighed to determine its density based on its mass and volume. To ensure consistency in the analysis, all observations and measurements were made by the same person.

## 2.2 Algorithm development

### 2.2.1 The hybrid model

The HM developed by El Oufir *et al.* (2021b) to estimate seasonal snowpack density from hyperspectral data is composed of a classifier and three estimators, each specific to a given snow class (WMM, MHM and HVM). The HM classifier was trained using the classification and regression tree (CART) method (Breiman *et al.*, 1984). Once trained, it was possible to divide the calibration database into the three specific classes mentioned above, based on the reflectance value of the samples at wavelengths 1024 nm and 1161 nm (El Oufir *et al.*, 2021b). The classifier was then used to calibrate the three specific estimators of the HM (Figure 3-4) using a stepwise multivariate regression. Density estimation using the HM is performed in two steps:

- ❖ Classification of the snow samples into one of the three snow classes using the classifier of the HM;
- ❖ Estimation of each class's density using the corresponding specific estimator (El Oufir *et al.*, 2021b).




Figure 3-4: Density class determination using the hybrid model. The light blue, the marine blue and the dark blue dots indicate the WMM, MHM and HVM classes respectively, and represent the calibration database used to calibrate the corresponding estimators. The grey lines are the two discrimination thresholds used based on wavelengths V1 (1161 nm) and V2 (1024 nm).

### 2.2.2 Development of the ensemble-based system

In order to optimize density estimates using the HM, the sources of uncertainty in classification and estimation must be controlled. For this purpose, we have developed a mixed EBS comprising both classifiers and ensemble-based estimators.

#### ➤ Parameterization of classifiers based on ensembles

The classification thresholds of the HM proposed by the CART algorithm are optimal, but not unique. A simple change in the training database leads to changes in the decision hierarchy. An effective way to control this error is to quantify the threshold uncertainties of the classifiers and to take them into account when estimating the density. Quantifying classifier uncertainty is possible using the bagging algorithm (Breiman, 1996) (n-sampling with replacement;  $n_{\text{bagg}}$  was set to 25 000), which is one of the most commonly used algorithms to build EBSs (Polikar, 2006). It consists of randomly removing a part of the calibration database and to compute a new classifier using the remaining data using the CART algorithm. The result of each iteration is the calculation of a threshold. The end of this step is marked by the development of two random vectors ( $v_1$ ) and ( $v_2$ ) composed of “ $n = 25\ 000$ ” classifiers. The appearance of the thresholds composing the random vectors made it possible to determine a threshold probability distribution for each of the discrimination variables of the HM classifier. This probability is characterized by a mean ( $\mu$ ) and a variance ( $\sigma$ ). These two statistical moments are subsequently used to develop the ensemble-based classifier consisting of a nominal (N), lower (L) and upper (U) threshold. Based on these statistical moments, it was possible to quantify the classification uncertainty by using the following equations:

$$\text{Mean: } \mu_{f(v)} = \int_V f(v) \cdot P(v) \, dv \quad (1)$$

$$\text{Variance: } \sigma_{f(v)}^2 = \int_V (f[v] - \mu)^2 \cdot P(v) \, dv \quad (2)$$

Where  $v$  is the random vector belonging to  $V$ , which represents the space of the input variables of the model,  $f(v)$  is the output of the model and  $P(v)$  is the conditional distribution of the input variables.

Normally, all classification decisions made by the ensemble-based classifier should be retained and the most frequent decision is considered the correct one (Polikar, 2006). This process minimizes the risk of snow samples misclassification. However, taking into account each output of ensemble-based classifiers to make a decision for each processed sample will surely require a huge processing time. Tørvi and Hertzberg (1997) proposed an approach based on the GQF, which converts the probabilistic integrals (equations 1–2) into weighted summations (equations 3–4), which are functions of the original distribution’s optimal  $n$ -thresholds ( $n_{\text{OT}}$ ). Each optimal threshold (OT) is weighted according to its occurrence in the random vector (Table 1), fixed at three in our study. Table 3-1 summarizes the abscissa and weights related to each OT as proposed in the work of Tørvi and Hertzberg (1997),



where the mathematical details of the GQF demonstration and its validation can also be found. Thus, equations (1) and (2) take the following forms:

$$\text{Mean: } \mu = \sum_{i=1}^{n_{OT}} \omega_i \times f(z_i) \quad (3)$$

$$\text{Variance: } \sigma = \sum_{i=1}^{n_{OT}} \omega_i \times f(z_i - \mu)^2 \quad (4)$$

$$OT_i = \mu + \sqrt{\sigma} \times Z_i \quad (5)$$

Where  $\mu$  and  $\sigma$  are respectively the empirical mean and variance of the standardized random vector  $f(z)$ .  $Z_i$  and  $\omega_i$  are respectively the abscissa and weight related to each optimal threshold ( $OT_i$ ; [ $i = 1: n_{OT}$ ]),  $n_{OT} = 3$ .

Table 3-1: Abscissa and weight of the optimal thresholds.

Optimal threshold (OT)	Abscissa ( $Z_i$ )	Weight ( $\omega_i$ )
1	0	1
2	-1, +1	$\frac{1}{2}, \frac{1}{2}$
3	$-\sqrt{3}, 0, +\sqrt{3}$	$\frac{1}{6}, \frac{2}{3}, \frac{1}{6}$

