

Centre Eau Terre Environnement

**DÉTERMINATION DES EFFETS DES INONDATIONS SUR LA SAISON
DE CULTURE DANS LA RÉGION DU LAC ST-PIERRE AU QUÉBEC**

Par
Rabab Zeroual

Mémoire ou thèse présentée pour l'obtention du grade de
Maître ès Sciences (M.Sc.)

Jury d'évaluation

Président du jury et Examineur interne

Saeid HOMAYOUNI

Professeur, INRS-ETE, Université de Québec

Examineur interne

Karem CHOKMANI

Professeur, INRS-ETE, Université de Québec

Co-directeur de recherche

Kamal EL HAJI

Institut Supérieur des Hautes Études en
Développement Durable

Mohammed ABOU NIANG

Examineur externe

Chercheur, Institut de recherche et
développement en agroenvironnement (IRDA)

REMERCIEMENTS

Je tiens en premier lieu à remercier mon directeur de mémoire, Monsieur Saeid Homayouni pour sa disponibilité, son écoute et ses conseils, tout au long de ces semestres de maîtrise. Nos échanges m'ont été très précieux et j'ai énormément appris à ses côtés.

Merci au directeur de l'ISHÉDD Monsieur Kamal EL Haji et les professeurs de l'ISHÉDD, leurs remarques constructives m'ont permis de progresser. J'adresse également mes remerciements aux professeurs de l'INRS, dont j'ai pu suivre les cours dans le cadre du programme de maîtrise en sciences de l'eau.

Je remercie également Messieurs Karem Chokmani et Mohammed Abou Niang d'avoir accepté d'être membres du jury et d'évaluer ce travail de recherche.

Je remercie l'équipe TENOR, dont le soutien financier m'a permis de mener à bien ce travail de recherche.

Je tiens à exprimer ma profonde gratitude à mes parents, Amina et Riahi, pour leur soutien inébranlable, leur patience et leurs encouragements constants tout au long de ce travail. Ainsi qu'à toutes les personnes qui m'ont soutenue de près ou de loin durant la réalisation de ce mémoire.

C'est certes avec joie et fierté que je dépose aujourd'hui ce mémoire, mais aussi avec un brin de nostalgie que je termine ce programme d'études et je conclus ce travail de recherche.

RÉSUMÉ

Cette étude analyse l'incidence des inondations printanières sur l'agriculture dans la région du lac St-Pierre, au Québec, en se focalisant sur l'événement de 2019. L'objectif principal est d'exploiter les données de télédétection satellitaire et les modèles d'apprentissage automatique pour évaluer l'impact des inondations sur les principales cultures, notamment le blé, le maïs, l'orge et le soja. En raison de sa topographie plane et de son agriculture intensive, cette région est particulièrement vulnérable aux inondations, phénomène accentué chaque printemps par la fonte rapide des neiges combinée à de fortes précipitations.

Dans ce contexte, l'indice de différence normalisée de l'eau modifié (MNDWI) et l'indice de différence normalisée de végétation (NDVI) sont utilisés pour repérer les zones à risque d'inondation et évaluer l'état des cultures avant, pendant et après les crues. L'analyse des variations du NDVI durant ces périodes révèle un ralentissement notable de la croissance, avec des retards de développement pouvant atteindre deux mois. Ce stress physiologique, particulièrement marqué sur le maïs et le blé, confirme l'effet direct des inondations sur la santé des plantations.

L'application de modèles d'apprentissage automatique, en particulier l'algorithme Random Forest, a permis d'identifier de façon précise les secteurs affectés. La méthode a atteint une précision moyenne de 87,2 %, avec un indice de Kappa validé à 0,69, attestant de la robustesse des résultats. Globalement, ces travaux mettent en évidence la fragilité des systèmes agricoles régionaux face aux événements météorologiques extrêmes. L'intégration des images satellites et des outils d'intelligence artificielle offre la possibilité de localiser les zones inondées, de suivre l'évolution de la santé des cultures et de prédire l'impact des inondations à partir des données disponibles. En conclusion, l'étude propose, à la lumière de la littérature récente, plusieurs pistes d'adaptation pour mieux faire face aux conséquences des inondations sur les productions agricoles.

Mots-clés : Inondations ; Agriculture ; Lac St-Pierre ; Télédétection ; NDVI ; MNDWI ; Apprentissage Automatique ; Algorithme de forêt aléatoire ; Changement Climatique.

ABSTRACT

This study examines the effects of spring flooding on agriculture in Quebec's Lake St. Pierre region, with a particular focus on the 2019 flood. The primary objective is to leverage satellite-based remote sensing data and machine learning models to assess the impact of flooding on key crops, including wheat, corn, barley, and soybeans. Characterized by a flat landscape and intensive agricultural practices, this region is especially prone to flooding, a risk that is heightened each spring as rapid snowmelt combines with heavy rainfall.

To identify flood-prone areas and assess crop conditions before, during, and after flooding, the study utilizes the Modified Normalized Difference Water Index (MNDWI) and the Normalized Difference Vegetation Index (NDVI). Analysis of NDVI variations across these time periods reveals a significant slowdown in crop growth, with developmental delays reaching up to two months. This plant stress, most pronounced in corn and wheat, highlights the direct adverse effects of flooding on crop health.

Advanced machine learning methods, particularly Random Forest classification, were employed to delineate flood-affected areas accurately. The methodology achieved a mean accuracy of 87.2%, with a cross-validated Kappa index of 0.69, underscoring the robustness of the results. The findings demonstrate the vulnerability of local agricultural systems to extreme meteorological events. The integration of satellite imagery and artificial intelligence (AI) techniques enables precise detection of inundated zones, continuous monitoring of vegetation health, and improved predictions of flooding impacts on agricultural productivity. The report concludes with recommendations, drawn from the latest academic research, to inform future adaptation strategies against flood-induced risks.

Keywords: Floods; Agriculture; Lac St Pierre; Remote Sensing; NDVI; MNDWI; Machine Learning; Random Forest; Climate change.

TABLES DES MATIERES

REMERCIEMENTS	II
RÉSUMÉ	III
ABSTRACT	IV
TABLES DES MATIERES	V
LISTE DES FIGURES.....	VII
LISTE DES TABLEAUX.....	VIII
LISTE DES ABRÉVIATIONS	IX
1. INTRODUCTION	2
1.1. MISE EN CONTEXTE :	2
1.2. PROBLEMATIQUE :	3
1.3. OBJECTIFS :	4
1.4. STRUCTURE DU MEMOIRE :	4
2. REVUE DE LA LITTÉRATURE	5
2.1. CHANGEMENTS CLIMATIQUES DANS LA REGION DU QUEBEC :	5
2.2. VULNERABILITE AGRICOLE AU QUEBEC :	5
2.3. INONDATIONS DU LAC ST-PIERRE :	6
2.4. IMPACTS DES GELS TARDIFS ET GELS PRECOCES SUR LES TERRES AGRICOLES :	6
2.5. NOTIONS SUR LA TELEDETECTION :	8
2.5.1. Concepts de base et applications :	8
2.5.2. Capteurs satellitaires :	8
2.5.3. Indices spectraux :	10
2.6. TECHNIQUES DE MODELISATION DES IMPACTS DES INONDATIONS :	12
2.6.1. Modèles hydrodynamiques :	13
2.6.2. Modèles basés sur un SIG :	14
2.6.3. Modèles statistiques :	15
2.7. ÉTUDES DE CAS CONCERNANT LE LAC ST-PIERRE ET LE FLEUVE ST-LAURENT :	16
2.8. INTEGRATION DE L'APPRENTISSAGE PROFOND ET DE L'INTELLIGENCE ARTIFICIELLE :	17
2.8.1. Simulation numérique et observation terrestre :	18
2.8.1. Classification des images par Random Forest :	19
2.9. VALIDATION CROISEE ET LIMITES DES APPROCHES D'INTELLIGENCE ARTIFICIELLE EN TELEDETECTION (CAS SENTINEL-2) :	20
2.7. CONCLUSION :	21
3. MATÉRIELS ET METHODE :	22
3.1. ZONE D'ETUDE :	22
3.2. DONNEES ET OUTILS :	23

3.2.1. <i>Google Earth Engine</i> :	23
3.2.2. <i>Programmation sous le langage R</i> :	23
3.3.3. <i>Classification Sentinel-2 de la végétation impactée</i> :	24
3.2.5. <i>Méthode d'entraînement et hyperparamètre</i> :	26
3.3. ORGANIGRAMME METHODOLOGIQUE :	27
4. RÉSULTATS	29
4.1. CARTOGRAPHIE DES ZONES INONDEES :	29
4.2. SUPERPOSITION DES INDICES :	30
4.3. CARTE DES ZONES INONDEES :	31
4.4. ANALYSE TEMPORELLE DE LA VEGETATION :	32
4.5. VISUALISATION SPATIO-TEMPORELLE DE CARTE DE CHALEURS DU NDVI :	35
4.6. CLASSIFICATION DES ZONES INONDEES PAR APPRENTISSAGE AUTOMATIQUE (APPROCHE RANDOM FOREST) :	37
4.7. VALIDATION CROISEE PAR MATRICE DE CONFUSION ET INDICE KAPPA :	38
4.8. ANALYSE COMPARATIVE DE L'IMPACT DES INONDATIONS SUR QUATRE CULTURES ENTRE 2017/2018 ET 2018/2019 :	40
5. DISCUSSION ET INTERPRETATION	42
6. CONCLUSION	45
7. BIBLIOGRAPHIE	46

LISTE DES FIGURES

Figure 1 : Approches méthodologique de modélisation	22
Figure 2 : Localisation de la zone d'étude.....	23
Figure 3 :Organigrme de méthodologie de travail.....	28
Figure 4: Visualisation de la zone inondée en 2019 en RGB.....	29
Figure 5 :Visualisation en fausses couleurs de la zone inondée en 2019.....	30
Figure 6 : Comparaison MNDWI pendant et après la crue d'avril 2019	31
Figure 7: Comparaison MNDWI pendant et après la crue d'avril 2019	31
Figure 8: Carte des zones inondées par MNDWI	32
Figure 9. Évolution NDVI d'un pixel représentatif (blé, maïs, orge, soja).....	34
Figure 10. Évolution temporelle du NDVI sur parcelles représentatives (blé, maïs, orge, soja) ...	35
Figure 11: Visualisation du NDVI en carte thermique par type de culture	36
Figure 12 : Classification par Random Forest des cultures affectées.....	37
Figure 13 : Matrice de confusion.....	41

LISTE DES TABLEAUX

Tableau 1 : Synthèse des dates de semis et de l'évolution du NDVI selon les espèces cultivées...	41
--	----

LISTE DES ABRÉVIATIONS

- **2D:** Deux Dimensions
- **AUC:** Area Under the Curve
- **APSIM:** Agricultural Production Systems Simulator
- **BOA:** Bottom of Atmosphere
- **CNN:** Convolutional Neural Network
- **DEM :** *Digital Elevation Model*
- **FEWS:** Flood Early Warning Systems
- **GEE:** Google Earth Engine
- **GFI:** Gestion des Fenêtres d’Inondation
- **GIS :** Geographic Information System
- **HAND:** Height Above Nearest Drainage
- **IPCC:** Intergovernmental Panel on Climate Change
- **LSP :** Lac St-Pierre
- **MAPAQ,** Ministère de l’Agriculture, des Pêcheries et de l’Alimentation du Québec
- **MDDEFP:** Ministère du Développement durable, de l’Environnement, de la Faune et des Parcs
- **MNA:** Mean Normalized Altitude
- **MNDWI:** Modified Normalized Difference Water Index
- **MSI :** Multispectral Instrument
- **MSS :** Multispectral Scanner
- **MODIS:** Moderate Resolution Imaging Spectroradiometer
- **NASA :** National Aeronautics and Space Administration
- **NDBI:** Normalized Difference Built-up Index

- **MOM:** Model of Model
- **NDSI:** Normalized Difference Snow Index
- **NDVI :** Normalized Difference Vegetation Index
- **NDWI :** Normalized Difference Water Index
- **NOAA:** National Oceanic and Atmospheric Administration
- **NRMSE:** Normalized Root Mean Square Error
- **RCP :** Representative Concentration Pathway
- **RBV :** Return Beam Video
- **RGB :** Red-Green-Blue
- **RNA:** Artificial Neural Network
- **S2 :** Sentinel-2
- **S2A :** Sentinel-2 A
- **SAV:** Soil-Adjusted Vegetation Index
- **SIAC:** Simplified Image Analysis and Correction
- **SIG :** Système d'Information Géographique
- **St :** Saint
- **TM :** Thematic Mapper
- **TOA :** Top of Atmosphere
- **WOFOST :** World Food Studies

1. INTRODUCTION

1.1. Mise en contexte :

Le Québec, situé dans l'est du Canada, se caractérise par une géographie complexe dominée par un vaste réseau hydrographique et soumise à d'importantes variations climatiques saisonnières. Cette configuration en fait une région particulièrement vulnérable aux inondations printanières, un phénomène hydrométéorologique récurrent dont les répercussions sur le territoire suscitent une préoccupation croissante. Ces événements, généralement provoqués par la fonte rapide des neiges combinée à des précipitations abondantes, entraînent une élévation brutale du niveau des cours d'eau et inondent de manière récurrente les zones riveraines et agricoles. Selon le *Rapport sur les inondations printanières au Québec* (Gouvernement du Québec, 2019), environ quinze épisodes d'inondations majeures ont été recensés au cours des deux dernières décennies, affectant principalement les terres situées en bordure des rivières et des lacs.

L'inondation du printemps 2019 se distingue par son ampleur exceptionnelle et ses impacts particulièrement dévastateurs, en particulier dans la région du lac St-Pierre. Cet épisode a submergé près de 1 000 hectares de terres agricoles, perturbant la production de cultures stratégiques telles que le maïs, le blé, l'orge et le soja. Selon le Rapport économique de l'Union des producteurs agricoles (2019), les pertes économiques associées à cet événement ont été estimées à plus de 10 millions de dollars canadiens, illustrant la forte vulnérabilité des exploitations agricoles face aux aléas climatiques extrêmes.

