

Faculté des bioingénieurs

Comment améliorer la quantification du statut hydrique de la vigne par satellite grâce aux données multispectrales de drone : cas d'étude de deux vignobles belges.

Auteur : Arthur Sillis

Promoteur(s) : Prof. Mathieu Javaux(UCLouvain/ELI/ELIE)
Louis Delval (UCLouvain/ELI/ELIE)

Lecteur(s) : Prof. Bruno Delvaux (UCLouvain/ELI/ELIE)
Prof. Jonard François (UCLouvain/ELI/ELIE)

Année académique : 2023-2024

Mémoire de fin d'études présenté en vue de l'obtention du diplôme de Bioingénieur : sciences et technologies de l'environnement

Table des matières

| | |
|--|----|
| Remerciements..... | 6 |
| Liste des abréviations | 7 |
| Liste des figures | 8 |
| Liste des tableaux | 10 |
| 1 Introduction..... | 11 |
| 2 Contexte | 12 |
| 2.1 La viticulture en Belgique | 12 |
| 2.2 Un changement climatique « favorable »..... | 13 |
| 3 Etat de l'art | 14 |
| 3.1 L'importance du stress hydrique pour la viticulture..... | 14 |
| 3.2 Les paramètres physiologiques du stress hydrique dans la vigne | 16 |
| 3.3 La télédétection en viticulture..... | 17 |
| 3.3.1 Utilisation dans la détermination du stress hydrique..... | 17 |
| 3.3.2 Les différents outils de télédétection | 21 |
| 3.4 Comparaison entre drone et Sentinel-2 | 26 |
| 4 Objectifs..... | 29 |
| 5 Matériel et méthode | 30 |
| 5.1 Zone d'étude..... | 30 |
| 5.2 Les outils de télédétection | 34 |
| 5.2.1 Drone | 34 |
| 5.2.2 Sentinel-2..... | 35 |
| 5.3 Acquisition des données..... | 36 |
| 5.4 Les outils statistiques..... | 37 |
| 5.4.1 La corrélation de Pearson | 37 |
| 5.4.2 Le coefficient de détermination | 37 |
| 5.4.3 L'intervalle de prédiction | 37 |
| 5.4.4 La stepwise linear regression..... | 38 |
| 5.5 Méthodologie générale | 39 |
| 5.5.1 Relation entre le rang et l'inter-rang | 39 |
| 5.6 Comparaison entre drone et Sentinel | 46 |
| 5.7 Recherche d'indices Sentinel corrélés au potentiel vigne | 47 |
| 6 Résultats | 49 |
| 6.1 Séparation de l'ombre | 49 |
| 6.1.1 Classification supervisée..... | 49 |
| 6.1.2 Modélisation de l'ombre à partir du « canopy heigt model » | 50 |

| | |
|---|-----|
| 6.2 Étude des relations entre le « drone rang », « drone inter-rang » et « drone mixte » | 52 |
| 6.2.1 Bande par bande | 52 |
| 6.2.2 Pour différents indices | 54 |
| 6.3 Comparaison entre Sentinel-2 et drone | 56 |
| 6.3.1 Bande par bande | 56 |
| 6.3.2 Pour les Indices | 57 |
| 6.4 Détermination du potentiel foliaire de base directement depuis les bandes Sentinel | 58 |
| 6.4.1 Résultats pour les différents indices | 58 |
| 6.4.2 Stepwise linear regression | 59 |
| 6.4.3 Validation | 61 |
| 7 Discussion | 63 |
| 7.1 L'évolution du rang et de l'inter-rang | 63 |
| 7.2 Les indices spectraux et les prises de mesures | 65 |
| 7.3 Stepwise linear regression | 67 |
| 8 Conclusion | 70 |
| Références bibliographiques | 71 |
| Annexes | 76 |
| Annexe A : Comparaison des réflectances entre le rang et l'inter-rang pour le NIR et le RedEdge .. | 76 |
| Annexe B : Gamme de valeur de potentiel trouver dans la surface d'un pixel Sentinel. | 77 |
| Annexe C : Résultat de la stepwise linear regression | 77 |
| Annexe D : Résultat de l'unmixing | 78 |
| Annexe E : bandes Sentinel-2 | 78 |
| Annexe F : Tableau reprenant les principaux indices utilisés pour détecter le potentiel hydrique. . | 79 |
| Annexe G : Valeurs de plusieurs comparaisons pour d'autres pistes envisagées | 80 |
| Annexe H : Valeurs des signatures spectrales utilisées pour l'unmixing | 82 |
| Annexe I : Indices utilisés pour la stepwise | 83 |
| Annexe J : Script python | 84 |
| Annexe K : Script Rstudio | 99 |
| Annexe L : SVM pour la quantification de la proportion de rang. | 102 |
| Annexe M : Equation et code pour le calcul d'angle solaire | 102 |

Remerciements

Je tiens tout d'abord à exprimer ma profonde gratitude envers mes deux promoteurs, le Professeur Mathieu Javaux et le futur docteur Louis Delval. Leur patience et leur soutien ont été d'une aide inestimable tout au long de l'élaboration de ce travail. Je remercie chaleureusement le Professeur Mathieu Javaux pour ses remarques toujours pertinentes et éclairées. Sa logique et son sens de l'analyse, bien que donnant parfois le vertige, ont été une source d'inspiration constante. Je souhaite également adresser mes remerciements les plus sincères à Louis Delval pour les précieux conseils prodigués lors de nos nombreuses réunions hebdomadaires en plus de ses encouragements permanents. Sa passion et son expertise dans le domaine viticole m'ont été d'un soutien indéfectible jusqu'au bout. Je lui adresse tous mes vœux de réussite pour la remise de sa thèse.

Je tiens également à remercier le Professeur Pierre Defourny et Julien Radoux pour leurs conseils avisés en télédétection.

Un grand merci également à Monsieur Vincent Dienst et Monsieur Michel Verhaeghe de Naeyer pour m'avoir donné l'opportunité de visiter le Vignoble du Château de Bousval, ainsi qu'à Sophie Wautier et Dimitri Vander Heyden pour m'avoir permis d'accéder au Domaine W. Je leur souhaite le meilleur dans la concrétisation de leurs projets.

Je suis également reconnaissant envers le Professeur François Jonard et le Professeur Bruno Delvaux d'avoir accepté de faire partie de mon jury.

Liste des abréviations

| | |
|------|--|
| ANN | Artificial Neural Network |
| CHM | Canopy Height Model |
| DSM | Digital Surface Model |
| STM | Digital terrain Model |
| ETM | EvapoTranspiration Maximum |
| ETP | EvapoTranspiration Potentiel |
| GCM | Global Circulation Model |
| Kc | Coefficient cultural |
| LAI | Leaf Area Index |
| LSU | Linear Spectral Unmixing |
| LWP | Leaf Water Potential |
| MSWP | Midday Stem Water Potential |
| NDPI | Normalized Difference Phenology Index |
| NDSI | Noramlized Difference Snow index |
| NDVI | Noramlized Difference Vegetation Index |
| NIR | Near InfraRed |
| PRI | Photochemical Reflectance Index |
| RGB | Red Green Blue |
| SLR | Stepwise Linear Regression |
| SWI | Short Wave InfraRed |
| SWP | Stem Water Potential |
| S2 | Sentinel-2 |
| TOA | Top Of Atmosphere |
| UAV | Unmanned Aerial Vehicle |