#### ➤ Parameterization of estimators based on ensembles

Due to the complexity of the phenomenon to be modelled, the average of several density estimates will reduce the risk of using a single estimation function. Based on this principle and on the results of the ensemble classifier, it is possible to develop an ensemble estimator. Indeed, by means of the different thresholds calculated, it is possible to divide the calibration database into several sub-databases, allowing the calibration of 15 specific estimators, called “experts” in ensemble estimation (Polikar, 2006). Three subgroups of the WMM snow class, composed of the samples with the highest values (OTV1L, OTV1N, OTV1U), nine subgroups of the MHM snow class, composed of samples in the middle range, and three subgroups of snow class HVM, composed of samples with the lowest values (OTV2L, OTV2N, and OTV2U; Figure 3-5). On the other hand, it has been shown that estimators based on multivariate regression improve the accuracy of the estimation. Expert calibration was therefore carried out using a stepwise regression. One of the great advantages of these experts is that they are not only specific to the class to be modelled, but also to the transition zones from one class to another, which are often problematic to model. This step marks the development of the ensemble-based estimator. Using this scheme, equations 3–4 take the following form:

$$\mu = \sum_{i=1}^p \omega_i \times \text{Est}_{\text{OTV1}_i^{\uparrow}} + \sum_{i=1}^{n_{\text{OT}}-p} \omega_i \times \left[ \sum_{j=0}^k \omega_j \times \left[ \text{Est}_{\text{OTV1}_i^{\uparrow}, \text{OTV2}_j^{\uparrow}} \right] + \sum_{j=0}^k \omega_j \times \left[ \text{Est}_{\text{OTV2}_j^{\uparrow}, \text{OTV1}_i^{\uparrow}} \right] \right]; j = 0 \text{ for } k = 0 \quad (6)$$

$$\sigma = \sum_{i=1}^p [\omega_i \times \text{Est}_{\text{OTV1}_i^{\uparrow}} - \mu]^2 + \sum_{i=1}^{n_{\text{OT}}-p} \omega_i \times \left[ \sum_{j=0}^k \omega_j \times \left[ \text{Est}_{\text{OTV1}_i^{\uparrow}, \text{OTV2}_j^{\uparrow}} - \mu \right]^2 + \sum_{j=0}^k \omega_j \times \left[ \text{Est}_{\text{OTV2}_j^{\uparrow}, \text{OTV1}_i^{\uparrow}} - \mu \right]^2 \right]; j = 0 \text{ for } k = 0 \quad (7)$$

Where  $i$  and  $j$  respectively indicate OTV1 and OTV2 ( $i = 1: n_{\text{OT}}$  and  $j = 1: n_{\text{OT}}$ ; and where 1 refers to lower [L], 2 refers to nominal [N], and 3 refers to the upper threshold [U]; Figure 5);  $\omega_i$  and  $\omega_j$  are the weights associated with each particular optimal threshold for V1 and V2 ( $\omega_1 = \omega_3 = \frac{1}{6}$  and  $\omega_2 = \frac{2}{3}$ ; Table 1); V1 and V2 are the discrimination variables computed by the CART method OTV1 $_i$  and OTV2 $_j$  are the optimal thresholds calculated by the GQF for V1 and V2 (equations 3 and 4); Est $_{\text{OTV1}_i^{\uparrow}}$  is the set of estimators ( $n_{\text{OT}}$ ) trained by the subgroups of the WMM snow class; Est $_{\text{OTV1}_i^{\uparrow}, \text{OTV2}_j^{\uparrow}}$  is the set of estimators ( $n_{\text{OT}}^2$ ) trained by the subgroups of the MHM snow class; Est $_{\text{OTV2}_j^{\uparrow}, \text{OTV1}_i^{\uparrow}}$  is the set of estimators ( $n_{\text{OT}}$ ) trained by the subgroups of the snow class HVM;  $k$  and  $p$  are the indices of the OT related to V1 and V2, respectively ( $k \leq n_{\text{OT}}$  and  $p \leq n_{\text{OT}}$ ). More details are available in Appendix A.