La submersion des terres agricoles engendre des pertes économiques directes pour les exploitants, liées à la diminution des rendements, à la dégradation des infrastructures et à l'interruption des cycles de production. À plus long terme, ces événements compromettent à la fois la sécurité alimentaire et la viabilité économique des exploitations. Ces perturbations s'inscrivent dans une tendance plus large : l'intensification des phénomènes climatiques extrêmes sous l'effet du réchauffement global. Le Sixth Assessment Report du Groupe d'experts intergouvernemental sur l'évolution du climat (*Intergovernmental Panel on Climate Change*, IPCC, 2021) indique que la probabilité d'occurrence de crues soudaines a augmenté de près de 30 % en Amérique du Nord au cours des cinquante dernières années. Dans ce contexte, la présente recherche vise à analyser les impacts spécifiques de l'inondation de 2019 sur la saison de croissance des cultures agricoles autour du lac St-Pierre. En mobilisant conjointement les données issues de la télédétection et les

techniques d'intelligence artificielle, ce travail a pour objectif de quantifier les perturbations agricoles et d'en évaluer les implications sur les cycles de culture.

1.2. Problématique :

Les inondations printanières constituent un phénomène naturel récurrent dans la région du lac St-Pierre, affectant gravement les terres agricoles environnantes. Toutefois, la quantification précise de leur impact sur l'agriculture demeure un défi majeur, en raison de l'insuffisance des observations de terrain et du caractère sporadique des données disponibles. Cette situation limite la compréhension fine des effets des inondations sur la dynamique des cultures et complique la mise en œuvre de stratégies efficaces de gestion et d'adaptation.

Depuis 2017, une intensification des événements climatiques extrêmes, tels que des précipitations plus abondantes et de fortes variations de température, a été observée. Cette évolution a accentué la fréquence et la gravité des inondations, mettant en évidence la vulnérabilité croissante des terres agricoles face au changement climatique.

Dans ce contexte, les images satellites, en particulier celles issues des capteurs optiques Sentinel-2, offrent des perspectives prometteuses pour le suivi spatial et temporel des inondations. Par ailleurs, les limites des observations traditionnelles peuvent être partiellement surmontées grâce à l'intégration d'indices spectraux tels que le NDVI, le NDSI et le MNDWI dans des modèles d'apprentissage automatique. Plusieurs études ont démontré l'efficacité de ces approches pour cartographier les zones inondées et évaluer leurs impacts environnementaux à différentes échelles. Toutefois, peu d'entre elles ont spécifiquement appliqué ces méthodes à l'analyse des impacts agricoles des inondations dans la région du lac St-Pierre.

La présente recherche propose de développer une approche intégrée afin d'estimer l'impact des inondations printanières sur les cultures agricoles en mobilisant des données satellitaires optiques et des modèles d'apprentissage automatique. Plus précisément, il s'agira d'identifier les zones inondées, d'analyser les effets sur la santé des cultures à travers le suivi des indices de végétation et de classer les surfaces agricoles affectées à l'aide de techniques de classification supervisée. L'approche repose sur l'utilisation conjointe de méthodes de traitement d'images, de classification et d'analyse temporelle appliquées à différentes cultures. L'objectif de ce travail est ainsi d'analyser en profondeur les impacts des inondations sur l'agriculture dans la région du lac St-

Pierre, en mettant particulièrement en évidence les conséquences spécifiques de la crue exceptionnelle d'avril 2019 sur les systèmes agricoles locaux.

1.3. Objectifs :

L'objectif principal de cette étude est de mettre en œuvre une approche intégrée qui fusionne les données provenant des satellites d'observation de terre avec des modèles d'intelligence artificielle pour classer et évaluer les conséquences des crues printanières sur l'activité agricole dans la zone avoisinant le lac St-Pierre.

Les objectifs spécifiques de cette démarche sont les suivants :

- Identifier et cartographier les régions agricoles sujettes aux inondations à l'aide d'indicateurs spectraux (tels que le MNDWI), en exploitant des images Sentinel-2 prétraitées.
- Analyser les conséquences des inondations sur la santé des cultures agricoles en étudiant les changements dans les indices de végétation (notamment le NDVI), avant, durant et après l'événement d'inondation.
- Analyser les zones impactées de productivité agricole et en utilisant des méthodes d'apprentissage automatique, à partir d'un ensemble de variables explicatives.

1.4. Structure du mémoire :

Le mémoire est structuré en sections suivant une progression méthodologique, comme détaillé ci-dessous ;

- **La section 1** présente une introduction générale. Elle fait ressortir le contexte de l'étude, la problématique et l'importance de la recherche.
- La section 2 comprend une revue de la littérature sur l'utilisation de la télédétection dans l'analyse de santé des terres agricoles. La première section se termine par une présentation de la structure générale du mémoire.
- **La section 3** détaille la méthodologie adoptée pour réaliser l'étude. Elle présente les données satellitaires utilisées, décrit les étapes de traitement des données et explique les techniques d'analyse, telles que la télédétection et l'apprentissage profond.
- **La section 4** présente les résultats obtenus et leur analyse. Elle inclut également une comparaison entre une année inondée et une année non inondée.
- Enfin, **la section 5** propose une discussion sur les résultats obtenus, les possibles contributions de l'étude ainsi que les perspectives de recherche future.

2. REVUE DE LA LITTÉRATURE

Cette section a pour but d'explorer à travers la revue de littérature la problématique des inondations et leur effet sur la saison de croissance des cultures. Elle passe également en revue l'apport possible de la télédétection dans un tel contexte. Dans un premier temps, la durée de croissance des cultures ainsi que les notions fondamentales de télédétection sont présentées. Ensuite, les principaux indices utilisés dans cette étude sont décrits. La troisième section est consacrée aux définitions des inondations et du changement climatique. Enfin, les projets antérieurs et récents portant sur ces thématiques sont examinés.

2.1.Changements climatiques dans la région du Québec :

La température moyenne annuelle de la région du Québec a augmenté de 1,1° C entre 1948 et 2016. La température annuelle moyenne de l'air est prévue augmenter pour la période de 2031 à 2050 de 1,5 °C³⁷ (de 1,0 à 2,1) pour un scénario de faibles émissions (RCP2.6) à 2,3 °C (de 1,7 à 2,9) pour un scénario d'émissions élevées (RCP8.5) et de 1,7 °C (de 1,0 à 2,2) (RCP2.6) à 6,3 °C (de 5,3 à 6,9) (RCP8.5) pour la période de 2081 à 2100 par rapport à la base de référence de 1986 à 2005 (Takaro et al., 2022).

Selon deux scénarios précédents d'Ouranos³, les changements climatiques pourraient entraîner une augmentation des températures annuelles moyennes de 1,7 à 4,6°C dans le sud du Québec et de 1,9 à 5,8°C dans le nord d'ici 2050. Des anomalies de température importantes ont un impact significatif sur la période de gel-dégel, les degrés-jours de croissance de la végétation et la période de fonte des neiges (Institut de la statistique de Québec,2023).

2.2.Vulnérabilité agricole au Québec :

L'agriculture occupe une place centrale dans l'économie et l'aménagement du territoire québécois. Toutefois, ce secteur est particulièrement vulnérable aux effets des changements climatiques, notamment en ce qui concerne la production et le rendement des cultures. En effet, l'augmentation des émissions de gaz à effet de serre contribue à modifier les conditions climatiques, ce qui affecte directement la productivité agricole. La culture de grains occupe la troisième place en importance, les agriculteurs québécois cultivent le maïs, soja, les céréales (blé, orges) et le canola. Les principales régions productrices de grains, en superficie, sont la Montérégie (62 %), le Centre-du-Québec (15 %), Montréal, Laval et Lanaudière (7 %), la Capitale-Nationale et la Mauricie (6 %) et Chaudière-Appalaches (5 %) (MAPA, 2019).

2.3. Inondations du lac St-Pierre :

Le lac St-Pierre mesure près de 30 kilomètres de long et 13 kilomètres de large. C'est le dernier bassin d'eau douce du cours supérieur de l'estuaire du fleuve St-Laurent. Il se caractérise par une topographie plane, à l'origine de la plus vaste plaine inondable d'eau douce du Québec. Autour du lac St-Pierre, les zones inondées (en moyenne tous les deux ans) sont appelées le littoral. Composé de milieux humides, de marais et de terres cultivées, ce littoral a une fonction écologique importante pour l'écosystème du lac St-Pierre. Le littoral du lac St-Pierre s'est largement développé en agriculture de soja, maïs et blé (Pole au gestion durable du littoral, 2020). Ce grand lac fluvial (~ 300 km²) peu profond (~ 3 m) est une extension du fleuve St-Laurent (Farly et al., 2019) et comprend 28 000 ha de terres submergées et de zones riveraines dans la zone de récurrences de 0 à 2 années d'inondations côtières (MDDEFP, 2013).

La plaine de lac St-Pierre est une région vulnérable, facilement inondée, où le risque est accentué par le changement climatique. En 2019, le niveau du lac St-Pierre n'a jamais été aussi élevé, ce qui a provoqué des inondations dans de nombreuses villes. Les municipalités locales qui sont situées près du lac St-Pierre ont été touchées. Les forces armées canadiennes ont été appelées en renfort à Trois-Rivières, à Maskinongé, à Nicolet et à Bécancour (Gouvernement du Québec, 2023).

Les eaux de crue ont également inondé des terres agricoles dans la région, entraînant des pertes de récoltes, en particulier dans les zones où les champs ont été submergés (Paradis A et al., 2015). Les agriculteurs ont subi d'importantes pertes financières, et certains champs sont restés non cultivables pour le reste de l'année (St Laurent et al., 2010). Les inondations ont intensifié l'érosion dans certaines zones des rives du lac, affectant les paysages naturels et les bâtiments culturels.

La plaine inondable du lac St-Pierre était historiquement considérée par les agriculteurs locaux comme pâturage et est maintenant utilisée pour des activités agricoles industrielles. La superficie consacrée aux cultures annuelles comme le maïs et le soja a augmenté de 225 % entre 1950 et 1997 (De La Chenelière et al., 2014).

2.4. Impacts des gels tardifs et gels précoces sur les terres agricoles :

Dans le cas des inondations de 2019 au lac St-Pierre, les conditions climatiques extrêmes ont joué un rôle déterminant dans la genèse et l'amplification du phénomène. Les températures anormalement élevées enregistrées en début d'année ont provoqué une fonte précoce et rapide du manteau neigeux, ce qui a entraîné une surcharge hydrologique des sols et des cours d'eau,

accentuant le risque de crue printanière. À cette dynamique s'est ajouté un retour de températures froides au printemps, qui a entraîné des conséquences directes sur le développement des cultures. Ces conditions ont contribué à retarder la croissance végétative, voire à endommager certaines plantations sensibles au gel, notamment lors des phases critiques de germination et d'émergence (Bélanger et al., 2006).

De nombreuses études ont montré que les températures glaciales printanières constituent un facteur de stress majeur pour les cultures. Le gel peut entraîner la rupture des cellules végétales, en raison de l'expansion de l'eau intracellulaire lors de sa transformation en glace, ce qui provoque la nécrose des tissus (Brown et Blackburn, 1987). Les feuilles, les tiges et, dans certains cas, les racines, peuvent ainsi être sévèrement endommagées, compromettant la capacité photosynthétique des plantes, ralentissant leur croissance et réduisant leur rendement potentiel. Ces effets sont particulièrement préoccupants pour des cultures stratégiques telles que le maïs et le soja, dont les stades précoces de développement (germination, levée) sont très sensibles aux épisodes de gel.

Par ailleurs, les gelées précoces à l'automne ou tardives au printemps constituent une contrainte agronomique bien documentée, car elles perturbent la phénologie des cultures. En retardant la maturation des plantes, elles compromettent la planification des semis et de la récolte, ce qui accroît les pertes agricoles, en particulier si les cultures sont exposées au gel peu de temps avant la récolte (Bélanger et al., 2006). Dans de telles conditions, les grains de maïs ou les gousses de soja peuvent être partiellement détruits ou perdre de leur valeur commerciale, entraînant des pertes économiques directes. Les impacts des épisodes de gel ne se limitent pas aux dommages physiologiques immédiats sur les cultures. Ils engendrent également des répercussions indirectes sur la qualité des sols et la gestion des pratiques culturales. Les sols saturés par la fonte rapide des neiges et pluies abondantes réduisent l'infiltration et aggravent le risque d'érosion, accentuant les difficultés d'implantation des cultures. Les producteurs agricoles doivent alors adapter leurs calendriers de semis, modifier les densités de plantation ou recourir à des variétés plus résistantes au froid, ce qui implique des coûts supplémentaires et une incertitude accrue dans la gestion des systèmes agricoles (Rupngam et al., 2024).

Enfin, la littérature scientifique souligne que la combinaison de la fonte rapide des neiges, des précipitations abondantes et des épisodes de gel printanier illustre la vulnérabilité croissante des systèmes agricoles face à la variabilité climatique. Ces événements extrêmes tendent à se multiplier

sous l'effet du changement climatique, ce qui renforce la nécessité d'outils de surveillance et de modélisation permettant d'anticiper leurs impacts. Les données satellitaires, couplées à des approches d'apprentissage automatique, offrent ainsi une opportunité pour mieux comprendre et évaluer la résilience des cultures soumises à ces aléas.

2.5. Notions sur la télédétection :

2.5.1. Concepts de base et applications :

- **Définition de la télédétection :**

La télédétection est une technique qui consiste à collecter des informations sur un objet ou une zone sans contact direct, à l'aide de capteurs pour détecter et mesurer l'énergie réfléchie ou émise par la surface de la Terre. Ces capteurs sont généralement montés sur des satellites, des drones ou des avions, et les données collectées sont ensuite analysées pour obtenir des informations sur les conditions de la surface observée. (Centre canadien de télédétection, 2024).

- **Applications de la télédétection dans l'agriculture :**

La télédétection permet de suivre l'état des cultures en identifiant les changements dans la couleur des plantes. Les changements de couleur observés peuvent être dus à un manque d'eau ou à la présence de maladies. Les images acquises par satellite ou par drone fournissent des informations précieuses sur les besoins en eau, les carences en nutriments, ainsi que sur la présence éventuelle de ravageurs et de maladies (Ressources naturelles Canada, 2014).

La télédétection permet d'identifier et de classer divers types de surfaces terrestres, notamment les forêts, les zones agricoles, les plans d'eau et les zones urbaines. Ces données aident à suivre les changements dans l'utilisation des terres, à évaluer la déforestation, à gérer les ressources naturelles et à planifier le développement urbain (Centre Canadien de télédétection, 2024).