Liste des figures

| | |
|---|----|
| Figure 1 : évolution de la surface de vigne cultivée et de la production de vin en Belgique de 2006 à 2022 (Source : SPF Economie). | 12 |
| Figure 2 : La variation de l'aptitude viticole est montrée entre la période actuelle (1961-2000) et 2050 (2041-2060), en mettant en évidence l'accord parmi un ensemble de 17 modèles climatiques. Les zones où l'aptitude actuelle diminue d'ici 2050 sont indiquées en rouge (plus de 50% des GCM). Les zones où l'aptitude actuelle est maintenue sont indiquées en vert clair (plus de 50% des GCM) et en vert foncé (plus de 90% des GCM), tandis que les zones non aptes dans la période actuelle mais aptes dans le futur sont représentées en bleu clair (plus de 50% GCM) et en bleu foncé (plus de 90% des GCM). (Hannah et al.,2013) | 13 |
| Figure 3 : graphique indiquant la contrainte hydrique souhaitée pour la vigne en fonction du stade phénologique et du type de vin fabriqué. Ψ_t représente le potentiel de tige à midi, Ψ_b représente le potentiel de base et Ψ_h le potentiel hydrique du sol. (Pinel, 2021)..... | 15 |
| Figure 4 : représentation du spectre de réflectance de la végétation et des paramètres influençant la réponse spectrale de la végétation dans les différentes longueurs d'onde. (source : Pinel et al.,2021) | 17 |
| Figure 5 : Spectroscopie de la vigne pour différents potentiels hydriques (source : Pôças et al. (5a) ; Gonzàlez_Fernàndez et al (5b))..... | 18 |
| Figure 6 : Représentation de l'indice NDWI pour une feuille sèche et verte. On comprend qu'un indice élevé correspond à une feuille avec une forte teneur en eau et inversement. | 19 |
| Figure 7 : Meilleures bandes à utiliser pour faire le modèle de régression d'après l'étude de (Laroche Pinel et al. 2021). | 22 |
| Figure 8 : (a) Vue aérienne d'un verger de grenadier (<i>Punica granatum</i> L.) et les pixels S2. (b) signature spectrale de la végétation pure. (c) signature spectrale de sol pur. (d) signature spectrale mixte. (Source : (Borgogno Mondino et al., 2022))..... | 23 |
| Figure 9 : Plage de variation, exprimée à l'aide du coefficient de Gini sous forme de boîtes à moustaches, dans les quatre couches à travers 30 parcelles de vignes. (Source : (Sozzi et al., 2020))..... | 27 |
| Figure 10 : Localisation des parcelles d'étude. | 30 |
| Figure 11 : Parcelle d'étude du « Vignoble du Château de Bousval »..... | 31 |
| Figure 12 : Courbe de niveau du Vignoble du château de Bousval (auteur : Clémence Becker)..... | 32 |
| Figure 13 : interpolation de la profondeur d'apparition du sable bruxellien dans la parcelle du Château de Bousval (Auteur : (Claessens,2024). | 32 |
| Figure 14 : Parcelle d'étude du « Domaine W » | 33 |
| Figure 15 : Type de sol du « Domaine W » | 34 |
| Figure 16 : exemple de sélection des échantillons pour les deux classes : en bleu l'ombre et en vert la lumière. . | 41 |
| Figure 17 : a) image Zenmuse RGB haute résolution, b) résultat de la classification : l'ombre en noir et la lumière en blanc, c) suppression des pixels « rang » et vectorisation. Les lignes noires représentent le quadrillage qui divisait le raster pour la vectorisation. | 42 |
| Figure 18 : méthode pour passer du CHM à un masque des surfaces d'ombre..... | 44 |
| Figure 19 : illustration des pixels se trouvant à l'intérieur de la ROI (à droite) et des pixels sélectionnés (à gauche)..... | 46 |
| Figure 20: exemple de rééchantillonnage d'un raster "drone" | 47 |
| Figure 21 : Diagramme représentant la méthodologie utilisée pour étudier la corrélation entre le potentiel de tige et différents indices. | 48 |
| Figure 22 : Illustration de la limite de la modélisation de l'ombre dans la détection des trous dans la canopée.. | 51 |
| Figure 23 : a) graphique de la réflectance du RedEdge entre le rang et l'inter-rang , b) graphique de la réflectance du rouge entre le rang et l'inter-rang et c) graphique de la réflectance du NIR entre le rang et l'inter-rang. La ligne jaune correspond à la droite de régression, la rouge à la droite $y = x$. Les points pleins correspondent à Bousval et les creux au domaine W. | 53 |
| Figure 24 : Potentiel prédit par SLR sur la base des indices Sentinel en fonction du potentiel. | 59 |

Figure 25 : Potentiel prédit par SLR sur base des indices Sentinel possédant un coefficient de détermination supérieure à 0.6 avec le « potentiel de rang calculé-rééchantillonné » et dont la corrélation entre le rang et l'inter-rang est également supérieur à 0.6. 60

Figure 26 : Potentiel prédit par SLR en fonction du potentiel mesuré pour les dates ne disposant pas de vol de drone. 61

Figure 27 : graphique représentant la variabilité intra-pixel du potentiel (stepwise model) du rang. Les points correspondent à la moyenne des pixels de drone dans la surface d'un pixel Sentinel (« stepwise rang ») et les lignes verticales correspondent au premier écart-type de la gamme de valeurs trouvée au sein de ce pixel. 62

Figure 28 : a) Différence entre le potentiel prédit et le potentiel mesuré (b-a), b) potentiel mesuré et c) potentiel prédits par SLR sur base des données Sentinel-2..... 69

Liste des tableaux

| | |
|--|-----------|
| <i>Tableau 1 : recensement des résultats des comparaisons entre S2/Landsat8 et UAV pour la vigueur.</i> | <i>27</i> |
| <i>Tableau 2 : Température et précipitation de la station de Uccle pour les mois de prise de mesure (source : IRM)</i> | <i>30</i> |
| <i>Tableau 3 : Longueur d'onde centrale des différentes bandes du capteur MicaSense RedEdge-M Sensor et Sentinel.....</i> | <i>35</i> |
| <i>Tableau 4 : Dates d'acquisition des données drone et l'image Sentinel utilisable la plus proche pour les deux domaines.....</i> | <i>36</i> |
| <i>Tableau 5 : Variables d'entrées pour résoudre les équations de position solaire</i> | <i>43</i> |
| <i>Tableau 6 : Irradiance et angle d'élévation solaire pour les différents vols de drone.</i> | <i>45</i> |
| <i>Tableau 7 : Matrice de confusion pour la classification de l'ombre avec l'outil SCP de QGIS pour les 4 dates disposant d'image RGB haute résolution.</i> | <i>49</i> |
| <i>Tableau 8 : Corrélation de Pearson, Intervalle de prédiction à 95% (IP) et la pente de la droite de régression pour les paires rang/inter, rang/light, mixte/rang et mixte/inter dans les 5 bandes du drone. La droite de régression est construite, pour chaque paire, en prenant la première variable du titre pour l'axe des x.</i> | <i>52</i> |
| <i>Tableau 9 : Corrélation de Pearson, Intervalle de prédiction à 95% et la pente de la droite de régression pour les paires rang/inter, rang/light, mixte/rang et mixte/inter pour le CLRedEdge, le NDVI et le stepwise. La droite de régression est construite, pour chaque paire, en prenant la première variable du titre pour l'axe des x.</i> | <i>54</i> |
| <i>Tableau 10 : Corrélation et pente entre les bandes du drone rééchantillonné à 10 mètres et Sentinel-2.....</i> | <i>56</i> |
| <i>Tableau 11 : Corrélation et pente entre stepwise, CLRedEdge et NDVI drone rééchantillonné à 10 mètres et Sentinel-2</i> | <i>57</i> |
| <i>Tableau 12 : de droite à gauche : indice, corrélation de Pearson entre l'indice et le modèle stepwise, coefficient de détermination entre l'indice et le modèle stepwise, corrélation de Pearson moyenne pour le modèle stepwise et l'indice pour chaque date, , corrélation de Pearson entre le rang et l'inter-rang pour l'indice. Les indices sélectionnés sont les indices présentant un r^2 supérieur à 0.6.</i> | <i>58</i> |
| <i>Tableau 13 : corrélation de Pearson entre rang/inter et rang/light pour le rouge, vert, bleu, NIR et RedEdge date par date.....</i> | <i>64</i> |
| <i>Tableau 14 : RMSE de la prédiction du potentiel de tige pour chacune des dates de mesures.</i> | <i>67</i> |

1 Introduction

Bien que nécessitant un besoin en eau déficitaire lors de sa maturation, la qualité et le rendement du raisin sont tout de même altérés par un excès de sécheresse. Avec le réchauffement de l'atmosphère et des épisodes de sécheresse plus intenses et récurrents dans certaines régions du sud, les zones de culture du raisin risquent fortement de remonter vers le nord, et la Belgique semble avoir tous les atouts nécessaires pour devenir une région viticole de premier plan. La production de ces 20 dernières années a d'ailleurs été multipliée par 8, passant de près de 100 hectares à plus de 800 actuellement. Les méthodes traditionnelles de suivi du potentiel hydrique sont fortement chronophages et ne permettent pas une extension sur l'entièreté de la parcelle. Les outils de télédétection permettent de collecter des données rapidement et sur l'ensemble des parcelles. En outre, des outils satellites comme Sentinel-2 permettent des mesures gratuites et régulières avec cependant une résolution limitée. Le drone, en revanche, possède une bonne résolution mais il est plus onéreux et chronophage.

L'objectif principal de ce travail est de déterminer le potentiel de tige du vignoble à partir de Sentinel-2 en utilisant le drone comme intermédiaire. Ce dernier est capable de séparer le rang et l'inter-rang alors que le satellite mélange les deux. Pour ce faire, plusieurs sous-objectifs ont été abordés, à savoir l'étude de l'évolution du rang par rapport à l'inter-rang et l'influence de l'ombre.

Pour atteindre ces différents objectifs, une méthodologie spécifique a été développée pour chaque point abordé. La méthode élaborée pour détecter l'ombre repose sur des images RGB, tandis que la modélisation de l'ombre utilise le CHM (canopy height model).

Enfin vous trouverez la méthodologie qui décrit les étapes pour utiliser le drone comme intermédiaire dans la quantification du potentiel de tige de rang de la vigne à partir d'images Sentinel-2.