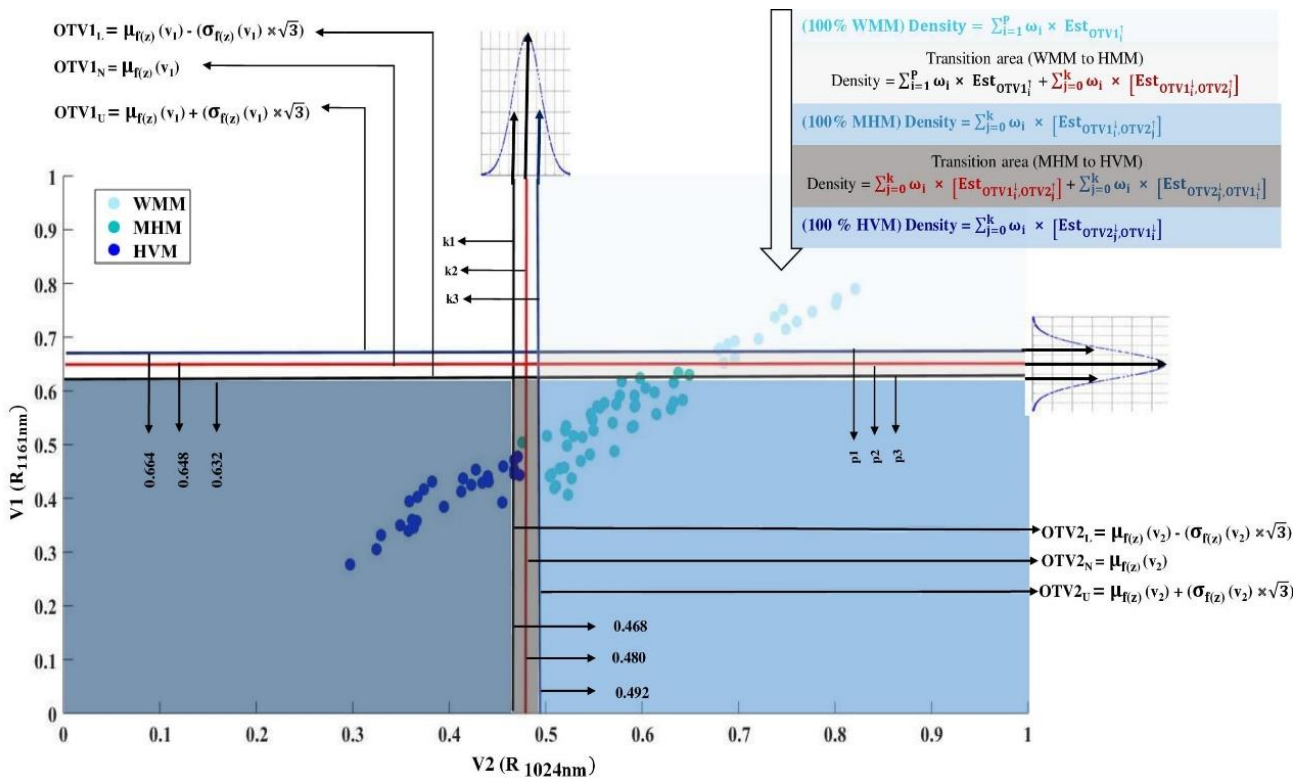


Figure 3-5: The two-dimensional GQF scheme using variables V1 and V2 and its application to calibrate the EBS. The black, red and blue lines represent the optimal thresholds (lower, nominal and upper respectively) for V1 (OTV1L = 0.632, OT1N = 0.648 and OTV1U = 0.664) and V2 (OTV2L = 0.468, OTV2N = 0.480, and OTV2U = 0.492).  $k(1-3)$  and  $p(1-3)$  are the indices of the optimal thresholds associated with V1 and V2. The light blue, marine blue and dark blue points represent the data used for training (WMM, MHM, and HVM, respectively) to calibrate the specific estimators. At the top right is the flow chart of the simplified EBS operational mode. The light blue, marine blue and dark blue boxes designate the areas with WMM, MHM and HVM classes respectively. The overlapping areas in light and dark grey indicate the transitions between low-moderate and moderate-high densities, respectively. The terms of the equations are detailed in Equation 6. A detailed flow chart is presented in Appendix B (Figure 3-11).



### 2.3 Accuracy assessment

Twenty-five percent of the data was systematically selected from the initial database before proceeding to the EBS calibration (every fourth value was selected and set aside starting with low density values). This technique is called split validation. The remaining data were used to calibrate the models by combining an ensemble-based classifier using CART with a multivariate stepwise regression based on fifteen specific estimators. The two models developed were subjected to a robustness test using the k-fold cross-validation method with 1K iterations. The latter is an iterative method (1K times) of random sampling by discount (50% of the data used for calibration and 50% for testing). The k-fold cross-validation approach is summarized in the flow chart in Figure 3-6.

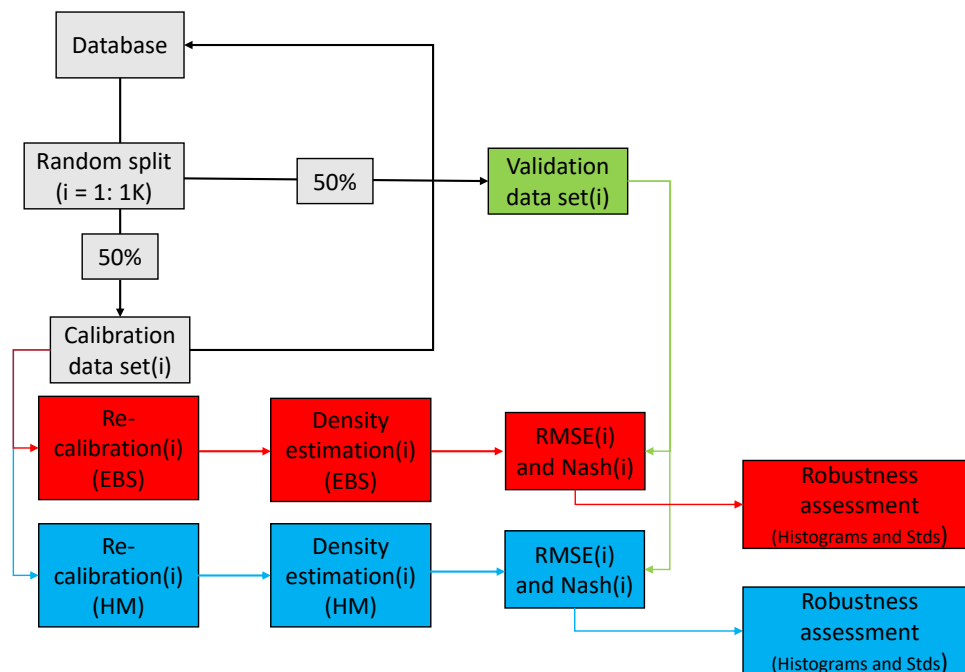


Figure 3-6 : Stability test (k-fold cross-validation) flow chart.

The four statistical indices (equations 8–11) used to assess the EBS are: coefficient of determination ( $R^2$ ), bias (BIAS), root mean square error (RMSE) and NASH-Sutcliffe efficiency (NASH). The NASH criterion assesses performance based on the estimated values and the mean of the in situ measurements. A negative NASH value indicates that the mean of the measurements is more accurate than the model estimates; a NASH value of 1.0 means that the model is perfect (Nash & Sutcliffe, 1970). The mathematical equations for the statistical indices used are as follows:

$$R^2 = \left[ \frac{\sum_{i=1}^n (M_i - \bar{M})(E_{s_i} - \bar{E}_s)}{\sqrt{\sum_{i=1}^n (M_i - \bar{M})^2} \sqrt{\sum_{i=1}^n (E_{s_i} - \bar{E}_s)^2}} \right]^2 \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{E_{s_i} - M_i}{M_i} \right)^2} \quad (9)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n \left( \frac{E_{s_i} - M_i}{M_i} \right) \quad (10)$$

$$NASH = 1 - \frac{\sum_{i=1}^n \left( \frac{E_{s_i} - M_i}{M_i} \right)^2}{\sum_{i=1}^n \left( \frac{M_i - \bar{M}}{\bar{M}} \right)^2} \quad (11)$$

Where: n is the size of the dataset, M and Es are the measured and estimated density values,  $\bar{M}$  and  $\bar{E}_s$  are the measured and estimated means.

### 3. Results and discussion

#### 3.1 Analysis of in situ snow data

Twenty-four snow cores were collected from January 19 to March 27, 2018, from January 10 to April 3, 2019 and from January 29 to March 9, 2020. A total of 114 homogeneous layer samples were collected. In situ snow sample values are grouped by grain size, grain type, and density in Table 3-2, which highlights their variability (El Oufir *et al.*, 2021a). On the basis of these three physical characteristics, each snow layer was associated to one of three snow classes (WMM, MHM and HVM) based on the classification of Pahaut (1975) and the International Classification of Seasonal Snow on the Ground of Fierz *et al.* (2009).

Table 3-2: Distribution of snow density in terms of type and size of snow grains (field data: 2018, 2019 and 2020) (El Oufir *et al.*, 2021a).