La télédétection permet d'observer et d'analyser des paramètres environnementaux comme la santé des plantes, la qualité de l'eau, la pollution de l'air et les signes du changement climatique. Elle aide à surveiller et à comprendre les phénomènes naturels tels que les feux de forêt, les sécheresses et la fonte des glaciers polaires.

2.5.2. Capteurs satellitaires :

- a. Capteurs Landsat et résolution radiométrique :**

Les systèmes de caméras RBV, Le *Multispectral Scanner* (MSS) et le *Thematic Mapper* (TM) sont deux capteurs optiques utilisés pour l'observation de la Terre. Le capteur MSS, lancé pour la première fois à bord du satellite Landsat 1 en 1972, permettait de capter des images dans plusieurs bandes spectrales, principalement dans le visible et le proche infrarouge. Le capteur TM, introduit avec Landsat 4 en 1982, représente une amélioration majeure en offrant une meilleure résolution spatiale et un plus grand nombre de bandes spectrales. Ces deux capteurs font partie des différents instruments embarqués sur les satellites de la série Landsat, largement utilisés pour la télédétection environnementale, notamment en cartographie des inondations et en suivi des terres agricoles. Les systèmes MSS et le TM font partie des différents capteurs portés par les satellites de la série Landsat. Chaque capteur couvre une bande de 185 km et capture une scène complète mesurant 185 km sur 185 km. Le capteur MSS capte le rayonnement électromagnétique de la surface de la Terre sur quatre bandes spectrales. Chaque bande a une résolution spatiale de 60 mètres sur 80 et une résolution radiométrique de 6 octets, équivalente à 64 valeurs numériques. Utilisant un scanner mécanique avec un miroir oscillant, le MSS collecte les rayonnements. Lors de chaque balayage est-ouest du miroir, six lignes de balayage peuvent être collectées simultanément. Conçu à l'origine pour évaluer la faisabilité d'une plateforme d'observation de la Terre multispectrale sans pilote, le programme Landsat a depuis facilité la collecte de données provenant des quatre coins du globe. En 1983, le programme est passé de la gestion de la NASA à la responsabilité de la NOAA. Deux ans plus tard, le programme a été commercialisé pour répondre aux besoins en données de divers utilisateurs civils (Centre canadien de télédétection, 2024).

b. Capteurs Sentinel-2 :

Grâce au programme Copernicus, l'Agence spatiale européenne fournit gratuitement des images satellitaires Sentinel-2. Ces images satellitaires sont dotées des mesures de la réflexion à la base de l'atmosphère et d'une résolution spatiale de 10 mètres pour certaines bandes spectrales. Le traitement des images utilise le processeur Sen2Cor pour les corrections atmosphériques. (Gascon et al., 2017)

c. Capteurs MODIS :

En télédétection environnementale, le capteur satellite MODIS est un outil clé qui fournit des données multispectrales à haute fréquence et à des résolutions variées (de 250 m à 1 km) pour une surveillance globale de la Terre. Il permet d'analyser une multitude de phénomènes

environnementaux, notamment l'état de la végétation (à travers des indices comme le NDVI), la qualité de l'air (mesure des aérosols), la couleur et la température des océans, ainsi que les glaces, les neiges et les catastrophes naturelles comme les incendies ou les inondations. Grâce à ses 36 bandes spectrales et à sa couverture presque quotidienne, MODIS joue un rôle fondamental dans l'étude des changements climatiques, la gestion des ressources naturelles et le suivi des dynamiques environnementales à l'échelle mondiale (MODIS Web, 2025).

2.5.3. Indices spectraux :

a. NDVI :

Le NDVI est un indice spectral qui permet d'évaluer la vigueur et la densité de la végétation. Il est calculé à partir des différences de réflectance entre le proche infrarouge, fortement réfléchi par les tissus végétaux, et le rouge, fortement absorbé par la chlorophylle. L'équation de NDVI par défaut documentée est la suivante :

$$NDVI = \frac{IR-R}{IR+R} \quad (\text{Eq. 1})$$

Avec **IR** = valeurs de pixel du canal infrarouge, et **R** = valeurs de pixel du canal rouge.

La plage de valeurs produites par l'indice s'étend de -1,0 à 1,0, indiquant principalement l'étendue de la couverture végétale. Les valeurs négatives sont principalement associées aux nuages, à l'eau et à la neige, tandis que les valeurs proches de zéro indiquent un terrain rocheux ou aride. Les valeurs NDVI extrêmement faibles (0,1 ou moins) correspondent à des surfaces dépourvues de végétation comme des rochers, du sable ou de la neige. Des valeurs modérées (0,2 à 0,3) indiquent la présence d'arbustes et de prairies, tandis que des valeurs élevées (0,6 à 0,8) indiquent l'existence d'une végétation saine (Pettorelli et al. 2005).

Le pigment appelé chlorophylle, qui sert d'indicateur fiable de la santé, possède une capacité remarquable à capter la lumière visible, tandis que la structure des feuilles reflète la lumière proche infrarouge de manière très prononcée. Dans les cas où une plante souffre de déshydratation, de maladie ou de circonstances similaires, la couche spongieuse se détériore, provoquant une augmentation de l'absorption de la lumière proche infrarouge au lieu de sa réflexion. Par conséquent, en examinant les disparités entre la lumière proche infrarouge et la lumière rouge, on

peut effectivement vérifier l'existence de la chlorophylle, un déterminant essentiel du bien-être des plantes (Pettorelli et al. 2005) (Felegari et al.,2022).

b. NDSI :

Le NDSI est un indice utilisé pour cartographier la neige. Il quantifie la différence de réflectance entre le spectre vert et le SWIR (infrarouge à ondes courtes), en comparant les bandes du visible et du proche infrarouge.

La neige est reconnue pour sa forte réflectance dans le spectre visible, mais elle absorbe également une quantité importante de rayonnement dans le proche infrarouge et l'infrarouge à ondes courtes. À l'inverse, les nuages conservent un niveau de réflectance élevé dans ces régions du spectre. Par conséquent, le NDSI constitue un outil essentiel pour distinguer la neige des nuages, les différences de réflectance dans ces bandes étant particulièrement marquées (Salomonson et al.,2006).

La formule du NDSI est la suivante :

$$NDSI = \frac{B_{green} - B_{SWIR}}{B_{green} + B_{SWIR}} \quad (Eq. 2)$$

Avec B_{green} désigne la valeur de réflectance dans la bande verte (visible) de l'image satellite et B_{SWIR} la valeur de réflectance dans la bande proche infrarouge à ondes courtes (SWIR)

c. NDWI :

Le NDWI est un indice spectral utilisé en télédétection pour localiser et surveiller la présence d'eau sur différentes surfaces terrestres, y compris les plans d'eau naturels comme les lacs, les rivières, les zones humides, ainsi que les sols saturés ou les surfaces artificielles.

Formule :

$$NDWI = \frac{B_{green} - B_{NIR}}{B_{green} + B_{NIR}} \quad (Eq. 3)$$

Où **Green** représente la réflectance dans la bande du vert (spectre visible), et **NIR** désigne la réflectance dans le domaine proche infrarouge.

- **Valeurs positives** : Reflètent généralement la présence d'eau.
- **Valeurs faibles ou négatives** : Indiquent des zones non aquatiques, telles que le sol, la végétation ou des surfaces imperméables.

Le NDWI est un indice en télédétection environnementale, permettant d'identifier et de surveiller les plans d'eau et les zones humides, de détecter rapidement les zones inondées après de fortes précipitations ou des crues, d'évaluer la diminution des ressources en eau en période de sécheresse et d'analyser les zones humides ainsi que leur rôle écologique. Il se distingue par sa capacité à différencier efficacement les surfaces aquatiques des autres types de surfaces et peut être calculé aisément à partir des données satellites telles que celles fournies par Landsat et Sentinel (Gao,1996).

d.MNDWI :

Le MNDWI est utilisé pour détecter l'eau de surface, en particulier dans les zones urbaines où les eaux suffisamment réfléchissantes susceptibles de saturer le classique NDWI sont souvent asséchées par les imperméabilisations. Utilisé notamment dans le cadre de l'analyse des fleuves, des lacs et des milieux côtiers (Szabo,2016). Il est défini comme suit :

$$MNDWI = \frac{B_{green} - B_{MIR}}{B_{green} + B_{MIR}} \quad (\text{Eq. 4})$$

Où **MIR** désigne la réflectance dans la bande du Moyen Infrarouge (Middle Infrared).

e. SAVI :

Le SAVI est un indice de végétation utilisé dans les zones où la végétation est peu dense, comme les régions arides ou semi-arides. Il est conçu pour réduire l'influence du sol nu sur les valeurs mesurées, ce qui le rend plus fiable que le NDVI dans les milieux peu végétalisés (Cahyono et al.,2022). En effet, le SAVI est plus ou moins sensible au sol que le NDVI, ce qui est un avantage dans les environnements peu végétalisés (Huete ,1988). Il est défini comme suit :

$$SAVI = \left(\frac{B_{NIR} - B_{red}}{B_{NIR} + B_{red} + L} \right) \times (1 + L) \quad (\text{Eq.5})$$

Où est un facteur de correction du sol (typiquement 0.5).

2.6. Techniques de modélisation des impacts des inondations :

La modélisation des inondations est un outil essentiel pour comprendre et atténuer les impacts des inondations sur des plans d'eau tels que le lac St-Pierre, au Québec. Trois approches de modélisation principales sont couramment utilisées : les modèles hydrodynamiques, les modèles basés sur les SIG et les modèles statistiques. Chaque approche présente des avantages distincts

et convient à des applications spécifiques, allant de la simulation détaillée de processus physiques à des scénarios à grande échelle et limités en données.

2.6.1. Modèles hydrodynamiques :

Principales techniques :

Les modèles hydrodynamiques reposent sur des concepts physiques visant à résoudre les équations qui régissent le mouvement des fluides. Ils permettent de simuler avec précision les écoulements hydrauliques et les phénomènes d'inondation en mobilisant les principes de la mécanique des fluides. Concrètement, ces modèles s'appuient sur les équations de Navier–Stokes, adaptées pour représenter les interactions entre la vitesse, la pression, la viscosité et les contraintes liées au milieu aquatique (Chow et al., 1988). En fonction de leur complexité, ils peuvent être unidimensionnels (1D), bidimensionnels (2D) ou tridimensionnels (3D), offrant des degrés de précision croissants pour représenter les flux hydrauliques.

Dans le cas du lac St-Pierre, Matte et al. (2017) ont utilisé un modèle hydrodynamique bidimensionnel basé sur la méthode des éléments finis afin d'analyser l'influence de la végétation aquatique sur les flux dynamiques. Les résultats ont montré une excellente capacité de reproduction des niveaux d'eau et des débits, avec un coefficient de détermination supérieur :

0,99 pour les hauteurs d'eau et des erreurs inférieures à 6 % pour les rejets. Ce type d'approche démontre la puissance des modèles hydrodynamiques pour reproduire et anticiper des phénomènes hydrologiques complexes, en intégrant des paramètres liés à la topographie, à la rugosité du lit, à la végétation et aux conditions climatiques.

Applications et apports scientifiques

Les modèles hydrodynamiques trouvent de nombreuses applications en hydrologie appliquée et en gestion des risques. Ils constituent des outils essentiels pour :

- **La cartographie des zones inondables**, en identifiant avec précision les secteurs susceptibles d'être submergés lors de crues.
- **La prévision de l'étendue et de la dynamique des inondations**, en simulant la vitesse, la hauteur et la durée des submersions (Matte et al., 2017).

- **L'évaluation de scénarios de gestion** (ex. ouverture de barrages, aménagement de digues, restauration de zones humides), permettant d'anticiper les effets de mesures d'atténuation.
- **La prise en compte du changement climatique**, en intégrant des scénarios hydrologiques futurs (augmentation des précipitations, fonte précoce des neiges) afin d'estimer l'évolution des risques dans les décennies à venir (Brunner et al., 2021).

En plus de leur capacité prédictive, ces modèles offrent une information spatio-temporelle détaillée sur les hauteurs d'eau, les vitesses d'écoulement et les zones de stagnation, ce qui est fondamental pour la planification urbaine, la protection des infrastructures et la gestion des terres agricoles.

2.6.2. Modèles basés sur un SIG :

Les modèles basés sur les SIG exploitent les systèmes d'information géographique pour intégrer des données spatiales aux modèles hydrologiques et hydrauliques. Ils sont particulièrement utiles pour la cartographie des zones inondables et la prévision de l'étendue des inondations, notamment dans les régions où les données disponibles sont limitées.

Principales techniques :

Une recherche menée dans les bassins versants du sud du Québec, incluant la région du lac St-Pierre, a mis en évidence l'application de techniques géomatiques pour estimer les courbes d'évaluation synthétiques (SRC). Basées sur la géométrie des cours d'eau et la formule de Manning, ces courbes relient le débit aux niveaux d'eau. La comparaison avec des données observées a montré une bonne précision, avec des valeurs de NRMSE comprises entre 0,03 et 0,62 (Gordon et al., 2023 ; Scriven et al., 2021).

La méthode HAND, ou hauteur au-dessus du drainage le plus proche, permet de cartographier les zones inondables en déterminant la cote altimétrique de chaque point par rapport au cours d'eau de drainage le plus proche. Implémentée dans un **SIG**, cette approche permet de produire des systèmes de référence de crue et des cartes d'inondation fiables (Gordon et al., 2023 ; Scriven et al., 2021).

Par ailleurs, les modèles numériques d'altitude (MNA) ont été largement utilisés pour évaluer les zones à risque d'inondation. Ils établissent une corrélation entre la profondeur du débit dans

les réseaux fluviaux et les zones contributives en amont. Calibré à l'aide d'un modèle hydrodynamique bidimensionnel, l'indice géomorphologique de risque d'inondation (GFI) a montré une grande précision, avec une AUC atteignant 92 % (Amellah et al., 2024).