Les résultats obtenus permettent d'évaluer l'efficacité de Sentinel-2 pour déterminer le potentiel de tige du vignoble et les corrélations qui existent entre le rang et l'inter-rang du vignoble. Une discussion suit, mettant en lumière les principales sources d'erreur et les limitations des différentes méthodologies abordées.

2 Contexte

2.1 La viticulture en Belgique

Au début des années 1990, après plusieurs siècles de disparition, le vin wallon fait son retour dans nos contrées. Trente-trois ans plus tard, en juin 2023, le guide Gault et Millau publie son premier livre sur les vins belges. Et pour cause : l'augmentation drastique de la production (cf. Figure 1), des appellations qui commencent à se faire connaître, une diversité de cépages importante, l'émergence d'une viticulture bio et un changement climatique favorable. En effet, entre 2018 et fin 2022, le nombre de viticulteurs belges est passé de 136 à 259 et la production est passée d'un peu moins de 2 millions de litres à 4 millions aujourd'hui (de Torgny, n.d.). Cette augmentation est encouragée par des subsides fournis par la Région wallonne ainsi que par la création de formations axées autour de la viticulture (SPW, n.d.) ("Snapshot," n.d.).




Figure 1 : évolution de la surface de vigne cultivée et de la production de vin en Belgique de 2006 à 2022 (Source : SPF Economie).

De plus, la viticulture belge a fait le pari de miser sur le bio pour bâtir sa réputation. Ceci est rendu possible grâce à l'utilisation de cépages hybrides offrant une plus grande résistance aux maladies et aux conditions climatiques ("de Torgny" n.d.). On trouve donc chez nous une grande diversité de cépages, bien que notre production soit encore minime par rapport au marché mondial, notamment celui de nos voisins européens tels que la France, l'Italie et l'Espagne. C'est donc dans le développement du bio et des vins de grande qualité que nous devons puiser notre force. Et le pari est réussi pour certains domaines qui ont acquis leurs lettres de noblesse, tels que Rufus, Chant d'Eole et bien d'autres encore.

2.2 Un changement climatique « favorable »

La Belgique, étant située à la limite Nord de la culture de la vigne, rencontre des défis liés à la température et à l'ensoleillement pour la viticulture. Ces deux facteurs sont cruciaux, car la température joue un rôle déterminant dans la chronologie des étapes de croissance de la vigne. Plus il fera chaud, plus les raisins arriveront à maturité tôt et profiteront des dernières chaleurs du mois de septembre. ("LE VIN EN BELGIQUE," n.d.). Avec l'arrivée du changement climatique, des zones climatiques telles que la Belgique possèdent tout le potentiel nécessaire pour devenir les nouvelles régions viticoles de renommée.

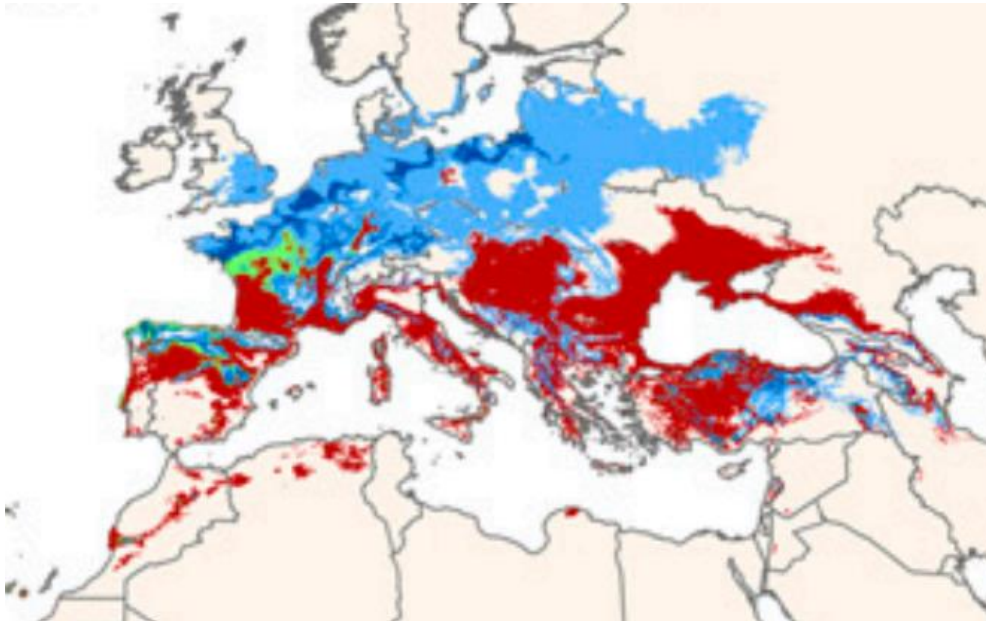


Figure 2 : La variation de l'aptitude viticole est montrée entre la période actuelle (1961-2000) et 2050 (2041-2060), en mettant en évidence l'accord parmi un ensemble de 17 modèles climatiques. Les zones où l'aptitude actuelle diminue d'ici 2050 sont indiquées en rouge (plus de 50% des GCM). Les zones où l'aptitude actuelle est maintenue sont indiquées en vert clair (plus de 50% des GCM) et en vert foncé (plus de 90% des GCM), tandis que les zones non aptes dans la période actuelle mais aptes dans le futur sont représentées en bleu clair (plus de 50% GCM) et en bleu foncé (plus de 90% des GCM). (Hannah et al., 2013)

Sur la figure 2, les zones bleu foncé montrent les régions qui présentent un climat futur favorable pour la culture des vignes d'après 90 % des 17 GCM utilisés. La Belgique se trouve dans l'une de ces zones. On a donc tout intérêt à étudier le système de la vigne dans nos contrées (Hannah et al., 2013).

3 Etat de l'art

3.1 L'importance du stress hydrique pour la viticulture.

La majorité des plantes présentent une corrélation positive entre la disponibilité en eau et le rendement. Pour atteindre un rendement optimal, les plantes doivent disposer d'une quantité d'eau correspondant à leur évapotranspiration potentielle (ETP) dans des conditions idéales (Allan et al., 1998). La vigne ne fait pas exception avec une relation presque linéaire observée entre le volume de raisins récoltés et la consommation d'eau (Freeman and Kliewer, 1983).

Cependant, en viticulture, l'accent est mis sur la qualité des raisins plutôt que sur le rendement maximal. L'eau est un facteur déterminant de la composition des baies de raisin, à condition que la vigne ne souffre pas de carences en autres nutriments (Pinel, 2021). Par exemple, une carence en azote entraîne une diminution de la concentration de chlorophylle et, par conséquent, une réduction de la synthèse de sucre, ainsi qu'une baisse de la synthèse d'arginine, affectant la fermentation (Bisson, 1991). Le stress hydrique limite la taille des baies et stimule la synthèse des composés phénoliques (van Leeuwen and Vivin, 2008). Le rendement diminue en raison de la réduction de la taille et du nombre de baies. La teneur en sucre est également affectée par le stress hydrique, en fonction de la durée et du moment de son apparition (Delrot et al., 2015). Le stress hydrique est également à l'origine de l'augmentation de la teneur en flavanols et anthocyanes (Escudier et al., 2014).

Le statut hydrique d'une plante indique l'équilibre entre l'eau absorbée par les racines et celle perdue par transpiration, essentielle pour la photosynthèse et la croissance optimale (Allan et al., 1998). En revanche, le stress hydrique survient lorsque l'eau disponible est insuffisante, provoquant des réactions physiologiques comme la fermeture des stomates et une réduction de la photosynthèse, impactant négativement la croissance et le rendement (Chaves et al., 2009; Jones, 2004). Pour quantifier le statut hydrique de la vigne, l'indicateur le plus utilisé, et qui est également le plus fiable, est le potentiel foliaire de base (Attia, 2007; Girona et al., 1993; Matthews and Boyer, 1984). Il s'agit du potentiel hydrique foliaire mesuré en fin de nuit lorsque la tension de l'eau au sein de la vigne est en équilibre avec le potentiel hydrique du sol (Romero et al., 2018) car la transpiration est nulle (Van Leeuwen et al., 2009). En se basant sur cette définition, un stress faible est caractérisé par un potentiel foliaire de base compris entre -0,15 et -0,3 MPa, un stress modéré entre -0,3 et -0,5 MPa, et au-delà, le stress sera qualifié d'élevé (Sibille et al., 2007). D'autres études (Choné et al., 2001; Williams and Araujo, 2002) ont montré la pertinence de l'utilisation du potentiel foliaire à midi dans l'évaluation du statut hydrique de la plante dans un vignoble. Toutefois, cette méthode est jugée moins fiable par d'autres études (Attia, 2007; Remorini and Massai, 2003) qui préfèrent utiliser, outre le potentiel foliaire de base, le cumul de transpiration et le potentiel de tige. Pour ce dernier, qui

est l'unité utilisée dans ce travail, on considère que le stress est faible si le potentiel est compris entre -0.6 et -0.9 MPa, modéré s'il est compris entre -0.9 et -1.4 MPa et sévère s'il se situe en-dessous de -1.4 MPa. Finalement, toujours d'après Attia (2007), la température du feuillage semble être moins pertinente pour estimer le statut hydrique de la vigne.