Snow class	Type of grain	Grain size (mm)	Number of samples (N)	Density (kg m <sup>-3</sup> )
WMM	$\begin{pmatrix} + \\ \lambda \end{pmatrix}$	< 1 mm	19	100–250
MHM	$\begin{pmatrix} \square \\ \bullet \end{pmatrix}$	1–2 mm	59	150–400
HVM	$\begin{pmatrix} \wedge \\ o \end{pmatrix}$	> 2 mm	36	350–650

#### 3.2 Estimator calibration

By combining the results of the ensemble-based classifiers and estimators, it was possible to achieve a good level of diversity for both parameters since the final snow density estimate is based on at least 3 classifiers and 3 estimators (depending on the snow class to be modelled; Equation 6). The dataset

was separated into 15 subgroups, allowing to train 15 specific ensemble-based estimator. Calibration characteristics for the specific estimators are shown in Table 3-3. The correlation between spectral indices and in-situ density measurements ranged from modest ( $R^2 = 0.77$  for specific estimators 13 and 14 to high ( $R^2 = 0.97$  for estimator 3). It is important to note that the specific estimators designed to estimate the three snow classes (WMM, MHM, and HVM) were trained using linear functions.

Table 3-3: Calibration equations for each specific estimator.  $R^2$  is the coefficient of determination of the multivariate regressions; Samp is the size of the training dataset of each estimator;  $Exp_{var}$  is the explanatory variable; U, N and L are the upper, nominal and lower thresholds; the arrow ( $\uparrow$ ) indicates an estimator trained with data superior to the threshold; and the downward arrow ( $\downarrow$ ) indicates an estimator trained with data inferior the threshold; The colours light blue, marine blue and dark blue refer to the estimators used to calculate the snow density of the WMM, MHM and HVM classes, respectively.

Snow class	Estimator ID	Specific estimator	Calibration equation	$R^2$	Samp	$Exp_{var}$ (nm)
WMM	1	$Est_{TV1\downarrow_L}$	$-1119.75 * SI_{SUB} (1282,941) - 167.59$	0.91	17	1282-941
	2	$Est_{TV1\downarrow_N}$	$-877.36 * SI_{SUB} (1452,968) - 433.25$	0.95	15	1452-968
	3	$Est_{TV1\downarrow_U}$	$-967.69 * SI_{SUB} (1666,935) - 425.24$	0.97	13	1666 – 935
MHM	4	$Est_{TV1\downarrow_U, TV2\downarrow_U}$	$-1491.40 * SI_{NOR} (1600,946) - 951.09$	0.83	45	1600 – 946
	5	$Est_{TV1\downarrow_U, TV2\downarrow_N}$	$-1491.40 * SI_{NOR} (1600,946) - 951.09$	0.83	45	1600-946
	6	$Est_{TV1\downarrow_U, TV2\downarrow_L}$	$-1432.65 * SI_{NOR} (1617,946) - 880.87$	0.84	48	1617- 946
	7	$Est_{TV1\downarrow_N, TV2\downarrow_U}$	$-1397.68 * SI_{NOR} (1617,941) - 854.96$	0.80	43	1617-941
	8	$Est_{TV1\downarrow_N, TV2\downarrow_N}$	$-1397.68 * SI_{NOR} (1617,941) - 854.96$	0.80	43	1617-941
	9	$Est_{TV1\downarrow_N, TV2\downarrow_L}$	$-1427.73 * SI_{NOR} (1617,941) - 877.38$	0.82	46	1617-941
	10	$Est_{TV1\downarrow_L, TV2\downarrow_U}$	$-1480.06 * SI_{NOR} (1600,946) - 940.11$	0.80	41	1600-946
	11	$Est_{TV1\downarrow_L, TV2\downarrow_N}$	$-1480.06 * SI_{NOR} (1600,946) - 940.11$	0.80	41	1600-946
	12	$Est_{TV1\downarrow_L, TV2\downarrow_L}$	$-1419.73 * SI_{NOR} (1617,946) - 868.75$	0.82	44	1617-946
HVM	13	$Est_{TV2\downarrow_U}$	$-26859.26 * SI_{NOR} (979,974,) + 82.90$	0.77	28	979- 974
	14	$Est_{TV2\downarrow_N}$	$-26859.26 * SI_{NOR} (979,974,) + 82.90$	0.77	28	979- 974
	15	$Est_{TV2\downarrow_L}$	$1738.90 * SI_{SUB} (1441,1122) + 1207.81$	0.86	22	1441-1122

It is known that the spectral reflectance of the snow cover results from the effect of different parameters such as the metamorphism, grain size, grain shape, liquid water content, contamination, snow depth, etc. (Dozier, 1989; Warren, 1982; Wiscombe & Warren, 1980). Indeed, the natural aging process of snow significantly affects the size, shape and cohesion of snow grains (Colbeck, 1982), which in turn influences reflectance. The specific estimators were analyzed to identify the wavelengths sensitive to each snow class, which were then used to estimate snow cover density using spectral data. Negi *et al.* (2010) have shown that for changes in liquid water content, grain size, and aging (metamorphism) of snow, the greatest spectral variations are observed between 980 nm and 1160 nm. Eppanapelli *et al.* (2018) suggested that the spectral reflectance of snow in the NIR is inversely proportional to the liquid water content in snow by using the normalized difference water index (NDWI) at 980 nm and 1310 nm. Gallet *et al.* (2009b) used the NIR spectrum to determine the size of snow grains. They found that the 1310 nm wavelength, which corresponds to the central section of the NIR spectrum, is sensitive to small snow grains (low to medium density) and that the 1550 nm wavelength, which corresponds to the higher section of the NIR spectrum, is sensitive to large snow grains (denser).