Applications :

La cartographie des zones inondables repose largement sur les modèles basés sur les SIG, qui permettent de créer des cartes fiables et d'anticiper l'ampleur des crues. Ils constituent des outils à la fois précis et accessibles pour identifier les zones à risque, en particulier dans les contextes où les données de terrain sont restreintes (Gordon et al., 2023 ; Scriven et al., 2021 ; Amellah et al., 2024). De plus, ces modèles se révèlent efficaces pour la planification des interventions d'urgence et la gestion des ressources, grâce à leur capacité à produire rapidement des cartes opérationnelles en situation de crise (Scriven et al., 2021).

2.6.3. Modèles statistiques :

Les modèles statistiques reposent sur des relations empiriques établies entre variables hydrologiques et hydrauliques pour prédire les caractéristiques des inondations, telles que les niveaux d'eau, les débits maximaux et l'étendue spatiale des zones submergées. Leur avantage réside dans leur simplicité de mise en œuvre, leur faible coût computationnel et leur adaptabilité aux applications à grande échelle, en particulier lorsque des séries temporelles de données sont disponibles sur de longues périodes (Salas et al., 2018).

Principales techniques :

- **Modélisation à grande échelle :**

Une étude menée sur plusieurs lacs du Québec, incluant le lac St-Pierre, a comparé les performances de modèles statistiques et de modèles physiques pour prévoir l'augmentation du niveau d'eau en période de crue. Les résultats ont montré que l'approche statistique, grâce à ses marges d'erreur plus faibles et sa rapidité de calcul, s'avère particulièrement pertinente pour la modélisation à large échelle (Olcese et al., n.d.). Ces modèles utilisent fréquemment des régressions linéaires ou non linéaires, des analyses de corrélation ou encore des lois de probabilité extrêmes (par ex. loi de Gumbel ou loi log-normale) pour estimer la fréquence et l'intensité des événements rares.

- **Algorithmes d'apprentissage automatique :**

L'intégration de l'intelligence artificielle a permis de combiner les atouts des modèles statistiques et physiques. Une approche hybride, associant modèles hydrodynamiques et réseaux de neurones artificiels (RNA), a été testée pour corriger les biais systématiques des simulations hydrodynamiques. Les RNA ont été entraînés à partir de séries de données simulées et observées afin d'anticiper les erreurs récurrentes et d'améliorer la précision des prévisions. Les résultats obtenus montrent une amélioration significative de la fiabilité des estimations des niveaux d'eau (Li & Jun, 2022). Cette hybridation illustre la complémentarité entre la robustesse physique des modèles hydrodynamiques et la capacité prédictive des algorithmes d'apprentissage automatique.

Applications

Les modèles statistiques sont largement utilisés pour l'évaluation des risques d'inondation, en particulier pour estimer la probabilité d'occurrence des crues et leurs conséquences potentielles sur les infrastructures, les écosystèmes et l'agriculture. Ils permettent d'identifier les zones à risque élevé, où la conjonction de facteurs climatiques (précipitations extrêmes), hydrologiques (débits élevés) et géomorphologiques (faible pente, sols saturés) accroît fortement la vulnérabilité des territoires (Surunis, 2022).

Prévisions en temps réel

Grâce à leur efficacité computationnelle, les modèles statistiques sont adaptés à la prévision opérationnelle en temps réel. Ils offrent la possibilité de générer rapidement des estimations fiables sur les niveaux d'eau et l'ampleur attendue des inondations, ce qui constitue un atout majeur pour les systèmes d'alerte précoce et la gestion des urgences (Li & Jun, 2022). Toutefois, leur performance dépend étroitement de la qualité et de la représentativité des séries de données historiques utilisées pour leur calibration. Dans le contexte du changement climatique, caractérisé par une intensification des événements extrêmes, cette dépendance représente une limite importante, nécessitant une intégration avec d'autres approches, notamment hydrodynamiques et géospatiales.

2.7.Études de cas concernant le lac St-Pierre et le fleuve St-Laurent :

Une étude menée par Matte et al. (2017) a eu recours à une modélisation hydrodynamique bidimensionnelle à haute résolution pour analyser l'estuaire du fleuve St-Laurent, incluant le lac St-Pierre. Cette approche a permis de simuler avec une grande précision les niveaux d'eau et les

débits, fournissant ainsi des données détaillées sur l'hydrodynamique régionale et validant la pertinence des modèles numériques pour la gestion des crues.

Parallèlement, des approches basées sur les systèmes d'information géographique (SIG), telles que la méthode HAND (*Height Above Nearest Drainage*) et les courbes d'évaluation synthétiques (SRC), ont été appliquées afin de cartographier les zones inondables dans les bassins versants du sud du Québec, notamment celui du lac St-Pierre (Gordon et al., 2023 ; Scriven et al., 2021). Ces approches combinent données topographiques et hydrologiques pour produire rapidement des cartes d'inondation, avec une efficacité particulière dans les régions où les données de terrain sont limitées

En complément, des modèles statistiques ont été utilisés pour prévoir l'élévation des niveaux d'eau dans les lacs québécois, incluant le lac St-Pierre. Leur précision, associée à une simplicité d'application, en fait une solution adaptée à la modélisation à large échelle (Olcese et al., s.d.). Ces modèles reposent souvent sur des relations empiriques issues de séries temporelles hydrologiques, comme les lois de probabilité extrêmes ou les régressions multiples, et fournissent des prévisions rapides utiles aux systèmes d'alerte.

Dans une perspective plus agronomique, des chercheurs ont mobilisé des modèles de simulation des cultures tels que WOFOST et APSIM pour évaluer les pertes de rendement liées aux inondations. Ces travaux ont montré que, malgré des méthodologies différentes, les résultats restaient globalement cohérents, confirmant la pertinence de ces modèles pour estimer l'impact des aléas hydrologiques sur les systèmes agricoles (Monteleone et al., 2021).

2.8.Intégration de l'apprentissage profond et de l'intelligence artificielle :

Récemment, l'essor des techniques d'apprentissage profond (*Deep Learning*) et d'intelligence artificielle (IA) a ouvert de nouvelles perspectives pour la modélisation des inondations et l'évaluation de leurs impacts. Contrairement aux modèles statistiques classiques, ces approches permettent de traiter de vastes volumes de données multi-sources (satellites, capteurs in situ, données climatiques) et d'identifier des relations complexes et non linéaires entre les variables. Par exemple, les réseaux de neurones convolutionnels ont été appliqués à la classification d'images satellitaires afin de détecter automatiquement les zones inondées, avec une précision supérieure à celle des méthodes traditionnelles (Feng et al., 2020). De même, les réseaux de neurones récurrents

se révèlent particulièrement adaptés à l'analyse des séries temporelles hydrologiques, permettant d'anticiper plus efficacement la dynamique des crues (Kratzert et al., 2019).

L'intégration de l'IA avec des modèles hydrodynamiques ou statistiques permet ainsi de développer des approches hybrides, combinant robustesse physique et capacité prédictive, et de renforcer la fiabilité des prévisions dans un contexte de changement climatique et de variabilité accrue des événements extrêmes.

Des algorithmes de Machine Learning et d'intelligence artificielle sont utilisés pour optimiser la cartographie des inondations, les prévisions et l'évaluation des risques, qui sont des composantes essentielles des systèmes d'alerte précoce. Ce genre de technologies sert à examiner des ensembles de données complexes en vue de prévoir les inondations et d'évaluer les conséquences possibles sur le secteur agricole (Paswan & Ray, 2023).

L'utilisation de méthodes telles que les forêts aléatoires, relevant de l'apprentissage automatique, permet de modéliser avec précision les inondations causées par les précipitations en milieu agricole. Ces approches facilitent l'identification des zones à risque ainsi que des cultures potentiellement affectées (Fidan et al., 2023).

En fait, les algorithmes de Machine Learning et d'intelligence artificielle sont utilisés pour optimiser la cartographie des inondations, les prévisions et l'évaluation des risques, qui sont des éléments essentiels des systèmes d'alerte précoce. Ces technologies servent à examiner des ensembles de données complexes en vue de prévoir les inondations et d'évaluer les conséquences possibles sur le secteur agricole (Paswan et Ray, 2023).

De plus, plusieurs méthodes d'apprentissage automatique telles que la Forêt Aléatoire ont été appliquées pour prédire avec précision les inondations pluviales dans les milieux agricoles en ciblant les zones à risque et les cultures susceptibles d'être touchées (Fidan et al., 2023).

2.8.1. Simulation numérique et observation terrestre :

Les systèmes d'alerte précoce en cas d'inondation dépendent des modèles numériques, qui permettent de générer des simulations précises des inondations à diverses échelles. Ces modèles permettent de mieux comprendre la dynamique des inondations et de concevoir des stratégies d'atténuation appropriées pour les zones agricoles (Fernández-Nóvoa et al., 2024).

Analyses de cas et mises en pratique :

Une étude en Malaisie a utilisé la modélisation des inondations avec Info Works et des SIG pour évaluer les dégâts des inondations dans les zones agricoles. Les résultats ont mis en évidence l'efficacité des bassins de rétention dans la réduction significative de l'ampleur des inondations, comme le montre Muhadi (2016). L'utilisation d'images de télédétection et de données géospatiales dans le domaine de l'apprentissage automatique s'est révélée être une approche efficace pour créer des séquences temporelles d'inondations et pour évaluer les répercussions sur des cultures particulières telles que le maïs et le soja (Fidan et al., 2023). Bien que la modélisation des inondations ait permis d'améliorer les systèmes d'alerte précoce, quelques difficultés demeurent pour garantir la fiabilité et la cohérence des résultats des modèles à l'échelle mondiale. L'inclusion de diverses sources de données et la conception de modèles universellement applicables sont des efforts constants destinés à améliorer la fiabilité et l'efficacité de ces systèmes pour la gestion des risques d'inondations agricoles (Schumann et al., 2023).

2.8.1. Classification des images par Random Forest :

Les forêts aléatoires (Random Forest) constituent une méthode d'ensemble (ensemble Learning) introduite par Breiman (2001) qui agrège plusieurs arbres de décision pour améliorer la stabilité et la précision de la classification. Chaque arbre de la forêt est construit à partir d'un échantillon bootstrap (tiré avec remise) du jeu d'entraînement, puis, à chaque nœud, un sous-ensemble aléatoire de variables est testé pour déterminer la meilleure partition.

Le classifieur Random Forest est constitué d'un ensemble d'arbres de décision, chaque arbre étant construit à partir d'un vecteur aléatoire prélevé dans l'espace des variables d'entrée. Pour classer un vecteur d'entrée, chaque arbre attribue un vote unitaire à la classe la plus probable, et la forêt combine ensuite ces votes pour déterminer la prédiction finale.

L'indice de Gini qui mesure l'impureté d'un attribut par rapport aux classes, est utilisé dans les modèles Random Forest afin de sélectionner la meilleure partition à chaque nœud. Pour un ensemble d'apprentissage T , si l'on choisit au hasard un pixel appartenant à la classe C_i , la probabilité que ce pixel appartienne à C_i est $\frac{f(C_i, T)}{|T|}$.

L'indice de Gini de l'ensemble TTT s'écrit alors :

$$Gini(T) = \sum_i \sum_{i \neq j} \frac{f(C_i, T)}{|T|} \times \frac{f(C_j, T)}{|T|} \quad (\text{Eq.6})$$

Où

- $f(C_i, T)$ Est l'effectif des pixels de la classe C_i dans T_i
- $|T|$ Est la taille totale de l'ensemble T .
- Cette quantité reflète l'impureté du nœud : plus les probabilités $\frac{f(C_i, T)}{|T|}$ sont réparties entre plusieurs classes, plus l'impureté est élevée

2.9. Validation croisée et limites des approches d'intelligence artificielle en télédétection (cas Sentinel-2) :

L'utilisation des images Sentinel-2 pour la classification de la végétation et de la neige est largement documentée. Les algorithmes d'apprentissage automatique, tels que le Random Forest (RF), sont fréquemment employés pour exploiter la richesse spectrale de ces capteurs. Afin d'évaluer la robustesse des modèles, plusieurs auteurs insistent sur l'importance de la validation croisée, notamment spatiale et temporelle, pour éviter les biais liés à l'autocorrélation des données. Par exemple, Foody (2002) a montré que l'autocorrélation spatiale pouvait conduire à une surestimation des performances si les ensembles d'entraînement et de test ne sont pas indépendants. Plus récemment, Matasci et al. (2018) ont appliqué la validation croisée sur des jeux de données Sentinel-2 pour la cartographie de la végétation, démontrant que les performances étaient plus fiables lorsque la validation respectait la structure spatiale des données.

Concernant la neige, Gascoin et al. (2020) ont utilisé des approches supervisées basées sur Sentinel-2 combinées à des techniques de validation croisée pour montrer la supériorité des méthodes d'IA par rapport aux indices spectraux classiques (ex. NDSI). Dans ce cadre, la matrice de confusion constitue un outil essentiel pour l'évaluation des modèles Random Forest. Elle permet de comparer les classes prédites et les classes observées, et d'en dériver des indicateurs tels que la précision globale, l'indice Kappa, ou encore les taux d'erreur d'omission et de commission. Ainsi, plusieurs études soulignent que la robustesse du Random Forest réside dans sa capacité à limiter le sur-apprentissage et à fournir des estimations stables, mais que son interprétation doit toujours être accompagnée d'une analyse fine de la matrice de confusion (Belgiu et Drăguț, 2016).

La matrice de confusion est un outil central dans l'évaluation des classifications supervisées issues des données de télédétection. Elle permet de comparer, pour chaque classe, les valeurs prédites par l'algorithme et les valeurs réelles issues des données de référence. Dans le cas des modèles d'apprentissage automatique tels que le Random Forest, la matrice de confusion constitue la base du calcul d'indicateurs de performance largement utilisés, comme la précision globale, l'indice Kappa, ainsi que les taux d'omission et de commission. Ces indicateurs apportent des informations complémentaires : alors que la précision globale synthétise la justesse de la classification, l'indice Kappa corrige l'effet du hasard, et les erreurs d'omission et de commission renseignent sur la capacité du modèle à éviter les confusions entre classes. Plusieurs études en télédétection (Foody, 2002 ; Belgiu & Drăguț, 2016) rappellent que l'interprétation de la matrice de confusion ne doit pas se limiter à un seul indicateur, mais à un ensemble de mesures permettant une évaluation robuste et nuancée. Dans le cadre de l'utilisation de Sentinel-2 pour la cartographie de la végétation ou de la neige, cette approche est particulièrement pertinente pour juger de la fiabilité des résultats et mettre en évidence les classes les plus sujettes aux erreurs de classification.