Figure 3 : graphique indiquant la contrainte hydrique souhaitée pour la vigne en fonction du stade phénologique et du type de vin fabriqué. Ψ_t représente le potentiel de tige à midi, Ψ_b représente le potentiel de base et Ψ_h le potentiel hydrique du sol. (Pinel, 2021)

Les besoins hydriques de la vigne varient considérablement selon différents facteurs. Pendant la période de croissance végétative, la plante nécessite une quantité suffisante d'eau pour le développement de ses rameaux. Tandis que pendant la période de maturation (période pendant laquelle le raisin gagne en sucre et perd en acidité), une contrainte en eau plus importante sera souhaitée pour concentrer les composés aromatiques et phénoliques (Pinel, 2021). On cherche également à obtenir une concentration en sucre plus importante (Ramos et al., 2020). Il convient tout de même de noter qu'une vigne trop exposée au stress verra sa concentration en sucre chuter suite à la fermeture de ses stomates, conduisant à un arrêt de la photosynthèse (van Leeuwen and Vivin, 2008). En fonction du type de vin souhaité, les niveaux de stress hydrique recherchés diffèrent également (cf. Figure 3). On recherchera plus de composés aromatiques pour un vin rouge que pour un vin rosé par exemple. Cette complexité rend la gestion de l'eau dans la viticulture à la fois cruciale et délicate (Pinel, 2021). Par ailleurs, en fonction de l'âge des vignes, leur capacité à résister à la sécheresse variera. En effet, les vignes plus matures développeront généralement un système racinaire plus profond, ce qui les rendra plus aptes à supporter des conditions de sécheresse plus sévères (Bou Nader et al., 2019).

Afin de gérer la contrainte hydrique, le viticulteur peut agir en choisissant les cépages et les porte-greffes adaptés. Il peut également opter pour une réduction de la surface foliaire afin de limiter la transpiration. L'entretien du sol joue un rôle crucial dans la gestion de l'eau, tout comme la mise en compétition de la vigne avec d'autres plantes, par exemple, en laissant de l'herbe entre les rangs. Enfin, l'irrigation peut être utilisée comme solution complémentaire (van Leeuwen and Vivin, 2008). La télédétection peut donc s'avérer utile dans la gestion de l'eau du vignoble car elle permet de cartographier rapidement les zones où il convient d'agir. Par exemple, l'étude de Romero et al. (2018) met en avant un modèle construit sur la base d'indices spectraux pour déterminer les zones à irriguer.

3.2 Les paramètres physiologiques du stress hydrique dans la vigne

En réponse à un déficit hydrique dans les vignes, on observe une diminution de la surface foliaire. Celle-ci peut résulter soit d'une diminution de l'expansion foliaire, soit d'une sénescence foliaire accélérée (Lebon et al., 2006). Cette diminution de la surface foliaire permet de diminuer la surface évaporative. La sénescence de la feuille, quant à elle, est le résultat d'une allocation préférentielle des ressources vers les organes reproducteurs (Attia, 2007). Or, la surface foliaire peut être estimée par des moyens de télédétection. En effet, le LAI peut être mesuré à partir d'un LiDAR embarqué sur un drone (Hmida, n.d.). En revanche, pour déterminer la quantité de feuilles mortes, des indices tels que le NDVI vont être favorisés (Bourgeon, 2015). La teneur en eau de la feuille diminue également avec le stress hydrique (Kara and Brinis, 2012). Celle-ci influence la réflectance des bandes comme le SWIR.

Le manque de disponibilité en eau va également entraîner des conséquences sur la photosynthèse et les échanges gazeux au niveau des feuilles (Lawlor, 2002). Et pour cause, une fermeture progressive des stomates qui limite la transpiration, au même titre que la diffusion de CO₂ (Zufferey et al., 2009). Cette diminution de la transpiration, conséquence directe du stress hydrique, peut conduire au stress thermique, qui peut être détecté à l'aide de capteurs infrarouges thermiques embarqués sur UAV. Une diminution de la photosynthèse entraîne également la formation de composés toxiques tels que les radicaux hydroxyles (Apel and Hirt, 2004). La diminution de chlorophylle est également liée, entre autres, au stress hydrique (Kara and Brinis, 2012). Cette dernière, nous le verrons plus tard, influence la réflectance dans le visible.

Il est important de noter que la télédétection propose des solutions qui mesurent les effets du stress hydrique sur la vigne et non des mesures directes de potentiel de tige qu'on peut obtenir avec une chambre de Scholander, par exemple. La télédétection offre tout de même un potentiel important dans la quantification du statut hydrique de la vigne.

3.3 La télédétection en viticulture

La signature spectrale d'un objet est la réflectance obtenue dans chaque longueur d'onde. Ce spectre s'étend du visible (400-700 nm) au proche infrarouge (750-1000 nm) et au SWIR (1000-2500 nm) (Pinel, 2021). Les plages de longueurs d'onde peuvent varier en fonction des sources, avec le NIR s'étendant jusqu'à 1400 nm et le SWIR jusqu'à 4000 nm (Fabien et al., 2001; Kouassi et al., 2020).

3.3.1 Utilisation dans la détermination du stress hydrique

a) Réponse spectrale de la végétation




Figure 4 : représentation du spectre de réflectance de la végétation et des paramètres influençant la réponse spectrale de la végétation dans les différentes longueurs d'onde. (source : Pinel et al., 2021)

La figure 4 montre que les pics d'absorption dans le visible sont, pour le bleu et le rouge, correspondant aux pics d'absorption de la chlorophylle A (430-660 nm) et B (450-650 nm). La transition rapide correspond au Red Edge. Les pics d'absorption dans le SWIR correspondent à l'absorption de l'eau (1450 et 1950 nm) (Dauriac, 2004). La réflectance des végétaux dans le NIR est fortement influencée par la structure interne de la feuille (Ceccato et al., 2001). Cette étude montre que, pour la plupart des espèces, la teneur en chlorophylle est proportionnelle à la teneur en eau. Bien que cela ne s'applique pas à tous les végétaux, c'est le cas pour la vigne (Benyahia et al., 2023). Il y a également un pic d'absorption de l'eau à 970 nm (Rinaldo R. Izzo, 2019).




Figure 5 : Spectroscopie de la vigne pour différents potentiels hydriques (source : Pôças et al. (5a) ; González_Fernández et al (5b))

Enfin, les figures 5a et 5b représentent l'évolution de la signature spectrale de la vigne pour différents potentiels hydriques. On remarque une diminution de l'absorbance dans le visible (chlorophylle qui disparaît). Il est important de noter que les études qui se sont intéressées au spectre de la vigne montrent des résultats mitigés quant à l'évolution de la réflectance dans le RedEdge et le NIR en fonction du potentiel hydrique. Selon les études, soit la réflectance augmente (Pôças et al., 2015) soit elle diminue (González-Fernández et al., 2019). On peut observer à la figure 5b une diminution de la réflectance dans le SWIR, alors que les pics d'absorption sont dus à la présence d'eau dans la feuille. Cependant, la teneur en eau diminue avec le potentiel hydrique (Kara and Brinis, 2012).

b) Utilisation des données multispectrales

Les mesures multispectrales, contrairement aux données hyperspectrales, n'utilisent qu'un nombre défini de bandes. Celles-ci sont également plus larges. La valeur obtenue est la proportion de lumière solaire réfléchi dans cette longueur d'onde. Plus la valeur est élevée, plus la surface réfléchit la lumière dans la longueur d'onde associée à la bande.