Our results support the works cited above. Because of snow grain aging (high metamorphosis) and the high liquid water content of the HVM snow class, the shorter wavelengths of the NIR spectrum (979 nm and 974 nm) were the most sensitive wavelengths. We found that the reflectance of short wavelengths of the NIR spectrum is highly correlated with snow grain aging and liquid water content, and this is consistent with the works of Negi *et al.*, 2010. However, for specific estimator 15 (Table 3-3), which represents the transition class from high to moderate densities, wavelengths corresponding to the medium and long wavelengths of the NIR spectrum (1122 nm and 1441 nm) were the most sensitive. The wavelengths sensitive to the snow classes of low and medium density (WMM and MHM), were a mixture of short (968 nm, 946 nm, and 941 nm), medium (1172 nm), and long (1452 nm, 1617 nm, and 1589 nm) wavelengths. This result was somewhat expected as both the WMM and MHM snow classes are composed of low, medium and high density snow blends, representing the different physical characteristics of the aging snow in terms of metamorphosis, liquid water content, and snow grain size and shape.

### 3.3 Evaluation and validation of the ensemble-based system

Validation results obtained with the independent database demonstrate the potential of the EBS as an effective approach for estimating seasonal snowpack density. The performance of the EBS and the HM are compared in Figure 6. The EBS had a coefficient of determination of 0.90, which indicates that it explains up to 90% of the variance in the data. The NASH index indicates that the model is robust with an 89% success rate. The NASH is in fact a more robust statistical index than  $R^2$ , as it compares the estimates to the mean of the observed measurements and is therefore not influenced

by extreme values. An RMSE of  $44.45 \text{ kg m}^{-3}$  for such a range of densities is a very acceptable error. The slightly positive BIAS indicates that the EBS tends to overestimate the snow density. The robustness of the EBS was also confirmed by the scatterplot of the in situ measurements against their estimates (Figure 3-7), where all points are well distributed with respect to the 1:1 line. In summary, the EBS performs similarly to the HM.

It is important to note that for both the HM and EBS models (figures 6a and 6b respectively) we use the same independent database. The general conceptualization of the HM is based on a local classifier and a single specific estimator to calculate the density. In contrast, the EBS is based on a more general and stable classifier, and a combination of several specific estimator outputs driven by different NIR spectral regions (short, medium, and long wavelengths). Indeed, HM modelling is carried out in two steps: 1) classification of the snow samples; and 2) estimation of the density of the classified snow samples using the corresponding specific estimator. Any misclassification error could lead to the selection of the wrong specific estimator, and consequently to an over- or underestimation of the density. An important advantage of the EBS is that the classification errors inherent to the HM are reduced and controlled. It is important to note that it is the way in which snow density is estimated with EBS that makes it more robust. Indeed, EBS modelling is based on the results of several experts trained with different spectral regions, hence their diversity. Thus, for each estimate, if all the experts converge toward the same density values using different spectral regions, this increases the estimation accuracy. On the other hand, even if one of the experts estimates the density incorrectly, averaging its result with those of the other experts allows to control and minimize this error. In fact, according to (Polikar, 2006) “The averaging may or may not beat the performance of the best classifier in the ensemble, but it certainly reduces the overall risk of making a particularly poor selection.



(a)




Figure 3-7: Snow density estimated by the two models (a) EBS and b) HM compared to the in situ measurements for the independent database.

### 3.4 Reliability test

The two developed approaches have undergone a robustness test using the k-fold cross-validation method with 1K iterations. The objective of this test is to quantify the stability and reliability of the two approaches to provide a good estimate of snow density using the bagging technique. The latter is an iterative (1K times) random sampling method by discounting (50% of the data used for calibration and 50% for testing). As expected, the EBS showed great flexibility in providing quality estimates of snow density compared to the HM. The histogram spreads (NASH and RMSE) of the EBS are less wide than those of the HM (Figure 3-8). This behaviour reflects the high robustness and reliability of the EBS ( $\text{std}_{\text{NASH}} = 0.18$  and  $\text{std}_{\text{RMSE}} = 15.04 \text{ kg m}^{-3}$  versus  $\text{std}_{\text{NASH}} = 0.02$  and  $\text{std}_{\text{RMSE}} = 4.27 \text{ kg m}^{-3}$  for the HM and EBS, respectively). Also, the box plot results support the histogram results. The box plots (NASH and MSE) for the MBME are narrower with less data falling outside the normal (box plot) which means that the values, whether NASH or RMSE, belong to the same population, in other words, the EBS estimates for the 1K iterations do not vary much. This is in contrast to the HM results, where we notice more values that fall outside the whisker box and therefore reflect the non-robust nature of the HM (Figure 3-9).




Figure 3-8 : Histograms showing the robustness test between EBS and HM: a) standard deviation (NASHEBS) = 0.02, b) standard deviation (NASHHM) = 0.18, c) standard deviation (RMSEEBS) = 4.27 kg m<sup>-3</sup>, d) standard deviation (RMSEHM) = 16.04 kg m<sup>-3</sup>.




Figure 3-9 : Boxplots representing the distribution of estimated snow density values expressed in a) NASH and b) RMSE, according to the two models EBS and HM.

The EBS is based on a more general classifier and a combination of several specific estimator outputs driven by different NIR spectral regions (short, medium and long). This conceptualisation mitigates any potential misclassification error, unlike that of the MH, leading to the selection of a wrong specific estimator, and consequently to an overestimation or underestimation of the density. On the other hand, since the MBME outputs are based on a set of SE, it is also possible to associate a confidence interval for each estimate, which is neither the case for the HM nor for the standard models.

## 4. Conclusions

In this paper, we proposed to use an EBS to estimate the seasonal snowpack density. We used NIR hyperspectral data (900-1700 nm) at a spectral resolution of 5.5 nm. The EBS was developed to control and attenuate the uncertainties associated with the HM. To enhance the reliability of our approach, we created a set of classifiers and estimators. Several innovative aspects were developed in this approach: 1) The use of in situ physical and optical data collected weekly for three winters (2018 to 2020); 2) The use of an EBS for classification and regression purposes in a proximal remote sensing application; and 3) The use of GQF for runtime optimization. The combination of these points led to the development of a robust method capable of estimating seasonal snowpack density and monitoring its continuous evolution.

The validation technique used to assess the performance of our approach was based on the use of an independent database. The results of the validation with the independent database were satisfactory, with NASH=0.89 and  $R^2=0.90$ , despite some relatively low-density values (90–120 kg m<sup>-3</sup>). However, the validation process showcased that the EBS underestimated density values. Since this is a systematic error, it could be corrected during the modelling process.