2.7.Conclusion :

Les techniques de modélisation des impacts des inondations sur le lac St-Pierre, au Québec, englobent une gamme d'approches, chacune ayant des atouts et des applications uniques. Les modèles hydrodynamiques fournissent des simulations détaillées de la dynamique des inondations, les modèles basés sur les SIG offrent des outils rentables pour la cartographie des zones inondables, et les modèles statistiques permettent des prévisions efficaces pour des applications à grande échelle. En intégrant ces approches et en relevant les défis actuels, les recherches futures pourront développer des outils de modélisation des inondations plus précis et plus efficaces, contribuant ainsi à une meilleure gestion des risques d'inondation et à des stratégies d'atténuation pour les terres agricoles (Figure 1).




Figure 1 : Approches méthodologique de modélisation

3. MATÉRIELS ET METHODE :

3.1. Zone d'étude :

Le site d'étude est localisé au Québec, au Canada ($46^{\circ}13'07''$ N ; $72^{\circ}47'30''$ O ; 153 m). Il s'agit du lac St-Pierre, un élargissement du fleuve St-Laurent. Les champs agricoles situés en bordure de ce lac sont principalement consacrés aux cultures céréalières, au soja, au maïs et à l'orge. Situé entre Sorel et Trois-Rivières, à environ 65 km à l'est de Montréal, le lac St-Pierre est entouré d'une vaste plaine inondable, considérée comme la plus grande zone inondable en eau du Québec (Figure 2). Au printemps 2019 et 2020, les eaux ont débordé du lit du fleuve et submergé près de 7 000 hectares de prairies naturelles, d'arbustes, de forêts riveraines et de terres cultivées, en raison de phénomènes climatiques extrêmes (MELCC, 2020).




Figure 2 : Localisation de la zone d'étude -Les cultures principales sont codées par couleur : le soja en rouge, l'orge en jaune, le maïs en bleu et le blé en violet. Les zones inondées sont indiquées en blanc, et la limite de la zone d'étude est tracée en noir.

((Source : Données Québec -jeu de données « limites des zones inondables » (shapefiles- ArcGIS 10.8))

3.2. Données et Outils :

3.2.1. Google Earth Engine :

Google Earth Engine (GEE) est une plateforme de calcul infonuagique développée en 2010 pour le traitement et l'analyse des données géospatiales. Elle met à disposition une vaste collection d'ensembles de données accessibles au public, incluant des images satellites (Landsat, Sentinel, MODIS, etc.), des systèmes d'imagerie aérienne, des cartes de couverture terrestre, des prévisions météorologiques et climatiques, ainsi que des données socio-économiques. L'architecture de GEE repose sur un traitement parallèle distribué sur des infrastructures de calcul à haute performance, capables de gérer des volumes de données de l'ordre du pétaoctet. Cette puissance de calcul permet de traiter en quelques secondes des centaines d'images, ce qui accélère considérablement l'ensemble du processus d'analyse. L'un de ses principaux avantages est qu'il n'est pas nécessaire de télécharger localement les images satellites : le traitement et l'analyse sont réalisés directement sur le cloud. Les scripts développés sur GEE, principalement en **JavaScript** (via l'interface en ligne) ou en **Python** (grâce à l'API Python), permettent d'accéder aux bibliothèques de données et aux ressources de calcul de la plateforme, rendant possible la réalisation d'analyses spatiales avancées, de la simple visualisation de données à la modélisation complexe des dynamiques environnementales.

3.2.2. Programmation sous le langage R :

Le langage de programmation R a gagné en popularité dans les domaines de l'apprentissage automatique et de la télédétection en raison de sa polyvalence et de ses vastes capacités statistiques. Les chercheurs peuvent analyser et modéliser efficacement des ensembles de données complexes en utilisant R, ce qui en fait un outil précieux pour extraire des informations significatives à partir des données de télédétection. Selon Li et al. (2018), R a été utilisé avec succès dans les études de télédétection pour des tâches telles que la classification d'images, la cartographie de l'occupation des sols et la détection de changements. Par exemple, les chercheurs ont utilisé R pour classer divers types de couverture terrestre à partir de photos satellites en utilisant des algorithmes d'apprentissage automatique comme les forêts aléatoires. Imageries satellites Sentinel-2 : Le programme Sentinel-2, mis en œuvre dans le cadre de l'initiative européenne Copernicus, repose sur une constellation de deux satellites optiques : Sentinel-2A (S2A), lancé en juin 2015, et Sentinel-2B (S2B), lancé en mars 2017. Ces deux satellites jumeaux sont spécifiquement conçus pour l'observation de la surface terrestre, en fournissant des images multispectrales à haute

résolution spatiale et temporelle. Leur fonctionnement en orbite héliosynchrone permet une couverture fréquente et régulière. Ils offrent des images de télédétection avec une résolution spatiale et spectrale élevée ainsi qu'une fréquence de revisite allant de 5 à 10 jours. Toutefois, toutes les images capturées ne peuvent pas être exploitées efficacement en raison d'un manque de couverture dans certaines régions. Les satellites Sentinel-2 sont équipés d'un instrument multispectral couvrant une gamme de longueurs d'onde de 0,4 à 2,2 μm . Celui-ci comprend six bandes dans le bord rouge et le proche infrarouge, quatre bandes dans le spectre visible et le proche infrarouge, avec une résolution spatiale de 10 mètres (Tavares et al., 2019 ; Tong, 2020).

Les images Sentinel-2 utilisées dans cette étude proviennent de la plateforme Google Earth Engine. Les séries d'images ont été sélectionnées pour les années 2017 et 2019. Une approche de filtrage complet a été appliquée afin de garantir la qualité des données. Dans un premier temps, les images ont été filtrées en fonction du pourcentage de couverture nuageuse, et seules celles présentant une couverture inférieure à 10 % ont été retenues pour l'analyse.

Par ailleurs, la correction atmosphérique SIAC a été appliquée aux images Sentinel-2 pour assurer une restitution précise de la réflectance de surface, en éliminant efficacement les perturbations atmosphériques telles que les aérosols et la vapeur d'eau. SIAC propose une méthode simplifiée, plus performante que les algorithmes de correction traditionnels, offrant une précision accrue tout en maintenant une efficacité de calcul. Son intégration dans Google Earth Engine facilite la gestion d'informations spatiales et temporelles volumineuses de manière automatisée et évolutive. Cette combinaison garantit la qualité et la fiabilité des données utilisées pour les évaluations environnementales et la couverture terrestre, renforçant ainsi la validité et la reproductibilité des résultats de l'étude (Yin et al., 2019).

3.3.3. Classification Sentinel-2 de la végétation impactée :

Pour développer un modèle d'apprentissage automatique capable de distinguer la végétation affectée de la végétation non affectée dans les images Sentinel-2 de la région du lac St-Pierre, nous avons adopté une démarche systématique combinant les langages de programmation R et Python.

Après la collecte et le prétraitement des données Sentinel-2, nous avons sélectionné les bandes spectrales et les indices spectraux pertinents à utiliser comme variables d'entrée pour la classification. Les bandes bleue, verte, rouge et proche infrarouge (NIR) a été retenues en raison

de leur sensibilité au rayonnement visible et au proche infrarouge, ainsi qu'à la réflectance différenciée de la neige comparée aux autres types de couverture terrestre (Shimamura et al., 2006). De plus, les bandes du spectre infrarouge à ondes courtes (SWIR) ont été intégrées, car elles permettent de distinguer efficacement la neige des nuages, ces derniers étant plus réfléchissants dans le visible que dans le SWIR (Lu et al., 2022).

En complément, plusieurs indices spectraux ont été calculés pour améliorer la précision de la classification : NDVI, SAVI, NDSI, NDBI et MNDWI.

Le modèle de classification choisi est la forêt aléatoire (Random Forest, RF), reconnue pour sa robustesse et son efficacité dans l'analyse d'images satellitaires. Les zones d'entraînement ont été délimitées sous forme de polygones dans ArcGIS 10.8, en se basant sur des composites en couleurs vraies et fausses issus d'images Sentinel-2 acquises à différentes dates (notamment les 20, 21 et 23 avril 2019), ainsi que sur un examen visuel approfondi pour distinguer les zones « impactées » et « non impactées ».

Au total, 93 polygones de référence ont été numérisés de façon experte afin de représenter trois classes thématiques exclusives (« *impacté* », « *non impacté* » et « *eau* »). La procédure de digitalisation a été conduite en veillant à l'absence de chevauchement spatial entre classes, garantissant ainsi une séparation nette et exclusive des entités pour l'étape d'apprentissage supervisé. Ces polygones ont servi de données de vérité terrain (ground truth) pour l'entraînement et la validation du modèle. Pour chaque polygone, un pixel représentatif a été extrait à l'aide de la méthode des statistiques zonales (zonal_stats), constituant un ensemble d'apprentissage de 93 pixels étiquetés : 56 pour la classe « impacté », 24 pour la classe « non impacté » et 13 pour la classe « eau ». Chaque pixel disposait de dix variables prédictives, composées de six bandes spectrales (bleu, vert, rouge, NIR, SWIR1, SWIR2) et de cinq indices spectraux dérivés (NDVI, NDSI, MNDWI, NDBI). Le modèle Random Forest a été entraîné sur cet ensemble d'échantillons. Afin d'optimiser ses performances, une recherche exhaustive des hyperparamètres a été réalisée, notamment sur le nombre d'arbres (n_estimators), testé de 20 à 100 par pas de 20, et sur le nombre maximal de variables considérées à chaque division (max_features), exploré entre 2 et 10. La meilleure configuration retenue a été de 80 arbres avec 9 variables maximales par division, conduisant à une précision moyenne de 87,2 %, témoignant de la qualité du modèle pour classer de nouvelles données.

Enfin, le modèle entraîné a été appliqué à l'ensemble de l'image Sentinel-2 pour produire une carte de classification à trois classes (« impacté », « non impacté », « eau »), exportée au format GeoTIFF. Cette carte conserve les coordonnées géographiques d'origine et utilise un code couleur spécifique pour chaque classe, facilitant ainsi son intégration et son analyse dans un système d'information géographique (ArcGIS 10.8).

Le Random Forest (RF) est un algorithme d'apprentissage supervisé basé sur un ensemble d'arbres de décision. Chaque arbre est construit à partir d'un sous-échantillon aléatoire du jeu de données (méthode du Bootstrap), et les divisions aux nœuds se font en sélectionnant aléatoirement un sous-ensemble de variables candidates. Le résultat final est obtenu par un vote majoritaire entre tous les arbres, ce qui réduit le risque de surapprentissage et améliore la robustesse du modèle (Breiman, 2001).

En télédétection, le Random Forest est largement utilisé car il tolère les variables corrélées, gère efficacement les données bruitées et ne nécessite pas d'hypothèses fortes sur la distribution des données. De plus, il fournit des mesures d'importance des variables, permettant d'évaluer la contribution de chaque bande ou indice spectral à la classification (Belgiu et Drăguț, 2016).

Dans le cas des images Sentinel-2, les bandes spectrales visibles (bleu, vert, rouge) et proche infrarouge (NIR) sont retenues car elles reflètent directement l'activité photosynthétique et la vigueur de la végétation. Les bandes SWIR (Shortwave Infrared) apportent une information déterminante pour distinguer la neige des nuages, ces derniers étant plus réfléchissants dans le visible que dans l'infrarouge à ondes courtes (Shimamura et al., 2006 ; Lu et al., 2022). En complément, les indices spectraux dérivés sont utilisés afin de mettre en évidence certaines caractéristiques : NDVI (Végétation), SAVI (végétation corrigée de l'effet du sol), NDSI (neige), NDBI (zones bâties) et MNDWI (eau). La combinaison de ces variables brutes et dérivées renforce la capacité discriminante du modèle.

3.2.5. Méthode d'entraînement et hyperparamètre :

Le processus d'entraînement repose sur des échantillons de référence (ground truth), extraits sous forme de polygones experts délimitant les classes « impacté », « non impacté » et « eau ». Chaque polygone fournit un ensemble de pixels étiquetés servant à la fois pour l'apprentissage et la validation du modèle. Afin d'optimiser la performance du Random Forest, deux hyperparamètres principaux ont été ajustés :

1. **Nombre d'arbres (n_estimators)** : ce paramètre correspond au nombre total d'arbres construits dans la forêt. Un nombre trop faible d'arbres peut conduire à un modèle instable, tandis qu'un nombre trop élevé augmente le temps de calcul sans gain significatif de précision. Dans cette étude, une recherche par pas de 20 a permis d'identifier qu'un total de 80 arbres offrait le meilleur compromis entre stabilité et performance.
2. **Nombre maximal de variables considérées à chaque division (max_features)** : ce paramètre contrôle la diversité des arbres. Si le nombre de variables testées à chaque nœud est trop faible, le modèle peut manquer d'information ; s'il est trop élevé, les arbres risquent d'être trop similaires et de perdre en diversité. Les essais ont montré que 9 variables constituaient une valeur optimale, permettant de maximiser la précision sans surajuster le modèle.

L'entraînement a été conduit selon une approche de validation croisée : une partie des échantillons a été utilisée pour l'apprentissage, tandis qu'une autre partie indépendante a servi à l'évaluation. La matrice de confusion a ensuite permis de calculer des indicateurs de performance (précision globale, Kappa, erreurs d'omission et de commission). Le modèle optimisé a atteint une précision moyenne de **87,2 %**, confirmant la pertinence du choix des variables et la fiabilité de l'algorithme pour discriminer les différentes classes de couverture.

3.3. Organigramme méthodologique :

Il y a trois étapes dans la méthodologie. La méthodologie adoptée comprend trois étapes principales : l'acquisition et le prétraitement des images Sentinel-2 via Google Earth Engine, incluant la sélection des bandes spectrales pertinentes (B2, B3, B4, B5, B6, B7), le masquage des nuages et la correction atmosphérique (TOA à BOA) ; l'analyse exploratoire des données réalisée avec Python et R, consistant au calcul d'indices spectraux (NDVI, MNDWI, NDSI, NDBI, AWEI) superposés à des composites en fausses couleurs pour visualiser les variations spatiales et temporelles ; enfin, la classification des zones d'intérêt, avec extraction des valeurs pixel par polygone, puis la modélisation et la calibration d'un algorithme de forêt aléatoire (Random Forest) afin d'assurer une classification précise des zones impactées. (Figure3).