L'utilisation de données multispectrales permet également le calcul d'indices de végétation. Certains sont même utilisés dans de nombreuses études bien qu'ils présentent quelques contraintes. On peut citer parmi ceux-ci le NDVI (normalized difference vegetation index). Il est l'indicateur le plus utilisé pour décrire la vigueur de la vigne mais également de la végétation en général. En viticulture, ses utilisations sont multiples. Matese et Di Gennaro (2021) ont utilisés le NDVI pour prédire le rendement ($r=0.8$). On peut aussi l'utiliser pour estimer la biomasse aérienne (Gao, 1996). Indirectement, le NDVI peut également expliquer le potentiel hydrique de la vigne (Pinel, 2021) car il utilise notamment la bande rouge qui est influencée par la teneur en chlorophylle elle-même liée au potentiel. Les résultats obtenus par Acevedo-

Opazo (2019) mettent en évidence une corrélation entre le potentiel hydrique de base et le NDVI. En d'autres termes, un NDVI élevé signifie une plante vigoureuse. Pour être vigoureuse, cette plante a bénéficié de bonne condition hydrique caractérisée par un potentiel élevé. C'est ce qui explique le lien existant entre le NDVI et le potentiel, le NDVI ne détecte pas le potentiel directement mais plutôt l'historique de celui-ci. Notons que cet indice montre particulièrement son efficacité pour identifier des zones plus ou moins homogènes de potentiel hydrique au sein de parcelles caractérisées par des placettes de potentiel hydrique hétérogène (Pinel, 2021). Cependant, les corrélations avec le potentiel restent faibles. Le fort pic d'absorption dans les longueurs d'onde rouge par la chlorophylle rend le NDVI rapidement saturé, surtout pour les canopées ayant un LAI supérieur à 3 (Lillesaeter, 1982). De plus, d'après Caruso and Palai (2023), l'utilisation du NIR et du SWIR apporte des coefficients de corrélation supérieurs à ceux de l'utilisation d'indices spectraux du visible et du NIR. C'est pourquoi le NDWI (NIR-SWIR/NIR+SWIR) est plus souvent utilisé pour quantifier la teneur en eau de la plante (Gao, 1996). Cet indice utilise deux bandes : l'une dans le NIR et l'autre dans le SWIR (cf. Figure 6). En fonction de l'outil utilisé, la définition peut changer. Ainsi avec Sentinel c'est la bande SWIR 1.6 μm qui est utilisée. Une corrélation importante est observée entre le potentiel hydrique de la feuille et le NDWI (Rapaport et al., 2015). Cependant, le NDWI est fortement impacté par les sols nus (Gao, 1996), ce qui ne facilite pas son utilisation dans les vignes qui ne contiennent pas souvent un inter-rang bien enherbé.

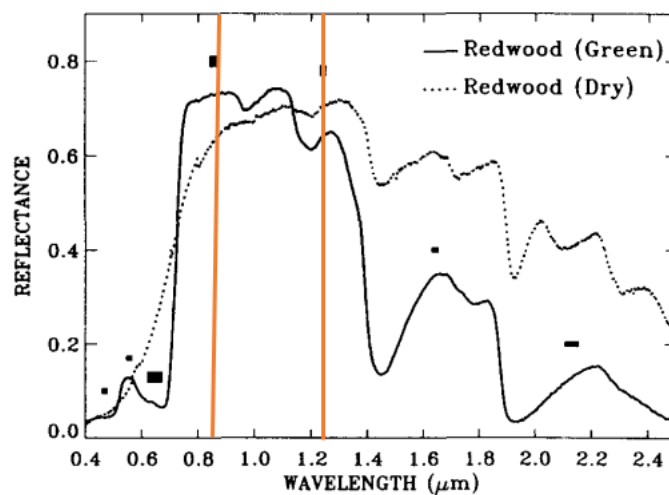


Figure 6 : Représentation de l'indice NDWI pour une feuille sèche et verte. On comprend qu'un indice élevé correspond à une feuille avec une forte teneur en eau et inversement.

Enfin, il existe une multitude d'autres indices spectraux qui tentent de déterminer le potentiel hydrique des végétaux et des vignes en particulier. Il est utile de noter que, dans beaucoup de cas, ce sont les effets de l'eau sur la plante et sur sa structure que nous observons à travers ces indices. On peut citer ici certains indices couramment utilisés tels que le VARI (visible atmospherically resistant index), le GI (green Index), le WI (water index) et bien d'autres encore (Pôças et al., 2015). La limitation majeure de l'utilisation d'indices spectraux ou de bandes spectrales dans la quantification du potentiel réside dans le fait que ces derniers évaluent les conséquences d'un stress hydrique sur les végétaux (Carter and Knapp, 2001) comme la diminution de chlorophylle, la teneur en eau ou encore l'anthocyanine pour le vert (Gitelson et al., 1996). La comparaison du potentiel avec un seul indice ne donne généralement pas un coefficient de détermination très élevé, allant de 0,03 à 0,42 pour des indices classiques tels que NDVI, NDRE, CLRedEdge, GI, OSAVi, etc... (Rapaport et al., 2015; Romero et al., 2018). Alors que l'utilisation de plusieurs indices simultanément, par exemple, à travers un réseau de neurones artificiels (ANN), conduit à des résultats plus satisfaisants (Romero et al., 2018). La même observation est présente dans Claessens (2023), qui obtient de meilleurs résultats en effectuant une régression linéaire pas à pas (SLR).

Enfin, il convient de noter que la variable à laquelle les indices sont comparés est importante. Par exemple, de bien meilleures corrélations sont obtenues par (Baluja et al., 2012) en comparant les indices à la conductance stomatique plutôt qu'au potentiel de tige. La conductance stomatique étant également un indicateur de stress hydrique (Besnard, 1990).

3.3.2 Les différents outils de télédétection

Il existe trois grands types de plateformes pour la télédétection multispectrale : les drones, les avions et les satellites. Les drones présentent l'avantage d'avoir une résolution spatiale très fine, tandis que les satellites offrent une redondance intéressante, avec des prises de vue tous les 4 à 5 jours pour Sentinel-2, par exemple. L'utilisation d'un avion perd de sa pertinence lorsque l'on s'intéresse à une ou deux parcelles, car le coût de base dépasse celui d'un drone et la résolution est généralement moins bonne. Le choix du satellite s'est porté sur Sentinel-2 en raison de sa résolution spatiale supérieure (10-20 m) par rapport à son homologue américain Landsat (30 m en général, 15 m pour le panchromatique) ou MODIS (250 m - 1000 m). D'autres satellites proposent des images à résolution plus élevée, comme RapidEye qui sort des pixels de 5 mètres, mais elles sont payantes (Matese et al., 2015).

a) L'utilisation de Sentinel en viticulture

En raison de sa résolution variant entre 10 et 20 mètres, l'utilisation de Sentinel-2 en viticulture fusionne les informations provenant de la vigne et de l'inter-rang, ce qui introduit diverses imprécisions dans le suivi hydrique. Par exemple, lorsque la fraction de sol recouverte par la végétation est faible, le stress hydrique de la vigne est souvent surestimé (Pinel et al., 2021). Cependant, Sentinel-2 permet un suivi temporel du statut hydrique, mettant en évidence les variabilités intra-parcellaires. Cette section présente les principales conclusions des études sur le lien entre différents indices calculés à partir de Sentinel-2 et le potentiel hydrique.

Dans une partie de la thèse de Pinel et al. (2021), un coefficient de détermination moyen (R^2) de 0,3 est obtenu entre le potentiel hydrique et les indices suivants : NDVI, NDRE1, NDRE2, IRECI, NDMI, REP et MSI. La meilleure corrélation est observée lorsque toutes les bandes Sentinel sont utilisées simultanément dans un modèle linéaire, comme on peut le voir à la figure 7, cette corrélation diminuant à mesure que des bandes sont retirées.




Figure 7 : Meilleures bandes à utiliser pour faire le modèle de régression d'après l'étude de (Laroche Pinel et al. 2021).

L'étude note des performances accrues du modèle en l'absence d'herbe dans l'inter-rang. Toutefois, dans la région méditerranéenne où se situent les parcelles étudiées, l'herbe peut être mal développée et hétérogène. Un autre point notable est que la robustesse des prédictions n'est pas significativement affectée par les variations interannuelles de températures et de précipitations. La limite de cette étude réside dans le développement de l'herbe dans l'inter-rang et une validation du modèle dans des régions où l'inter-rang est plus développé, comme la Bourgogne ou la Belgique, serait intéressante. De plus, l'étude n'a pas éliminé les pixels de bordure, ce qui, selon Sozzi et al. (2020), devrait être fait pour éviter le bruit dans les mesures.

Caruso and Palai (2023) ont trouvé des R² proches de 0,65 pour le MSI et le NDWI en Toscane, tandis que la corrélation avec le NDVI chute à 0,07. Cependant, cette étude ne porte que sur une seule parcelle, alors que celle de Pinel et al. (2021) mentionnée précédemment rassemble des données de plusieurs parcelles.

L'étude de Cogato et al (2019) trouve les meilleures corrélations entre les épisodes de stress hydrique et les bandes vertes ainsi que RedEdge 5, en plus des indices TCARI et CARI.

Aucune de ces études n'a tenté de construire un modèle combinant une multitude d'indices pour estimer le potentiel hydrique de la vigne, à l'exception de Pinel et al. (2021) qui a utilisé les bandes Sentinel-2. De plus, la comparaison avec le potentiel hydrique foliaire a été limitée

à un nombre restreint d'indices, au maximum une dizaine selon les articles. Une étude plus approfondie de la recherche d'indices et de la combinaison de ceux-ci s'avère être une piste intéressante.