The proposed method allows to retrieve robust and accurate density estimates due to the very fine spectral resolution of the NIR hyperspectral sensor. However, the EBS approach is not limited to the NIR spectrum and could be applied to data from any other optical sensor, as high spectral resolution sensors become increasingly available. This new modelling approach could be of great help to water managers in northern regions, by optimizing snow water equivalent estimation. Another application would be to support researchers in their works aimed at understanding the spatio-temporal dynamics of seasonal snowpack's and their metamorphic evolution. The results of the EBS are comparable to those of the HM, but its robustness and accuracy could motivate its preferred use. Another interesting feature is that our system can be easily customized by the addition of other components and classifiers.



## APPENDIX A




An example of the subgroup selection used to calibrate the specific estimators for the brown point case in Figure 3-10. The arrows represent the direction of selection for each optimal threshold used.




The example presented here illustrates the steps taken to select the subgroups used to calibrate the submodels involved in estimating the density under a given physical metamorphosis condition. For example, if we take the case of the brown point on the graph below,  $p$  and  $k$  will be equal to 3. Thus, equations (6) and (7) will take the following forms:

$$\mu = \frac{1}{6} \times \text{Est}_{\text{TV}2_{\text{U}}} + \frac{1}{6} \times \left[ \frac{1}{6} \times \text{Est}_{\text{TV}1_{\text{U}};\text{TV}2_{\text{L}}} + \frac{2}{3} \times \text{Est}_{\text{TV}1_{\text{N}};\text{TV}2_{\text{L}}} + \frac{1}{6} \times \text{Est}_{\text{TV}1_{\text{L}};\text{TV}2_{\text{L}}} \right] + \frac{2}{3} \times \left[ \frac{1}{6} \times \text{Est}_{\text{TV}1_{\text{U}};\text{TV}2_{\text{N}}} + \frac{2}{3} \times \text{Est}_{\text{TV}1_{\text{N}};\text{TV}2_{\text{N}}} + \frac{1}{6} \times \text{Est}_{\text{TV}1_{\text{L}};\text{TV}2_{\text{N}}} \right] \quad (12)$$

$$\sigma = \frac{1}{6} \times \left( \text{Est}_{\text{TV}2_{\text{U}}} - \mu \right)^2 + \frac{1}{6} \times \left[ \frac{1}{6} \times \left( \text{Est}_{\text{TV}1_{\text{U}};\text{TV}2_{\text{L}}} - \mu \right)^2 + \frac{2}{3} \times \left( \text{Est}_{\text{TV}1_{\text{N}};\text{TV}2_{\text{L}}} - \mu \right)^2 + \frac{1}{6} \times \left( \text{Est}_{\text{TV}1_{\text{L}};\text{TV}2_{\text{L}}} - \mu \right)^2 \right] + \frac{2}{3} \times \left[ \frac{1}{6} \times \left( \text{Est}_{\text{TV}1_{\text{U}};\text{TV}2_{\text{N}}} - \mu \right)^2 + \frac{2}{3} \times \left( \text{Est}_{\text{TV}1_{\text{N}};\text{TV}2_{\text{N}}} - \mu \right)^2 + \frac{1}{6} \times \left( \text{Est}_{\text{TV}1_{\text{L}};\text{TV}2_{\text{N}}} - \mu \right)^2 \right] \quad (13)$$

Where  $\mu$  is the weighed average of the density estimate and  $\sigma$  is its variance,  $\text{Est}_{\text{TV}2_{\text{U}}}$  (Figure 6a) is the specific estimator calibrated with the subgroup of the training data set where the spectral index is below the upper optimal threshold of V2. Estimators  $\text{Est}_{\text{TV}1_{\text{U}};\text{TV}2_{\text{L}}}$  (Figure 6b),  $\text{Est}_{\text{TV}1_{\text{N}};\text{TV}2_{\text{L}}}$  (Figure 6c), and  $\text{Est}_{\text{TV}1_{\text{L}};\text{TV}2_{\text{L}}}$  (Figure 6d) are the specific estimators calibrated with the subgroups of training databases where the spectral indices are both above the lower optimal thresholds for V2 and below the lower, nominal and upper optimal thresholds for  $\text{Est}_{\text{TV}1_{\text{U}};\text{TV}2_{\text{N}}}$  (Figure 6e),  $\text{Est}_{\text{TV}1_{\text{N}};\text{TV}2_{\text{N}}}$  (Figure 6f), and  $\text{Est}_{\text{TV}1_{\text{L}};\text{TV}2_{\text{N}}}$  (Figure 6g) are the specific estimators calibrated with the subgroups of training databases where the spectral indices are both above the nominal optimal thresholds for V2 and below the lower, nominal and upper optimal thresholds for V1. This combination of specific estimators is not unique, as it varies according to the snow classes to be modelled ( $p$  and  $k$ ).








Figure 3-10: Scheme of training subgroup selection in one of the moderate snow class cases (brown point).