Figure 3 : Organigramme approche méthodologique du travail

4. RÉSULTATS

4.1. Cartographie des zones inondées :

Les figures 4 et 5 illustrent respectivement l'évolution saisonnière du paysage agricole autour du lac St-Pierre avant, pendant et après la crue printanière d'avril 2019, à partir d'images Sentinel-2 en RGB (figure 4) et en fausses couleurs NIR-Rouge-Vert (figure 5), acquises les 12 mars, 21 avril et 6 mai 2019.

Les images RGB et en fausses couleurs (NIR, rouge, vert) issues de Sentinel-2 ont permis d'illustrer l'évolution spatio-temporelle des inondations du printemps 2019 au lac St-Pierre. Avant la crue (mars 2019), le paysage agricole présentait des sols encore gelés et faiblement végétalisés, ce qui correspond à la phénologie printanière de la région. Pendant la crue (avril 2019), une expansion notable des zones sombres sur les images RGB et une forte baisse de la réflectance NIR dans les fausses couleurs ont clairement révélé l'extension des eaux sur les terres agricoles. Après le retrait partiel des eaux (mai 2019), la reprise de la végétation est visible mais reste incomplète, signe de l'impact durable de la saturation des sols sur la croissance des cultures. Ces résultats confirment l'intérêt de la télédétection optique pour suivre les inondations, mais ils soulignent également ses limites. En particulier, la présence de neige résiduelle en amont de la crue complique l'interprétation des surfaces inondées, tandis que l'humidité du sol peut accentuer le signal de l'eau et conduire à une surestimation des zones inondées. Ainsi, bien que la méthode permette une visualisation claire des crues, son interprétation doit être nuancée par les conditions climatiques et pédologiques locales.




Figure 4 : Visualisation de la zone inondée en 2019 en RGB




Figure 5 : Visualisation en fausses couleurs de la zone inondées en 2019

4.2. Superposition des indices :

Les figures 6 et 7 présentent la comparaison du MNDWI pendant et après la crue printanière d'avril 2019, mettant en évidence les variations de l'étendue des zones inondées observées dans la région du lac St-Pierre.

La superposition du MNDWI sur les images RGB a permis de localiser l'extension maximale des zones inondées. Comme attendu, les valeurs positives et proches de 1 correspondaient aux plaines agricoles recouvertes d'eau libre. Toutefois, certaines zones humides ou sols fortement saturés ont pu être assimilés à de l'eau, ce qui constitue une limite déjà signalée dans la littérature (Blackmore et al., 2016). En revanche, la superposition du NDVI a montré une chute marquée de l'activité chlorophyllienne dans les zones inondées pendant la crue, suivie d'une reprise partielle après le retrait des eaux. Cette dynamique illustre bien la résilience végétative, mais également le retard phénologique imposé aux cultures, ce qui se traduit par une diminution potentielle de rendement.

Dans l'ensemble, l'approche combinant RGB, fausses couleurs, MNDWI et NDVI permet d'obtenir une vision intégrée des impacts hydrologiques et agricoles de la crue. Toutefois, ces résultats doivent être replacés dans leur contexte : l'analyse reste sensible aux conditions atmosphériques, à la couverture neigeuse et à la résolution spatiale de Sentinel-2, qui ne permet pas toujours de capturer les hétérogénéités fines des parcelles agricoles. Une validation croisée avec des données de Sentinel-1, par exemple pour renforcer la fiabilité des estimations.




Figure 6 : Comparaison MNDWI pendant et après la crue d'avril 2019




Figure 7 : Comparaison MNDWI pendant et après la crue d'avril 2019

4.3. Carte des zones inondées :

La figure 8 présente la carte des zones inondées obtenue à partir de l'indice MNDWI, illustrant l'étendue spatiale des surfaces en eau identifiées lors de la crue printanière d'avril 2019 dans la région du lac St-Pierre. La cartographie des zones inondées autour du lac St-Pierre lors de la crue exceptionnelle des 21–23 avril 2019 a été réalisée à partir de l'indice MNDWI proposé par Xu (2006), calculé à partir des bandes verte (B3) et SWIR1 (B11) de Sentinel-2. Un seuil de 0,8 a été appliqué afin d'identifier les pixels correspondant à des surfaces inondées. Cette approche a permis de mettre en évidence l'extension maximale des eaux sur les terres agricoles peu ou non végétalisées, où le signal n'était pas masqué par la canopée. Cependant, certains facteurs environnementaux compliquent l'interprétation. En amont de la crue, au mois de mars et au début d'avril, la couverture neigeuse restait importante et des traces de neige et de givre persistaient encore lors du passage Sentinel-2 du 14 avril 2019. Cette situation a pu influencer le signal spectral et fausser la classification. En effet, le MNDWI tend à surestimer les superficies inondées en assimilant à de l'eau certains sols saturés ou gelés partiellement, comme l'ont déjà souligné

Blackmore et al. (2016). Ainsi, si le MNDWI constitue un indicateur efficace pour détecter les zones submergées et suivre l'évolution spatio-temporelle des inondations, son utilisation doit être accompagnée de précautions méthodologiques. L'intégration de données complémentaires (par exemple des séries temporelles plus longues, ou l'apport de données radar Sentinel-1 insensibles aux nuages et à la neige) permettrait d'améliorer la précision et de réduire les biais liés aux conditions climatiques printanières.




Figure 8 : Carte des zones inondées par MNDWI

4.4. Analyse temporelle de la végétation :

L'analyse des courbes de séries temporelles du NDVI (Figures 9 et 10) révèle un retard de croissance significatif des principales cultures entre l'année de référence 2017–2018 et l'année affectée par la crue 2018–2019. Dans des conditions normales, les cultures de blé, de maïs et orge atteignent leur seuil de croissance ($\text{NDVI} \approx 0,2-0,3$) dès le mois de mai. Or, en 2018–2019, ce seuil n'a été franchi qu'en juillet, traduisant un décalage de près de deux mois dans le cycle végétatif. Le blé et l'orge montrent un déplacement marqué de leur pic de NDVI de juin à août, confirmant l'impact direct de l'inondation sur la phénologie. Le maïs présente une dynamique

similaire, avec un retard aussi bien au démarrage qu'au pic de croissance. Le soja, en revanche, est moins affecté : son cycle démarre en juin dans les deux années, mais son maximum NDVI est atteint en août plutôt qu'en juillet, indiquant un décalage d'un mois seulement.

Ces tendances témoignent d'une altération profonde de la dynamique phénologique, liée à la saturation prolongée des sols et aux retards de semis imposés par la crue. Toutefois, il est important de noter que l'ampleur de l'impact varie selon les cultures : les céréales à cycle plus court (blé, orge) semblent plus vulnérables aux décalages, tandis que le soja, bien qu'affecté, conserve une meilleure capacité de résilience. Cette hétérogénéité confirme que les effets d'une inondation ne se traduisent pas uniformément sur toutes les cultures, ce qui doit être pris en compte dans les stratégies d'adaptation.

Sur le plan critique, l'interprétation des courbes NDVI doit être nuancée. D'une part, le NDVI est sensible à la couverture nuageuse, à l'humidité résiduelle et à la structure du couvert, ce qui peut introduire des incertitudes dans la détection des seuils de croissance. D'autre part, la résolution temporelle de Sentinel-2 (5 jours) et les pertes de données dues à la nébulosité limitent parfois la continuité de la série, ce qui peut lisser ou retarder artificiellement certaines tendances. Enfin, l'absence d'intégration de variables agronomiques (date de semis réelle, pratiques culturales) restreint la capacité à attribuer de manière certaine les retards observés uniquement à l'inondation.

En résumé, les séries temporelles de NDVI montrent de façon robuste que la crue exceptionnelle de 2019 a provoqué un retard généralisé de la croissance des cultures au lac St-Pierre, avec une intensité variable selon les espèces. Ces résultats soulignent l'importance de la télédétection pour documenter la phénologie agricole en contexte d'aléas climatiques, tout en rappelant que ces analyses doivent être interprétées avec prudence et idéalement couplées à des données de terrain pour renforcer leur validité scientifique.




Figure 9 : Évolution NDVI d'un pixel représentatif (blé, maïs, orge, soja)




Figure 10. Évolution NDVI sur une parcelle représentative (blé, maïs, orge, soja)

4.5. Visualisation spatio-temporelle de carte de chaleurs du NDVI :

La carte thermique du NDVI (Figure 12), représentée par un dégradé de vert, met en évidence la densité et la vitalité de la végétation sur les terres agricoles du lac St-Pierre. Les valeurs proches de 1, en vert foncé, signalent une forte activité photosynthétique et correspondent aux cultures en bon état, tandis que les tons plus clairs traduisent une faible densité végétale, généralement associée à des sols nus, des parcelles en phase de démarrage ou des zones récemment affectées par l'inondation. Ce type de représentation permet une lecture rapide et intuitive de l'état de la

couverture végétale, tout en offrant une spatialisation fine de l'activité agricole dans les plaines inondables.

Au-delà de l'aspect visuel, l'intérêt de la carte thermique réside dans sa capacité à quantifier et localiser les gradients de vitalité végétale, ce qui facilite l'identification des secteurs les plus vulnérables. Toutefois, une interprétation critique s'impose : le NDVI est sensible à plusieurs facteurs indépendants de l'état réel des cultures, tels que l'humidité résiduelle des sols, la structure du couvert ou les conditions atmosphériques lors de l'acquisition (présence de brume ou d'aérosols). De plus, les zones à forte saturation hydrique peuvent présenter des valeurs artificiellement faibles, conduisant à une sous-estimation de la vigueur végétale.

Ainsi, si la carte thermique NDVI constitue un outil efficace pour le suivi spatial de l'activité agricole, elle doit être intégrée dans une approche multi-indicateurs, combinant par exemple le NDVI avec d'autres indices (SAVI, MNDWI) ou avec des observations de terrain. Cette combinaison permet de distinguer plus clairement les effets liés aux inondations de ceux dus aux stades phénologiques naturels ou aux pratiques culturales.




Figure 11 : Visualisation du NDVI en carte thermique par type de culture

4.6. Classification des zones inondées par apprentissage automatique (approche Random Forest) :

La figure 13 présente les résultats de la classification des zones d'intérêt obtenus à l'aide de l'algorithme Random Forest, permettant d'identifier les principales catégories spatiales de la zone d'étude.

Le modèle a été entraîné sur un ensemble de données d'apprentissage composé à la fois de variables spectrales issues des images Sentinel-2 et de variables dérivées d'indices de télédétection (NDVI, MNDWI, etc.). La sélection des variables explicatives a été réalisée de manière itérative, en s'appuyant sur les mesures d'importance générées lors de la phase d'entraînement. Cette approche a permis de retenir uniquement les prédicteurs les plus pertinents pour distinguer efficacement les classes cibles, à savoir les zones impactées et non impactées.




Figure 12: Classification par Random Forest des cultures affectées (Source : classification réalisée avec Python ; données vectorielles préparées sous SIG)

Le modèle Random Forest entraîné sur les 93 échantillons a été évalué à l'aide d'une validation croisée spatiale à 7 plis, ce qui permet de mesurer sa capacité à généraliser tout en tenant compte de l'autocorrélation spatiale. Les résultats montrent une précision moyenne de 87,2 % sur l'ensemble des plis, avec des scores individuels variant entre 69,2 % et 92,3 %. Cette variabilité est attendue dans un contexte de données limitées et hétérogènes, mais elle confirme globalement la bonne capacité de généralisation du modèle. En complément de cette évaluation quantitative, une analyse visuelle de la carte de classification générée montre une cohérence spatiale satisfaisante, avec une délimitation claire des zones impactées, non impactées et recouvertes d'eau. Les zones d'inondation détectées correspondent aux observations terrain et à l'interprétation visuelle des images satellites.

Cette concordance visuelle, combinée aux bonnes performances statistiques, confirme que le modèle Random Forest, même avec un nombre d'échantillons restreint, est capable de produire une cartographie fiable de l'impact des inondations d'avril 2019 au sein du lac St-Pierre.

4.7. Validation croisée par matrice de confusion et indice Kappa :

La figure 13 présente la matrice de confusion obtenue à partir d'une validation croisée à 7 plis, illustrant la performance de l'algorithme Random Forest dans la classification des différentes zones d'intérêt.




Figure 13 : Matrice de confusion

L'évaluation du modèle Random Forest a été réalisée à l'aide de la matrice de confusion obtenue par validation croisée à 7 plis. Les résultats montrent une précision globale de 82,8 %, indiquant que la majorité des pixels ont été correctement classés dans leur catégorie respective. Cependant, afin de corriger l'influence du hasard, l'indice Kappa a également été calculé. Avec une valeur de 0,69, ce dernier témoigne d'un accord « bon » entre les classes prédites et les classes réelles. L'indice de Kappa obtenu (0,69) traduit un accord substantiel entre les résultats de classification et les données de référence, selon l'échelle de Landis et Koch (1977). Ces résultats confirment la pertinence de l'approche utilisée, tout en mettant en évidence quelques confusions résiduelles entre les classes « impactées » et « non impactées », déjà observées dans la matrice de confusion. L'utilisation conjointe de la précision globale et de l'indice Kappa permet ainsi d'apporter une évaluation plus robuste et nuancée des performances du modèle.

4.8. Analyse comparative de l'impact des inondations sur quatre cultures entre 2017/2018 et 2018/2019 :

La comparaison des indices spectraux pour le blé, le soja, le maïs et l'orge met en évidence l'ampleur de l'impact des inondations de 2018/2019 sur l'agriculture par rapport à la période de référence 2017/2018. Toutes les cultures présentent un retard de plantation de 1 à 2 mois, particulièrement marqué pour le blé, dont le début de croissance est décalé de mai à juillet. L'analyse des séries temporelles NDVI révèle également une diminution significative des valeurs moyenne, traduisant un stress accru des cultures : pour le soja, par exemple, le NDVI moyen passe de 0,20 ($\pm 0,35$) en 2017/2018 à 0,11 ($\pm 0,23$) en 2018/2019. Ce déclin, associé au décalage des pics de NDVI (comme pour le blé, déplacé de juin à août), illustre une perturbation profonde de la phénologie agricole.