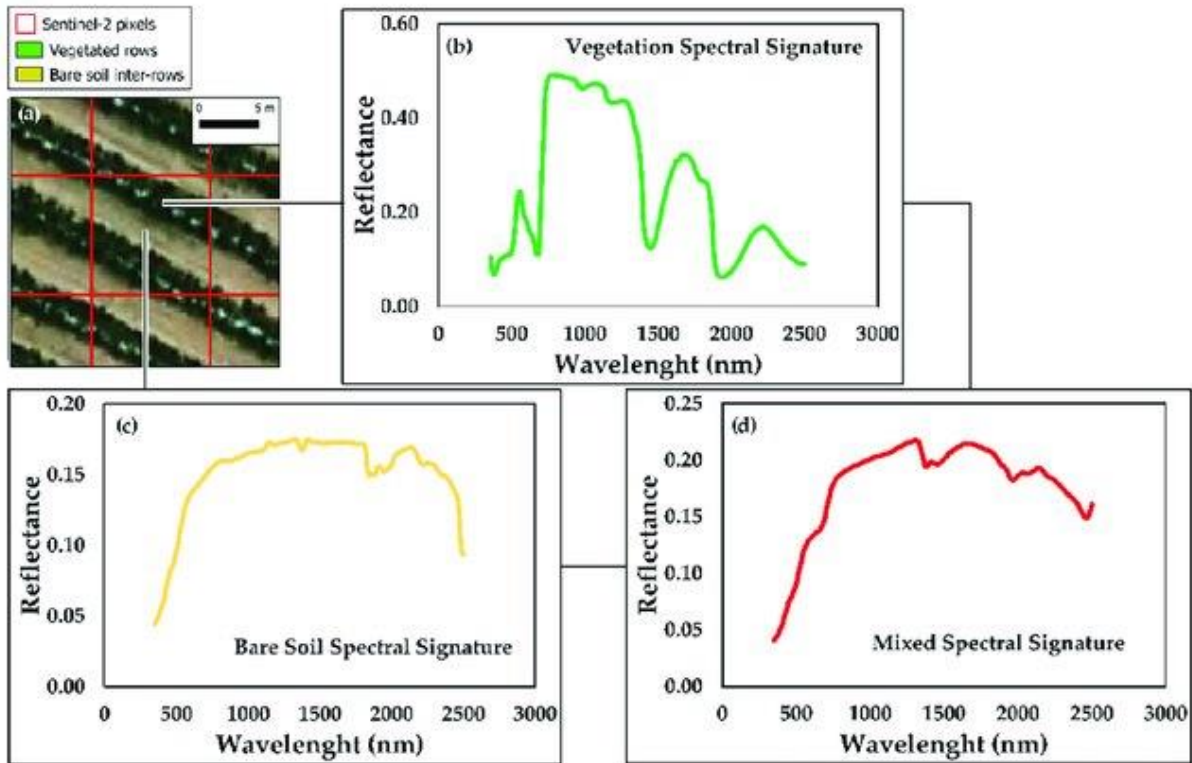


Figure 8 : (a) Vue aérienne d'un verger de grenadier (*Punica granatum L.*) et les pixels S2. (b) signature spectrale de la végétation pure. (c) signature spectrale de sol pur. (d) signature spectrale mixte. (Source : (Borgogno Mondino et al., 2022))

Un autre problème lié à l'utilisation de Sentinel-2 dans les cultures pérennes comme la vigne est que les données recueillies intègrent des informations provenant à la fois du sol et de la vigne. La figure 8 illustre ce phénomène. Ainsi, l'impact d'un changement de potentiel hydrique est moins perceptible que si toute la surface était couverte de végétation (Borgogno-Mondino et al., 2018). La signature spectrale pure du rang est obtenue par un mélange linéaire des proportions connues, en prenant une référence pour le sol. Si l'inter-rang est enherbé, la signature mixte devrait plus ou moins ressembler à celle du rang seul. Toutefois, il est nécessaire de comprendre comment le rang et l'inter-rang évoluent en fonction du déficit hydrique pour déterminer leur influence sur la signature mixte. À ce jour, peu de recherches ont exploré la relation entre le rang et l'inter-rang dans les vignobles.

Enfin, bien que de nombreuses études établissent un lien entre les images satellites et le statut hydrique de la vigne, toutes ne s'intéressent pas à la corrélation avec le potentiel hydrique de base ou le potentiel de tige. Certaines études se concentrent, par exemple, sur le lien entre la réflectance spectrale, la thermographie et l'évapotranspiration, la corrélation entre la transpiration et le potentiel hydrique étant ensuite établie (Bellvert et al., 2020).

b) L'utilisation du drone en viticulture

L'utilisation des drones en viticulture de précision a été largement explorée dans divers domaines, tels que l'évaluation de la répartition spatiale de la vigueur de la vigne et de la maturité phénolique à l'aide d'indices de végétation, d'imagerie multispectrale et hyperspectrale (Matese et al., 2015; Zarco-Tejada et al., 2005). D'autres études, comme celle de Baluja et al. (2012), ont montré l'efficacité de l'imagerie thermique pour évaluer le stress hydrique, particulièrement dans les vignobles mélangeant différents cépages. Un tableau récapitulatif des principaux indices spectraux utilisés pour quantifier le stress hydrique est disponible en annexe F.

L'utilisation du drone permet également de visualiser la répartition de l'ombre créée par les vignes sur l'inter-rang. Cette ombre dépend de la position du soleil (fonction de l'heure et de la date), de la densité de la canopée et de son état physiologique, notamment la teneur en chlorophylle. L'étude de Vélez et al. (2021) met en évidence la relation entre le LAI et l'ombre. Pour classifier la vigne et ses zones ombragées, Poblete-Echeverría et al. (2017) utilisent diverses méthodes, y compris le K-means basé sur les longueurs d'onde RGB et deux indices (2G_RBI et G%), atteignant une précision globale de 64 %.

La séparation du rang et de l'inter-rang permet également de calculer la proportion de vigne pure sur une surface donnée. L'étude de Berry et al. (2024) montre une corrélation entre le potentiel hydrique de la vigne et la fraction de sol occupée par celle-ci. Evidemment, bien que le modèle soit pertinent dans le temps, cette corrélation ne peut s'appliquer qu'à la parcelle étudiée car l'espacement entre les rangs joue un rôle important dans la fraction de canopée.

Parmi les études portant sur la quantification du potentiel hydrique à l'aide de drones, Vega et al. (2015) ont obtenu des coefficients de détermination de 0,57 et 0,44 entre le MSWP (potentiel hydrique de la tige à midi) et les indices PRI et NDSI, ce dernier étant généralement utilisé pour détecter la neige. Serrano and Gorchs (2022) ont mis en évidence une corrélation entre le LWP (potentiel hydrique foliaire) et les indices NDVI et WI. Une étude intéressante est celle de (Romero et al., 2018), qui utilise un grand nombre de mesures de potentiel à midi au sol (une centaine sur 10 ha) et combine divers indices dans un réseau de neurones artificiels (ANN). Cependant, cette étude présente des limites, car le modèle est basé sur une seule date et une seule parcelle, ce qui peut entraîner un problème d'overfitting. De plus, le réseau de neurones n'a testé qu'une dizaine d'indices, alors qu'il aurait pu en inclure davantage pour améliorer la précision. Dans le même genre, l'étude de (Loggenberg et al., 2018) a montré que

l'imagerie spectrale couplée à des algorithmes d'apprentissage automatique comme Random Forest et XGBoost peut discriminer efficacement les vignes stressées des vignes non-stressées avec des taux de précision de 83,3% et 80% respectivement. Seulement, l'algorithme devait classer la vigne en deux catégories : stressée ($-1.8 \text{ MPa} > \text{SWP} > -1 \text{ MPa}$) et non-stressée ($\text{SWP} < -0.7 \text{ MPa}$). On remarque ici que l'algorithme peut manquer de précision dans la quantification de SWP mais quand même donner la bonne classification.

Au vu de sa résolution trop grossière, l'utilisation de Sentinel ne peut pas séparer le rang de l'inter-rang. Ce qui fait qu'il mélange ces derniers dans son information. Cependant, il peut tout de même déterminer si les vignes possèdent ou non des inter-rangs enherbés (Palazzi et al., 2023a). Cependant, la précision de cette méthode n'est pas très fiable. On se tournera donc vers l'utilisation du drone, qui a déjà fait ses preuves pour séparer le rang de l'inter-rang. La segmentation manuelle (par exemple, par un système d'information géographique - SIG) des images RGB est laborieuse, chronophage et doit être améliorée pour prendre en compte les imprécisions de la canopée, de l'effet d'ombre et des différentes conditions du sol dans les inter-rangs (Sassu et al., 2021). Plusieurs méthodes ont donc vu le jour pour séparer le rang de l'inter-rang à partir d'images spectrales d'un drone. Le papier de Sozzi et al. (2020) a par exemple utilisé une classification supervisée grâce au logiciel QGIS. Il a ainsi obtenu un coefficient kappa de 0,84. L'étude menée par Matese et al. (2015) a quant à elle utilisé une méthode de classification non supervisée en séparant la vigne en 3 classes : la canopée, l'inter-rang et l'ombre. L'étude de Pádua et al. (2018) montre une méthode pour estimer automatiquement la canopée en utilisant des indices de végétation et un modèle numérique d'élévation (DEM) calculés à partir des images haute résolution du drone. L'algorithme Watershed (r.watershed sur QGIS), qui est généralement utilisé pour déterminer les bassins versants, a également fait ses preuves pour séparer le rang de l'inter-rang (Baluja et al., 2012).