## APPENDIX B

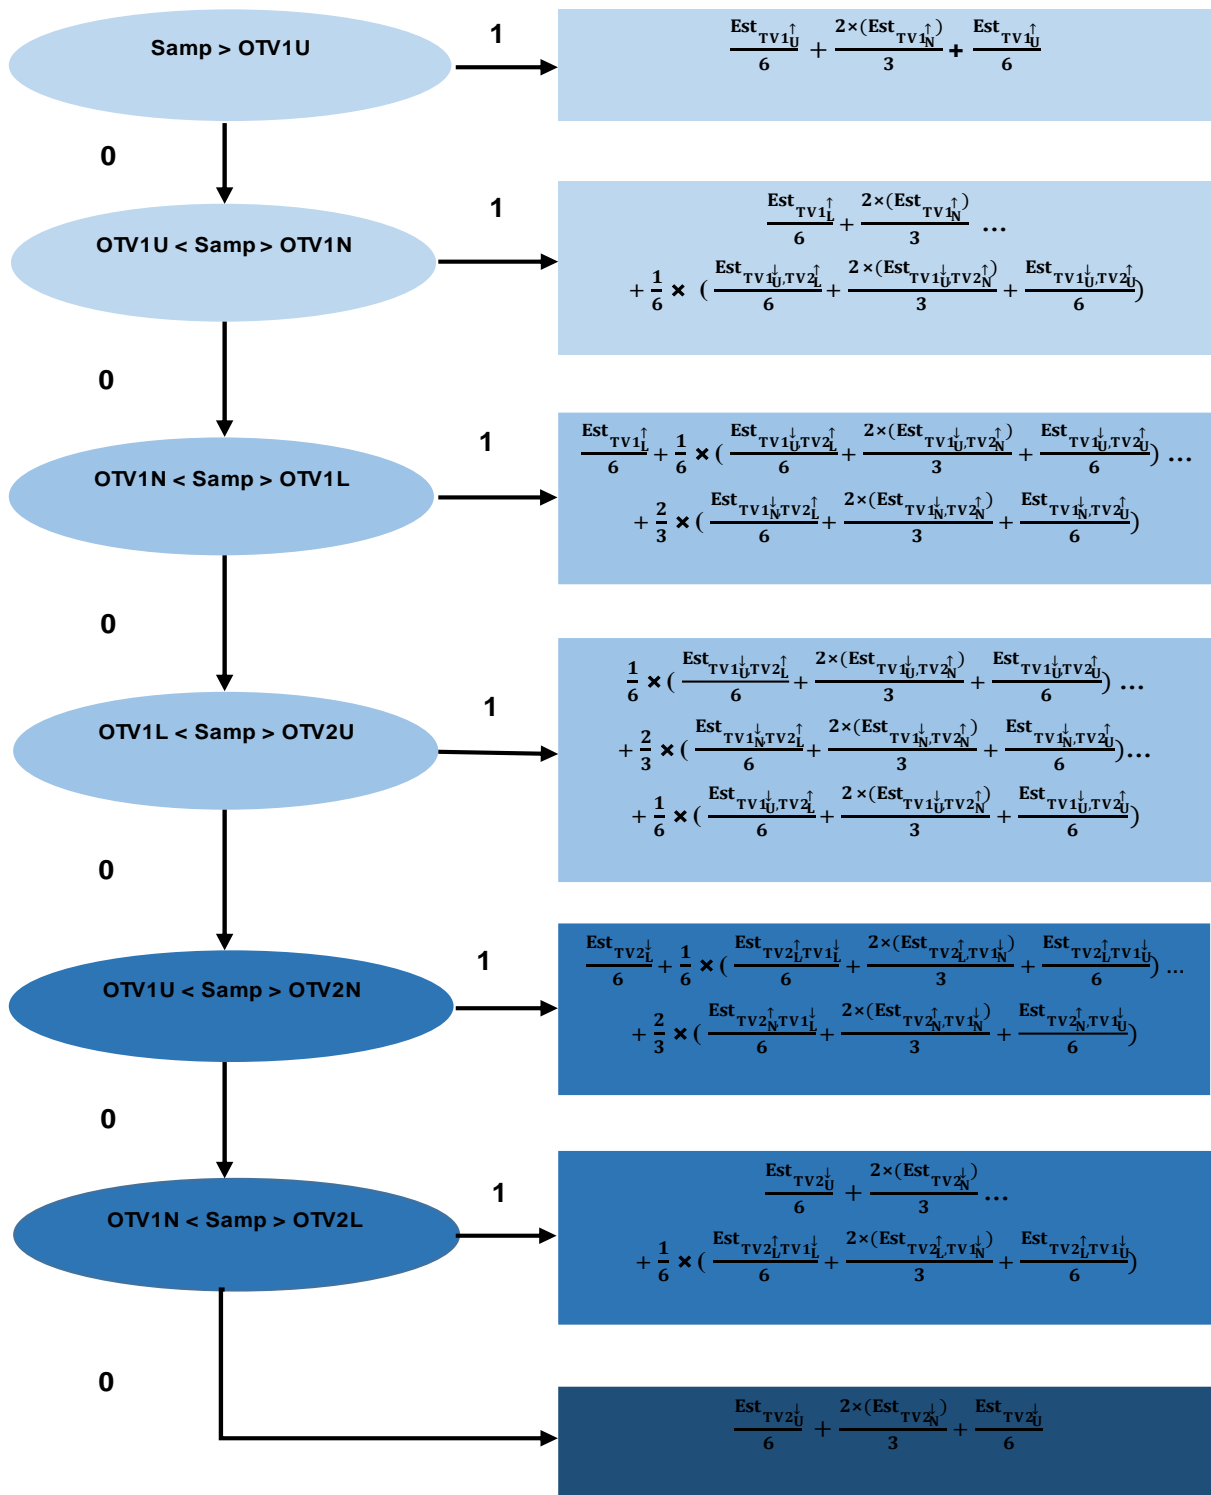


Figure 3-11: Flow chart of the developed algorithm for density estimation (Samp is the number of samples; OTV1 and OTV2 refer to the optimal thresholds of V1 and V2; and Est is the specific estimators as described in Table 3-3).