Ces résultats sont cohérents avec les conditions environnementales observées, notamment la persistance de la couverture neigeuse jusqu'en avril et l'humidité excessive prolongée, qui ont retardé l'établissement des cultures et limité leur vigueur initiale. L'excès d'eau a également pu provoquer une saturation des sols, une perte de nutriments par lessivage et une fragilisation de la structure pédologique, accentuant les contraintes de croissance. Sur le plan critique, ces observations confirment la vulnérabilité structurelle des systèmes agricoles face aux événements extrêmes, mais elles montrent aussi que les réponses varient selon les espèces : les céréales (blé, orge) apparaissent plus sensibles aux retards, tandis que le soja et le maïs, bien qu'affectés, conservent une relative capacité d'adaptation. Au-delà du constat, cette analyse souligne l'intérêt d'intégrer les indices spectraux comme outils de surveillance opérationnelle de la résilience agricole.

Tableau 1 : Synthèse des dates de semis et de l'évolution du NDVI selon les espèces cultivées

Culture	Année	Retard	Mois de début du semis	Nombre de mois avant la date estimée de semis	Moyenne NDVI	NDVI max	Mois avec couverture neigeuse	Mois avec forte humidité
Blé	2018	0	Mai	4	0.26 (± 0.28)	Juin	Déc, Jan, Fév, Mar	Nov, Déc, Jan, Fév, Mar
	2019	2	Juillet	5	0.19 (± 0.31)	Août	Nov, Déc, Jan, Fév, Mar, Avr	Nov, Déc, Jan, Fév, Mar, Avr
Soja	2018	0	Juillet	5	0.20 (± 0.35)	Août	Déc, Jan, Fév, Mar, Avr	Déc, Jan, Fév, Mar
	2019	1	Août	6	0.11 (± 0.23)	Août	Nov, Déc, Jan, Fév, Mar, Avr	Nov, Déc, Jan, Fév, Mar, Avr
Maïs	2018	0	Juin	4	0.27 (± 0.35)	Août	Déc, Jan, Fév, Mar	Déc, Jan, Fév, Mar
	2019	1	Juillet	5	0.21 (± 0.34)	Août	Déc, Jan, Fév, Mar, Avr	Nov, Déc, Jan, Fév, Mar, Avr
Orge	2018	0	Juin	4	0.26 (± 0.31)	Juil	Déc, Jan, Fév, Mar	Nov, Déc, Jan, Fév, Mar
	2019	1	Juillet	6	0.18 (± 0.30)	Juil	Nov, Déc, Jan, Fév, Mar, Avr	Nov, Déc, Jan, Fév, Mar, Avr

5. DISCUSSION ET INTERPRETATION :

L'objectif principal de cette étude était d'identifier et de cartographier les zones agricoles de la région du lac St-pierre vulnérables aux inondations et d'évaluer leurs effets sur la santé culturelle, en mobilisant les données Sentinel-2 et les indices spectraux tels que le MNDWI et le NDVI. Les résultats obtenus confirment que cette zone est particulièrement exposée aux risques d'inondation, un constat déjà bien documenté dans la littérature (Prowse et al., 2006 ; Damar et al., 2025). Toutefois, l'apport de cette recherche réside dans la capacité de l'approche par télédétection et l'apprentissage automatique à spatialiser et quantifier précisément l'impact des crues de 2019 sur les cultures.

Sur le plan hydrologique, les crues exceptionnelles de 2019, avec un pic atteignant 7,4 m et un maintien au-dessus de 6,2 m durant 55 jours (MAPAQ, 2020), ont entraîné une saturation prolongée des sols agricoles. Cette situation a provoqué des conséquences directes sur le calendrier cultural : retard des semis, difficultés de reprise végétative et baisse des rendements. L'analyse par NDVI a mis en évidence une diminution nette de la vigueur végétale au cours de la saison 2018/2019 comparativement à l'année de référence 2017/2018, en particulier pour le soja et le blé. Ce résultat corrobore les observations agronomiques, qui montrent que les excès d'eau réduisent la germination, retardent la phénologie et fragilisent les cultures face à des stress ultérieurs, notamment la sécheresse estivale (Kanwar, 2012 ; Rupngam et al., 2024).

Au-delà du constat descriptif, ces résultats révèlent un **double effet climatique** :

1. Une **humidité excessive printanière**, qui empêche les pratiques culturales normales (labour, semis) et favorise l'engorgement des sols.
2. Une **sécheresse estivale**, qui freine la croissance post-inondation et accentue les pertes de rendement.

Ce contraste souligne la vulnérabilité des systèmes agricoles du lac St-Pierre face aux aléas hydro-climatiques , mais également la nécessité d'intégrer la télédétection dans une stratégie de gestion des risques agricoles.

L'approche par **Random Forest**, optimisée par recherche d'hyperparamètres ($n_estimators = 80$; $max_features = 9$), a montré une bonne capacité de discrimination entre les zones impactées, non impactées et aquatiques, avec une précision globale de 82,8 % et un indice Kappa de 0,69. Ces résultats indiquent un accord substantiel, mais révèlent également certaines confusions résiduelles

entre les classes « impactées » et « non impactées ». Ce biais peut être attribué à la similarité spectrale de certaines cultures affaiblies ou à l'influence de la saturation hydrique sur la réflectance des sols argileux. Ainsi, si le modèle confirme la pertinence du RF pour cartographier les impacts des inondations, il met aussi en évidence ses limites : dépendance à la qualité des données d'entraînement, difficulté à généraliser hors du contexte étudié, et sensibilité aux conditions atmosphériques (présence de nuages).

Du point de vue agronomique et socioéconomique, les retards observés dans la phénologie des cultures ont des implications majeures. Pour le soja, le retard de plantation d'un mois a réduit la durée de la phase végétative, limitant la floraison et le remplissage des gousses (Sang et al., 2022 ; Parasuraman et al., 2023). Pour le blé et l'orge, les semis tardifs (jusqu'à deux mois de décalage) ont réduit la période de croissance optimale, entraînant une baisse de productivité. Ces effets cumulés se traduisent par des pertes économiques notables pour les producteurs, aggravées par la récurrence des crues et l'irrégularité des précipitations dans cette région (MAPAQ, 2020).

Enfin, cette étude met en lumière la nécessité d'une adaptation des pratiques culturales face à l'augmentation prévue de la variabilité climatique. Des solutions innovantes émergent dans la littérature : le priming des semences pour améliorer la germination en conditions froides (Rahman, 2025), l'utilisation de couverts végétaux à forte biomasse pour accélérer le réchauffement du sol (Çerçioğlu et al., 2025), ou encore la surveillance météorologique fine pour optimiser les fenêtres de semis (Wu, 2023). L'intégration de ces stratégies, combinée à la télédétection, pourrait permettre de réduire les impacts des crues récurrentes et d'accroître la résilience du système agricole du lac St-Pierre. Les résultats issus de l'analyse NDVI mettent en évidence une réduction significative de la vigueur végétale en 2018/2019 par rapport à 2017/2018, particulièrement pour le soja et le blé. Cela confirme l'impact direct de l'inondation prolongée et de la saturation des sols sur le cycle cultural. Ce retard, perceptible dès le printemps, entraîne une fenêtre de croissance raccourcie, une perte de nutriments par lessivage, une dégradation de la structure du sol et une compétition accrue avec les adventices. Ces facteurs se traduisent par une baisse notable de rendement et une perte économique directe pour les producteurs.

Pour les exploitations du lac St-Pierre, cette situation constitue une double contrainte. D'une part, les investissements en préparation du sol, intrants et traitements sont accrus. D'autre part, les

revenus agricoles diminuent, ce qui peut compromettre la viabilité financière de certaines fermes et conduire à des réorganisations culturelles.

Les effets dépassent l'échelle de la parcelle. Ils concernent l'instabilité des revenus, la pression sur les ménages agricoles, le risque de décapitalisation ou de migration, l'augmentation de la dépendance aux importations et les tensions sur les prix des céréales. À cela s'ajoute la mobilisation croissante des dispositifs d'assurance et de soutien public, qui alourdit la charge socioéconomique régionale.

Cependant, l'interprétation de ces résultats doit être nuancée. Le modèle Random Forest, bien qu'ayant montré une précision satisfaisante, reste calibré spécifiquement sur la crue de 2019 et pourrait ne pas être généralisable à d'autres contextes hydrologiques ou climatiques. De plus, la résolution spatiale de Sentinel-2 (10–20 m) ne permet pas de saisir certaines hétérogénéités fines, et le nombre limité de points d'entraînement peut fragiliser la robustesse des classifications, en particulier pour les classes minoritaires.

Enfin, il convient de rappeler que plusieurs variables agronomiques et humaines n'ont pas été intégrées. Le type de sol, la fertilité initiale, les pratiques culturales ou encore les interventions post-crue (drainage, réparations) influencent fortement les résultats réels. Par ailleurs, les répercussions socioéconomiques s'étendent sur plusieurs années. Une analyse saisonnière unique sous-estime probablement les effets différés tels que l'érosion progressive, l'appauvrissement des sols ou la fragilisation durable des revenus agricoles.

6. CONCLUSION

Cette recherche, fondée sur l'analyse de données satellitaires et l'application de modèles d'apprentissage automatique, met en lumière l'impact des inondations printanières de 2019 sur le secteur agricole de la région du lac St-Pierre. Les résultats obtenus révèlent une vulnérabilité marquée des terres cultivées face aux événements météorologiques extrêmes, qui se traduisent par des retards significatifs dans les cycles de plantation et de croissance, en particulier pour les cultures stratégiques (soja, blé, maïs). L'exploitation d'indices spectraux tels que le MNDWI et le NDVI a permis d'identifier avec précision les zones inondées, tout en assurant un suivi temporel de la vigueur et de l'état sanitaire des cultures durant la saison de croissance. Il apparaît que les contraintes hydriques, exacerbées par des conditions climatiques défavorables — notamment des températures extrêmes et des gels prolongés —, ont accentué les effets délétères des inondations.

L'intégration de l'apprentissage automatique, notamment l'algorithme Random Forest, s'est avérée particulièrement efficace pour la classification et la détection des zones inondées. Cette méthodologie a permis de cibler les secteurs à plus haute exposition, ouvrant ainsi des perspectives opérationnelles pour une gestion proactive et une optimisation de la planification des interventions. L'étude démontre ainsi la valeur ajoutée des technologies de télédétection et de l'intelligence artificielle dans l'analyse et le pilotage des impacts des inondations sur les systèmes agricoles.

Pour l'avenir, il serait opportun d'envisager l'intégration de flux de données en temps réel dans les modèles prédictifs, afin d'accroître la réactivité des dispositifs d'alerte et de faciliter une prise de décision rapide. Par ailleurs, une étude approfondie des effets à long terme du changement climatique sur la productivité agricole, tant dans la région du lac St-Pierre que dans d'autres zones vulnérables, pourrait permettre de concevoir des stratégies d'adaptation plus résilientes. Ces travaux contribueraient à renforcer la robustesse des systèmes agricoles et à préserver la sécurité alimentaire dans un contexte de variabilité climatique accrue.

7. BIBLIOGRAPHIE

- Agriculture à Québec. (2020). *Industrie agricole au Québec : Culture de grains, céréales et oléagineux*. Gouvernement du Québec. <https://www.quebec.ca/agriculture-environnement-et-ressources-naturelles/agriculture/industrie-agricole-au-quebec/productions-agricoles/culture-grains-cereales-oleagineux>
- Amellah, O., Mignosa, P., Prost, F., & Aureli, F. (2024). Assessment of flood hazard mapping using a DEM-based approach and 2D hydrodynamic modeling. *Water*, 16(13), 1844. <https://doi.org/10.3390/w16131844>
- Bamber, J. L., Lee, H., & Civelli, A. (2023). A large-scale flood modeling using geometry-adaptive physics-informed neural solver and Earth observation data. *EGU General Assembly*. <https://doi.org/10.5194/egusphere-egu23-3276>
- Bélanger, G., Y. Castonguay, A. Bertrand, C. Dhont, P. Rochette, L. Couture, R. Drapeau, D. Mongrain, F.-P. Chalifour, et R. Michaud. (2006) « Winter Damage to Perennial Forage Crops in Eastern Canada: Causes, Mitigation, and Prediction ». *Canadian Journal of Plant Science*, 86(1): 33-47. <https://doi.org/10.4141/P04-171>
- Belgiu, M., & Drăguț, L. (2016).** Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Boudreau, P., Leclerc, M., & Fortin, G. (1994). Modélisation hydrodynamique du lac St-Pierre, fleuve St-Laurent : l'influence de la végétation aquatique. *Canadian Journal of Civil Engineering*, 21(3), 471–489. <https://doi.org/10.1139/L94-05>
- Brown, D. M., & Blackburn, W. J. (1987). Impacts of freezing temperatures on crop production in Canada. *Canadian Journal of Plant Science*, 67(4), 1167–1180. <https://doi.org/10.4141/cjps87-156>
- Cahyono, B. E., Putri, P. O., Subekti, A., Nugroho, A. T., & Nishi, K. (2022). Analysis of soil moisture as an indicator of land quality using vegetation index (SAVI and NDMI) retrieved from remote sensing data in Jember-Indonesia. In *AIP Conference Proceedings* (Vol. 2391, No. 1) . <https://doi.org/10.1063/5.00078761>
- Çerçioğlu, M., Udawatta, R. P., & Anderson, S. H. (2025). Use of cover crops for sustainable management of soil condition and health: A review. *Geoderma Regional*, Article 100177. <https://doi.org/10.1016/j.soisec.2025.100177>
- Chow, V. T., Maidment, D. R., & Mays, L. W. (1988). *Applied hydrology*. McGraw-Hill.
- Damar, H., Vaillancourt, M., Bourgeois, B., & Poulin, M. (2025). Establishing perennial strips in a cultivated floodplain for habitat restoration: Monitoring over 4 years and success drivers. *Restoration Ecology*, 33(1), e14302. <https://doi.org/10.1111/rec.14302>
- de la Chenelière, V., Brodeur, P., & Mingelbier, M. (2014). Restauration des habitats du lac St-Pierre : un prérequis au rétablissement de la perchaude. *Le Naturaliste Canadien*, 138, 50–61.
- Development of a fast and accurate hybrid model for floodplain inundation. (2023). *ESSOAr Preprints*. <https://doi.org/10.22541/essoar.168121557.70526015/v1>
- Egli, D. B., & Cornelius, P. L. (2009). A regional analysis of the response of soybean yield to planting date. *Agron J.*, 101, 330–335.
- Elshikha, D. E. (2024). *Guidance for soil moisture sensor selection: Market analysis and decision-making strategy*. College of Agriculture, Life & Environmental Sciences, University of Arizona. <https://creativecommons.org/licenses/by-nc-sa/4.0/>
- ESA. (2015). *Sentinel-2 handbook*.