3.4 Comparaison entre drone et Sentinel-2

Peu d'études se sont intéressées à la comparaison entre les données de drones et les données satellites (Sentinel). La plupart de ces études ont été réalisées pour des parcelles viticoles de régions méditerranéennes caractérisées par un temps plus sec, des espacements inter-rangs plus importants que chez nous et l'absence d'herbe (ou herbe sèche) dans les inter-rangs. De plus, les comparaisons se font le plus souvent sur la vigueur. L'indice qui revient donc pratiquement tout le temps est le NDVI. Dans la plupart de ces études, la tendance générale est qu'on observe une bonne corrélation entre les pixels de drone mixte (rang et inter-rang) et les pixels de Sentinel. Ensuite, même si cela varie d'une étude à l'autre, la tendance s'accorde également à dire que la corrélation entre les images Sentinel et du drone pur (uniquement le rang) est faible, plus faible même dans certains cas que la corrélation avec l'inter-rang. Enfin, cette dernière observation varie, entre autres, avec l'espacement des rangs entre eux.

D'après l'étude menée par Khaliq et al. (2019), l'utilisation seule d'indices Sentinel décimétriques montre certaines limitations dans l'estimation de la vigueur de la vigne. Et pour cause, une influence importante de l'inter-rang dans la réponse spectrale de Sentinel caractérisée par un fort coefficient de corrélation de Pearson entre ceux-ci ; et, de manière opposée, par un faible coefficient de corrélation avec la canopée de la vigne. Matese et al. (2017), quant à eux, ont remarqué, de manière surprenante, que les observations entre Sentinel-2 et rang pur sont souvent opposées. Ainsi, une zone de faible NDVI pour le premier correspondrait à une zone de fort NDVI pour le second. Les deux études s'accordent également à dire que l'utilisation de Sentinel pour déterminer la vigueur de la vigne basée sur le NDVI n'est pas satisfaisante. Matese et al, (2017) proposent une explication en mettant en avant l'importance de la géométrie de la vigne. En effet, il n'est pas possible de savoir si la valeur du NDVI est due à une plante en bonne santé mais étroite plutôt qu'à une plante plus large mais en mauvaise santé. La quantification de la proportion de rang pourrait peut-être solutionner cette incertitude.

Contrairement aux études citées ci-dessus, l'étude de Sozzi et al. (2020), menée sur 30 parcelles différentes dans le Languedoc-Roussillon, montre de bonnes corrélations entre les images Sentinel et les images de rangs purs (il convient également de noter que l'espacement entre les rangs est plus restreint que dans les autres études). Cependant, elle met tout de même en avant le fait que les pixels Sentinel ont tendance à lisser l'information contenue dans le rang uniquement (cf. Figure 9).

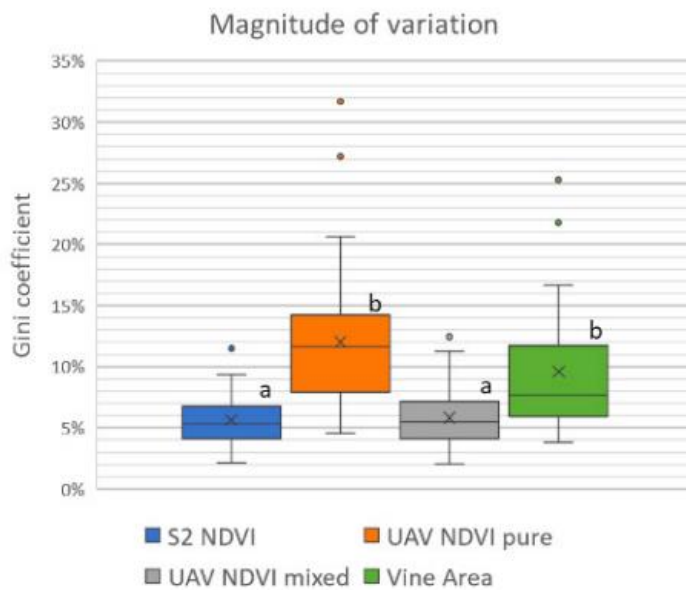


Figure 9 : Plage de variation, exprimée à l'aide du coefficient de Gini sous forme de boîtes à moustaches, dans les quatre couches à travers 30 parcelles de vignes. (Source : (Sozzi et al., 2020))

Sur la figure 9, on remarque que l'étendue des variations est plus importante pour le NDVI pur que pour le S2 NDVI. Cette étude met également en avant la corrélation existante entre la surface de vigne occupée dans un pixel Sentinel et la valeur du NDVI. La même observation est faite en Italie par Matese et al. (2015) où ils mettent en évidence les histogrammes des réflectances du drone et du satellite. On y voit une distribution beaucoup plus large pour les images drone que pour celles du satellite.

Tableau 1 : recensement des résultats des comparaisons entre S2/landsat8 et UAV pour la vigneur.

| Source | Indice | Corrélation (r) Rang/S2 | Corrélation Inter/S2 | Corrélation Mixte/S2 | Rang enherbé | Capteur |
|---------------------------------|--------|----------------------------|----------------------|----------------------|--------------|--------------------------|
| (Cogato et al., 2019) | NDVI | 0.74 | / | / | Oui | S2/WorldView-2 |
| (Sozzi et al., 2020) | NDVI | 0.84 | / | 0.86 | Non | S2/MicaSense RedEdge-MX |
| (Stolarski et al., 2022) | NDVI | 0.65 | 0.61 | 0.71 | Oui | S2/Parrot SEQUOIA |
| (Khaliq et al., 2019) | NDVI | 0.41 | 0.6 | 0.68 | Non | S2/Parrot SEQUOIA |
| (Matese et al., 2015) | NDVI | / | / | 0.55 | Non | S2/Tetracam ADC Lite |
| (Govi et al., 2024) | NDVI | 0.62 | / | 0.73 | Non | S2/ MicaSense RedEdge-MX |
| (Borgogno-Mondino et al., 2018) | NDVI | 0.8 | / | 0.5 | Non | Landsat8/RedLake MS4100 |

Enfin, notons que toutes les études qui ont comparé Sentinel-2 et drone n'ont jamais essayé d'utiliser le drone pour améliorer les données de Sentinel qui présentent comme limitations majeures de mélanger l'information du rang et de l'inter-rang. De plus, aucune comparaison entre les deux n'a été réalisée dans une région où la végétation dans l'inter-rang est aussi verte qu'en Belgique. Les autres études se faisant dans les régions méditerranéennes.

4 Objectifs

À cause de sa résolution spatiale trop grossière, Sentinel-2 mélange de l'information venant du rang et de l'inter-rang, ce qui conduit à diverses imprécisions dans son utilisation pour quantifier le statut hydrique. L'utilisation du drone, en revanche, permet de séparer le rang de l'inter-rang. L'objectif de ce travail est donc d'utiliser les informations provenant du drone pour améliorer la qualité de la prédiction du potentiel de tige avec les données Sentinel-2. Deux autres objectifs ont également été poursuivis, à savoir :

- 1) Comment la réflectance du rang évolue-t-elle par rapport à celle de l'inter-rang, et quels sont les facteurs qui influencent cette évolution ?
- 2) Comment séparer l'ombre de l'inter-rang et quel est son impact sur l'évolution de la réflectance du rang et de l'inter-rang ?

5 Matériel et méthode

5.1 Zone d'étude

Les zones d'étude sont deux parcelles appartenant à deux domaines viticoles wallons : le Domaine W et le Domaine du Château de Bousval (Brabant Wallon, Belgique). Tous deux présentent des inter-rangs enherbés. La moyenne des températures et des précipitations sont reprises dans le tableau 2.