## 5. REFERENCES

- Alpak FO, Vink JC, Gao G & Mo W (2013) Techniques for effective simulation, optimization, and uncertainty quantification of the in-situ upgrading process. *Journal of Unconventional Oil and Gas Resources* 3:1-14.
- Berisford DF, Molotch NP, Durand MT & Painter TH (2013) Portable spectral profiler probe for rapid snow grain size stratigraphy. *Cold regions science and technology* 85:183-190.
- Breiman L (1996) Bagging predictors. *Machine learning* 24(2):123-140.
- Breiman L, Friedman J, Olshen R & Stone C (1984) Classification and Regression Trees. Monterey, CA: Wadsworth. Wadsworth Statistics/Probability Series. (Wadsworth Advanced Books and Software, Belmont, CA).
- Chan JC-W & Paelinckx D (2008) Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment* 112(6):2999-3011.
- Colbeck S (1982) An overview of seasonal snow metamorphism. *Reviews of Geophysics* 20(1):45-61.
- Domine F, Salvatori R, Legagneux L, Salzano R, Fily M & Casacchia R (2006) Correlation between the specific surface area and the short wave infrared (SWIR) reflectance of snow. *Cold Regions Science and Technology* 46(1):60-68.
- Donahue C, Skiles SM & Hammonds K (2021) In situ effective snow grain size mapping using a compact hyperspectral imager. *Journal of Glaciology* 67(261):49-57.
- Dozier J (1989) Spectral signature of alpine snow cover from the Landsat Thematic Mapper. *Remote sensing of environment* 28:9-22.
- El Oufir MK, Chokmani K, El Alem A, Agili H & Bernier M (2021a) Seasonal Snowpack Classification Based on Physical Properties Using Near-Infrared Proximal Hyperspectral Data. *Sensors* 21(16):5259.
- El Oufir MK, Chokmani K, El Alem A & Bernier M (2021b) Estimating Snowpack Density from Near-Infrared Spectral Reflectance Using a Hybrid Model. *Remote Sensing* 13(20):4089.
- ElMasry G, Sun D-W & Allen P (2012) Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. *Journal of Food Engineering* 110(1):127-140.
- Eppanapelli LK, Lintzén N, Casselgren J & Wåhlin J (2018) Estimation of Liquid Water Content of Snow Surface by Spectral Reflectance. *Journal of Cold Regions Engineering* 32(1):05018001.
- Fierz C, Armstrong RL, Durand Y, Etchevers P, Greene E, McClung DM, Nishimura K, Satyawali PK & Sokratov SA (2009) *The international classification for seasonal snow on the ground*. UNESCO/IHP Paris,

- Gallet J-C, Domine F, Zender C & Picard G (2009a) Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm. *The Cryosphere* 3(2).
- Gallet J-C, Domine F, Zender C & Picard G (2009b) Measurement of the specific surface area of snow using infrared reflectance in an integrating sphere at 1310 and 1550 nm.
- Gergely M, Schneebeli M & Roth K (2010) First experiments to determine snow density from diffuse near-infrared transmittance. *Cold regions science and technology* 64(2):81-86.
- Gray D & Landine P (1988) An energy-budget snowmelt model for the Canadian Prairies. *Canadian Journal of Earth Sciences* 25(8):1292-1303.
- Hansen LK & Salamon P (1990) Neural network ensembles. *IEEE transactions on pattern analysis and machine intelligence* 12(10):993-1001.
- Ismail R & Mutanga O (2010) A comparison of regression tree ensembles: Predicting *Sirex noctilio* induced water stress in *Pinus patula* forests of KwaZulu-Natal, South Africa. *International Journal of Applied Earth Observation and Geoinformation* 12:S45-S51.
- Jacobs RA, Jordan MI, Nowlan SJ & Hinton GE (1991) Adaptive mixtures of local experts. *Neural computation* 3(1):79-87.
- Jordan MI & Jacobs RA (1994) Hierarchical mixtures of experts and the EM algorithm. *Neural computation* 6(2):181-214.
- Kelly K & Krzysztofowicz R (1997) A bivariate meta-Gaussian density for use in hydrology. *Stochastic Hydrology and hydraulics* 11(1):17-31.
- Kinar N & Pomeroy J (2015) Measurement of the physical properties of the snowpack. *Reviews of Geophysics* 53(2):481-544.
- Lorente D, Aleixos N, Gómez-Sanchis J, Cubero S, García-Navarrete OL & Blasco J (2012) Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment. *Food and Bioprocess Technology* 5(4):1121-1142.
- Lu G & Fei B (2014) Medical hyperspectral imaging: a review. *Journal of biomedical optics* 19(1):010901.
- Matzl M & Schneebeli M (2006) *Measuring specific surface area of snow by near-infrared photography.*
- McKay G & Blackwell S (1961) Plains snowpack water equivalent from climatological records. *29th Annual Western Snow Conference.* p 27-43.
- Nash JE & Sutcliffe JV (1970) River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology* 10(3):282-290.
- Negi H, Singh S, Kulkarni A & Semwal B (2010) Field-based spectral reflectance measurements of seasonal snow cover in the Indian Himalaya. *International Journal of Remote Sensing* 31(9):2393-2417.

- Oza NC & Tumer K (2008) Classifier ensembles: Select real-world applications. *Information fusion* 9(1):4-20.
- Pahaut E (1975) *Les Cristaux de neige et leurs métamorphoses*. Direction de la Météorologie nationale,
- Painter TH, Molotch NP, Cassidy M, Flanner M & Steffen K (2007) Contact spectroscopy for determination of stratigraphy of snow optical grain size. *Journal of Glaciology* 53(180):121-127.
- Pielmeier C & Schneebeli M (2003) Stratigraphy and changes in hardness of snow measured by hand, ramsonde and snow micro penetrometer: a comparison with planar sections. *Cold Regions Science and Technology* 37(3):393-405.
- Polikar R (2006) Ensemble based systems in decision making. *IEEE Circuits and systems magazine* 6(3):21-45.
- Schweizer J, Bruce Jamieson J & Schneebeli M (2003) Snow avalanche formation. *Reviews of Geophysics* 41(4).
- Tørvi H & Hertzberg T (1997) Estimation of uncertainty in dynamic simulation results. *Computers & chemical engineering* 21:S181-S185.
- Varade D, Maurya AK, Sure A & Dikshit O (2017) Supervised classification of snow cover using hyperspectral imagery. *2017 International Conference on Emerging Trends in Computing and Communication Technologies (ICETCCT)*. IEEE, p 1-7.
- Varade DM & Dikshit O (2017) A novel linear physical model for remote sensing of snow wetness and snow density using the visible and infrared bands. *AGU Fall Meeting Abstracts*. p C13C-0975.
- Wang S-j, Mathew A, Chen Y, Xi L-f, Ma L & Lee J (2009) Empirical analysis of support vector machine ensemble classifiers. *Expert Systems with applications* 36(3):6466-6476.
- Warren SG (1982) Optical properties of snow. *Reviews of Geophysics* 20(1):67-89.
- Wiscombe WJ & Warren SG (1980) A model for the spectral albedo of snow. I: Pure snow. *Journal of the Atmospheric Sciences* 37(12):2712-2733.
- Zuanon N (2013) IceCube, a portable and reliable instruments for snow specific surface area measurement in the field. *International Snow Science Workshop Grenoble-Chamonix Mont-Blance-2013 proceedings*. p 1020-1023.