- Farley, L., Hudon, C., Cattaneo, A., & Cabana, G. (2019). Seasonality of a floodplain subsidy to the fish community of a large temperate river. *Ecosystems*, 22(8), 1823–1837.
- Felegari, S., Sharifi, A., Moravej, K., Golchin, A., & Tariq, A. (2022). In P. Kumar, A. K. Pandey, S. K. Singh, S. S. Singh, & V. K. Singh (Chap. 15). John Wiley & Sons. <https://doi.org/10.1002/9781119808565.ch15>
- Fernández-Nóvoa, D., González-Cao, J., & García-Feal, O. (2024). Enhancing flood risk management: A comprehensive review on flood early warning systems with emphasis on numerical modeling. *Water*. <https://doi.org/10.3390/w16101408>
- Feyisa, G. L., Meilby, H., Fensholt, R., & Proud, S. R. (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*, 140, 23–35.
- Fidan, E., Gray, J. M., Doll, B. A., & Nelson, N. G. (2023). Machine learning approach for modeling daily pluvial flood dynamics in agricultural landscapes. *Environmental Modelling and Software*, 167, 105758. <https://doi.org/10.1016/j.envsoft.2023.105758>
- Fischer, R. A., Byerlee, D., & Edmeades, G. O. (2014). *Crop Yields and Climatic Variability: Implications for Semis et Rendement*. Springer.
- Foody, G. M. (2002).** Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Fraehr, N., Wang, Q. J., Wu, W., & Nathan, R. (2022). Upskilling low-fidelity hydrodynamic models of flood inundation through spatial analysis and Gaussian process learning. *Water Resources Research*, 58. <https://doi.org/10.1029/2022WR032248>
- Fraehr, N., Wang, Q. J., Wu, W., & Nathan, R. (2024). Assessment of surrogate models for flood inundation: The physics-guided LSG model vs. state-of-the-art machine learning models. *Water Research*. <https://doi.org/10.1016/j.watres.2024.121202>
- Fraehr, N., Wang, Q., Wu, W. K., & Nathan, R. (2023). Development of a fast and accurate hybrid model for floodplain inundation simulations. *Water Resources Research*, 59. <https://doi.org/10.1029/2022WR033836>
- Gentsch, N., Riechers, F. L., Boy, J., Schweneker, D., Feuerstein, U., Heuermann, D., & Guggenberger, G. (2024). Cover crops improve soil structure and change organic carbon distribution in macroaggregate fractions. *Soil*, 10, 139–150. <https://doi.org/10.5194/soil-10-139-2024>
- Gao, B.-C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gascoin, S., Grizonnet, M., Bouchet, M., Salgues, G., & Hagolle, O. (2020).** Theia Snow collection: High-resolution operational snow cover maps from Sentinel-2 and Landsat-8 data. *Remote Sensing*, 12(18), 2945. <https://doi.org/10.3390/rs12182945>
- Gordon, C., Foulon, É., & Rousseau, A. N. (2023). Deriving synthetic rating curves from a digital elevation model to delineate the inundated areas of small watersheds. *Journal of Hydrology: Regional Studies*. <https://doi.org/10.1016/j.ejrh.2023.101580>
- Gouvernement du Québec. (2019). *Rapport sur les inondations printanières au Québec*.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)

- Institut de la statistique du Québec. (2023). *Indicateurs de progrès – anomalies de température*. <https://statistique.quebec.ca/fr/produit/publication/indicateurs-progres-anomalies-temperature#note-desc-3>
- IPCC. (2021). *Sixth Assessment Report: Climate Change (2021)*.
- Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., & Nearing, G. S. (2019). Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences*, 23(12), 5089–5110. <https://doi.org/10.5194/hess-23-5089-2019>
- Kanwar Lal Sahrawat. (2012). Soil fertility in flooded and non-flooded irrigated rice systems. *Archives of Agronomy and Soil Science*, 58(4), 423–436.
- Kumudini, S. V., Pallikonda, P. K., & Steele, C. (2007). Photoperiod and e-genes influence the duration of the reproductive phase in soybean. *Crop Sci.*, 47, 1510–1517.
- Li, L., & Jun, K. S. (2022). A hybrid approach to improve flood forecasting by combining a hydrodynamic flow model and artificial neural networks. *Water*, 14(9), 1393. <https://doi.org/10.3390/w14091393>
- Lin, J., Sreng, C., Oare, E., & Batarseh, F. A. (2024). NeuralFlood: An AI-Driven Flood Susceptibility Index. *Proceedings of the AAAI Symposium Series*, 2(1), 94–101. <https://doi.org/10.1609/aaais.v2i1.27655>
- Ma, B. L., Dwyer, L. M., Costa, C., Cober, E. R., & Morrison, M. J. (2001). Early prediction of soybean yield from canopy reflectance measurements. *Agronomy Journal*.
- Matte, P., Secretan, Y., & Morin, J. (2017). Hydrodynamic modeling of the St. Lawrence fluvial estuary. I: Model setup, calibration, and validation. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 143(5), 04017010. [https://doi.org/10.1061/\(ASCE\)WW.1943-5460.0000397](https://doi.org/10.1061/(ASCE)WW.1943-5460.0000397)
- Matasci, G., Hermosilla, T., Wulder, M. A., White, J. C., Coops, N. C., Hobart, G. W., & Zald, H. S. J. (2018).** Large-area mapping of forest disturbances and recovery from Sentinel-2 time series. *Remote Sensing of Environment*, 217, 18-32. <https://doi.org/10.1016/j.rse.2018.08.034>
- MDDEFP (Ministère du Développement durable, de l'Environnement, de la Faune et des Parcs). (2013). *Le Lac St-Pierre*.
- MDDELCC, Ministère du Développement durable, de l'Environnement et de la Lutte contre les changements climatiques, 2018. *Mapping major floods April–May 2017*. Canada. <https://open.canada.ca/data/dataset/34085f6d-106a-41af-a29b-53ed6947c249>
- MDDELCC, Ministère du Développement durable, de l'Environnement et de la Lutte contre les changements. *Utilisation du territoire 2020*. Gouvernement du Québec.
- MAPAQ, Ministère de l'Agriculture, des Pêcheries et de l'Alimentation Québec (2024). <https://www.mapaq.gouv.qc.ca/fr/Pages/Accueil.aspx>
- MODIS Web. (s.d.). Consulté le 21 janvier 2025. <https://modis.gsfc.nasa.gov/data/>
- Monteleone, B., Giusti, R., Magnini, A., Arosio, M., Domeneghetti, A., Borzi, I., Petruccelli, N., Castellarin, A., Bonaccorso, B., & Martina, M. L. V. (2023). Estimations of crop losses due to flood using multiple sources of information and models: The case study of the Panaro River. *Water*, 15(11), 1980. <https://doi.org/10.3390/w15111980>
- Muhadi, N. A., Abdullah, A. F., Vojinovic, Z., & Vojinovic, Z. (2017). Estimating agricultural losses using flood modeling for rural area. *MATEC Web of Conferences*, 103, 04009. <https://doi.org/10.1051/MATECONF/201710304009>
- Olcese, G., Sampson, C., Chon, G. N., Biron, P., & Buffin-Bélanger, T. (n.d.). Large-scale flood models in watersheds with several lakes and reservoirs. *Authorea*. <https://doi.org/10.22541/au.160010749.97447657>

Paradis, A. (2015). *Integrating hydrogeomorphological concepts in management approaches of lowland agricultural streams in Quebec: Perspectives, problems and prospects* (Doctoral dissertation, Concordia University).

Parasuraman, B., Rajamanickam, V., Rathinavelu, S., Geethanjali, S., & Alagaraswamy, S. (2024). Interactive effect of drought and high temperature on physiological traits of soybean (*Glycine max*). *Plant Physiology Reports*, 29(1), 116-124. <https://doi.org/10.1007/s40502-023-00767-z>

Paswan, N. G., & Ray, L. K. (2024). Intelligent solutions for flood management: Integrating artificial intelligence and machine learning (pp. 43–55). *Springer Nature*. https://doi.org/10.1007/978-981-97-1685-2_3

Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J.-M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503–510. <https://doi.org/10.1016/j.tree.2005.05.011>

□

Prowse, T. D., et al. (2006). Climate change effects on hydroecology of Arctic freshwater ecosystems. *Ambio*, 35(7), 347–358.

Perception et Stratégies d'adaptation Aux Incertitudes Climatiques Par Les Exploitants Agricoles Des Zones Marécageuses Au Sud-Kivu Farmers' Perception of Climate Uncertainties and Adaptation Strategies in the Swampy Areas of South Kivu. (2025, mai). *ResearchGate*. <https://doi.org/10.4000/vertigo.3167> Rhaman, M. S. (2025). Seed priming before the sprout: Revisiting an established technique for stress-resilient germination. *Seeds*, 4(3), 29. <https://doi.org/10.3390/seeds4030029>

Rupngam, T., & Messiga, A. J. (2024). Unraveling the interactions between flooding dynamics and agricultural productivity in a changing climate. *Sustainability*, 16(14), 6141.

Rupngam, Thidarat, & Messiga, Aimé J. (2024). « Unraveling the Interactions between Flooding Dynamics and Agricultural Productivity in a Changing Climate ». *Sustainability*, 16(14), 6141. <https://doi.org/10.3390/su16146141>

Salas, J. D., Obeysekera, J., & Vogel, R. M. (2018). Techniques for frequency analysis of hydrologic extremes. *Journal of Hydrologic Engineering*, 23(2), 04018002. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001662](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001662)

Salomonson, V. V., & Appel, I. (2006). Development of the Aqua MODIS NDSI fractional snow cover algorithm and validation results. *IEEE Transactions on Geoscience and Remote Sensing*, 44(7), 1747–1756. <https://doi.org/10.1109/TGRS.2006.876029>

Sang, W. G., Baek, J. K., Kwon, D. W., & Cho, J. I. (2022). Impact of climate change on yield and canopy photosynthesis of soybean. *Korean Journal of Agricultural and Forest Meteorology*, 24, 275–284.

Schumann, G. J.-P., Kar, B., Sharma, P., Bausch, D., Wang, J., & Glasscoe, M. (2023). Early warning for all with a model-of-models approach. *IGARSS*, 456–459. <https://doi.org/10.1109/igarss52108.2023.10282256>

Scriven, B. W. G., McGrath, H., & Stefanakis, E. (2021). GIS derived synthetic rating curves and HAND model to support on-the-fly flood mapping. *Natural Hazards*, 109(2), 1. <https://doi.org/10.1007/S11069-021-04892-6>

St-Laurent, D., Lavoie, L., Drouin, A., St-Laurent, J., & Ghaleb, B. (2010). Floodplain sedimentation rates, soil properties and recent flood history in southern Québec. *Global and Planetary Change*, 70(1–4), 76–91. Surunis, A. (2022). Linking statistical, hydrodynamic and machine learning models for assessment of compound floods. *EGU General Assembly*. <https://doi.org/10.5194/egusphere-egu22-4388>

Szabo, S., Gácsi, Z., & Balazs, B. (2016). Specific features of NDVI, NDWI and MNDWI as reflected in land cover categories.

Takaro, T. (2022). Qualité, quantité et sécurité de l'eau.

Traore, B., Corbeels, M., van Wijk, M. T., Rufino, M. C., & Giller, K. E. (2013). Effects of climate variability and climate change on crop production in southern Mali. *European Journal of Agronomy*, 49(août), 115–125. <https://doi.org/10.1016/j.eja.2013.04.004>

Union des producteurs agricoles. (2019). *Rapport économique sur les pertes agricoles*.

Wu, W., Wang, Q., & Vaze, J. (2022). A 2D hydrodynamic model-based method for efficient flood inundation modelling. *Journal of Hydroinformatics*, 24(5), 1004–1019. <https://doi.org/10.2166/hydro.2022.13>

Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033.

Yin, F., Lewis, P. E., Gomez-Dans, J. L., & Wu, Q. (2019). A Sensor Invariant Atmospheric Correction: Sentinel-2/MSI and Landsat 8/OLI.

Yin, Feng, Lewis, P. E., Gomez-Dans, J. L., & Wu, Q. (2019). Withdrawn: A Sensor-Invariant Atmospheric Correction Method: Application to Sentinel-2/MSI and Landsat 8/OLI. *OSF*. https://osf.io/ps957_v1

Yue, J., Li, T., Shen, J., Wei, Y., Xu, X., Liu, Y., & Feng, H. (2024). Winter wheat maturity prediction via Sentinel-2 MSI images. *Agriculture*, 14(8), 1368.

Zhang, L., & Zhang, L. (2022). Artificial intelligence for remote sensing data analysis: A review of challenges and opportunities. *IEEE Geoscience and Remote Sensing Magazine*, 10(2), 270–294. <https://doi.org/10.1109/MGRS.2022.3145854>

Zhou, L., & Liu, L. (2024). Enhancing dynamic flood risk assessment and zoning using a coupled hydrological-hydrodynamic model and spatiotemporal information weighting method. *Journal of Environmental Management*, 366, 121831. <https://doi.org/10.1016/j.jenvman.2024.121831>

Zhu, S., & Mao, J. (2021). A machine learning approach for estimating the trophic state of urban waters based on remote sensing and environmental factors. *Remote Sensing*, 13(13), 2498.

Wu, B., Zhang, M., Zeng, H., Tian, F., Potgieter, A. B., Qin, X., Yan, N., Chang, S., Zhao, Y., Dong, Q., Boken, V., Plotnikov, D., Guo, H., Wu, F., Zhao, H., Deronde, B., Tits, L., & Loupian, E. (2023). Challenges and opportunities in remote sensing-based crop monitoring: A review. *National Science Review*, 10, nwac290.