Tableau 2 : Températures et précipitations moyennes de la station de Uccle pour les mois de prise de mesure (source : IRM)

| | Température (°C) | Précipitation (mm) |
|-----------------------|------------------|--------------------|
| Juillet 2022 | 19.6 | 5.2 |
| Aout 2022 | 21.4 | 17.8 |
| Juillet 2023 | 18.4 | 131 |
| Aout 2023 | 18.1 | 108 |
| Septembre 2023 | 18.8 | 64 |

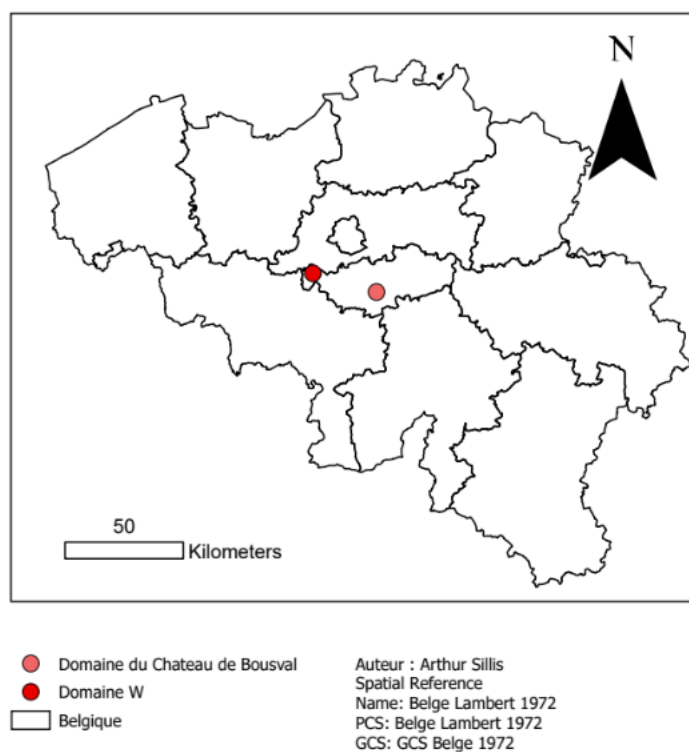


Figure 10 : Localisation des parcelles d'étude.

5.1.1 Domaine du Château de Bousval

Le vignoble du Château de Bousval (cf. Figure 11), situé à Bousval, est un domaine viticole fondé en 2014 qui a progressivement étendu sa superficie pour atteindre 8,2 hectares en 2020. Initialement, la parcelle de 2,3 hectares était consacrée à la culture intensive de maïs avant d'être convertie en vignoble. Le vignoble comprend 57 740 pieds de vignes répartis en Chardonnay (5,5 hectares), Pinot Noir (2,3 hectares) et Pinot Gris (0,45 hectare). Les vignes sont espacées selon des inter-rangs de 1,60 mètre et des pieds de vignes espacés de 0,80 mètre dans une orientation Est-Ouest. Le porte-greffe utilisé sur l'ensemble de la parcelle est le 3309C. Depuis 2017, le vignoble produit des vins blancs tranquilles et a obtenu les certifications biologique et biodynamique en 2021.

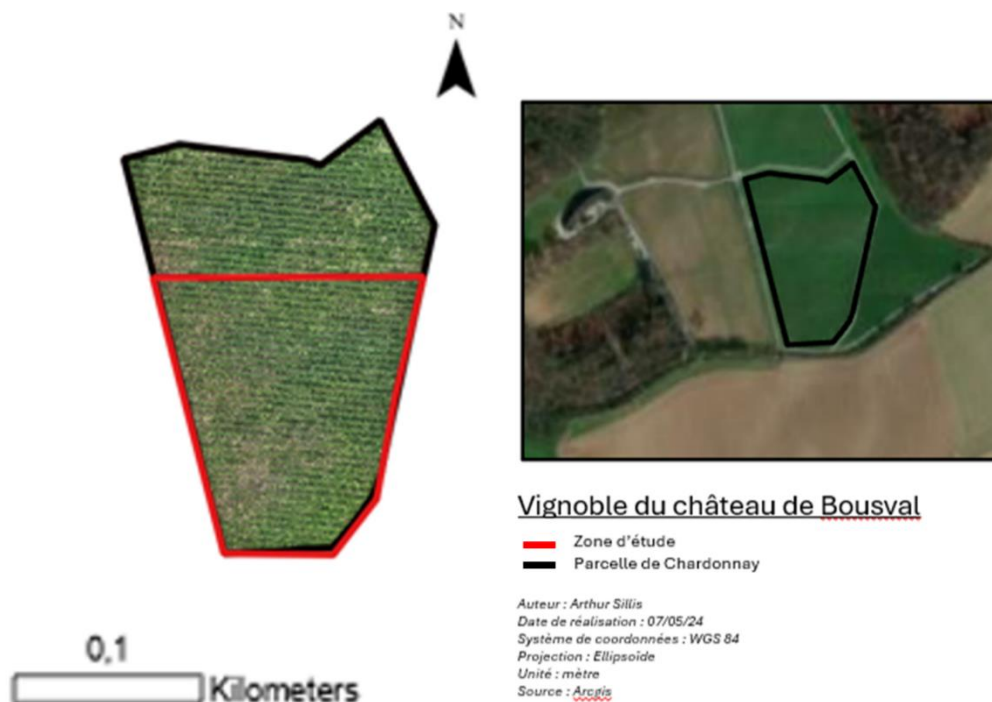


Figure 11 : Parcelle d'étude du « Vignoble du Château de Bousval »

La parcelle étudiée est constituée uniquement du cépage Chardonnay. L'élévation de la zone d'étude oscille entre 107 et 123,5 mètres au-dessus du niveau de la mer. Elle se trouve sur une pente orientée d'ouest en est, présentant une inclinaison moyenne de 6,4 degrés, variant de 1,4 à 13,6 degrés. Dans la zone d'étude, les altitudes s'échelonnent de 111 à 123 mètres au-dessus du niveau de la mer. La figure 12 représente la topographie de la parcelle.

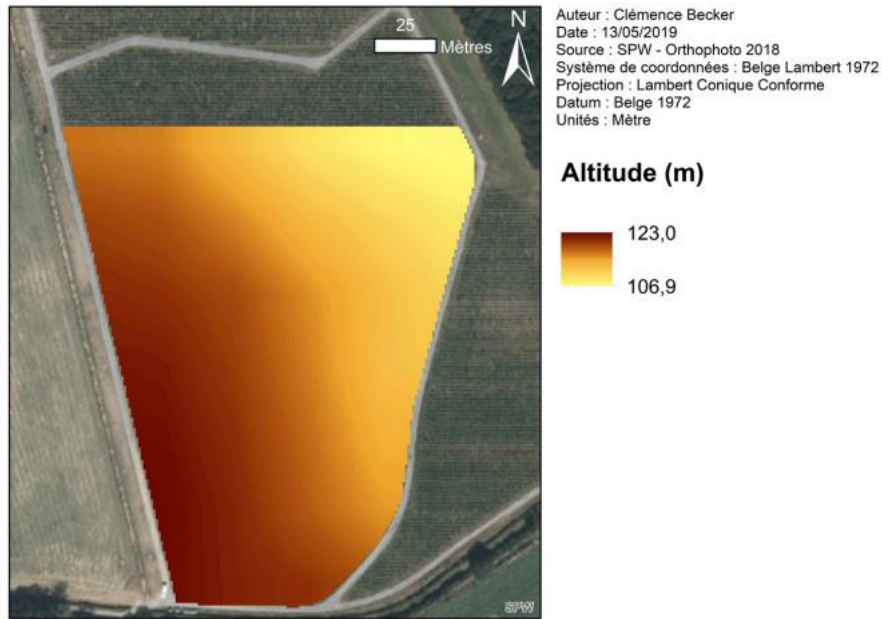


Figure 12 : Courbe de niveau du Vignoble du château de Bousval (auteur : Clémence Becker)

Il s'agit globalement de sols limoneux (30-50% de limon) avec une teneur en sable non négligeable, de 30 à 50%, et une teneur en argile assez faible, avoisinant les 20% (Becker, 2019). L'épaisseur de limon représentée à la figure 13, reposant sur la couche de sable bruxellien, varie de 40 cm dans le haut de la parcelle à plus de 100 cm dans le bas, mettant ainsi en évidence l'influence de la topographie sur la répartition du limon. La parcelle se trouve dans la tuile Sentinel 32 UFS.




Figure 13 : interpolation de la profondeur d'apparition du sable bruxellien dans la parcelle du Château de Bousval (Auteur : (Claessens,2024).

5.1.2 Domaine W

Fondé en 2016, le Domaine W (DW) (cf. figure 14) est un domaine viticole implanté à Saintes, dans la commune de Tubize, située dans la partie occidentale de la province du Brabant wallon en Belgique. Le DW s'étend sur 8 hectares et abrite 35 000 pieds de vignes. On y produit des vins pétillants selon la méthode champenoise.




Figure 14 : Parcelle d'étude du « Domaine W »

Les rangées de vignes s'étendent du nord-ouest au sud-est, espacées par des inter-rangs recouverts d'herbe d'une largeur de 2,25 mètres. Entre chaque pied de vigne, la distance est de 1 mètre. Avant la plantation du vignoble, les parcelles étaient utilisées pour la rotation des cultures, comprenant la culture de blé, de maïs, de pommes de terre et de betteraves à sucre, ou étaient maintenues comme pâturages permanents.

Sur l'ensemble de la parcelle, la pente moyenne est d'environ 2,24°. La zone de la sous-parcelle supérieure présente des valeurs de pente allant de 0° à 3,64°, avec une pente moyenne de 1,6°. En revanche, la zone de la sous-parcelle inférieure a des valeurs de pente allant de 0,16° à 6,9°, avec une pente moyenne de 2,5°.

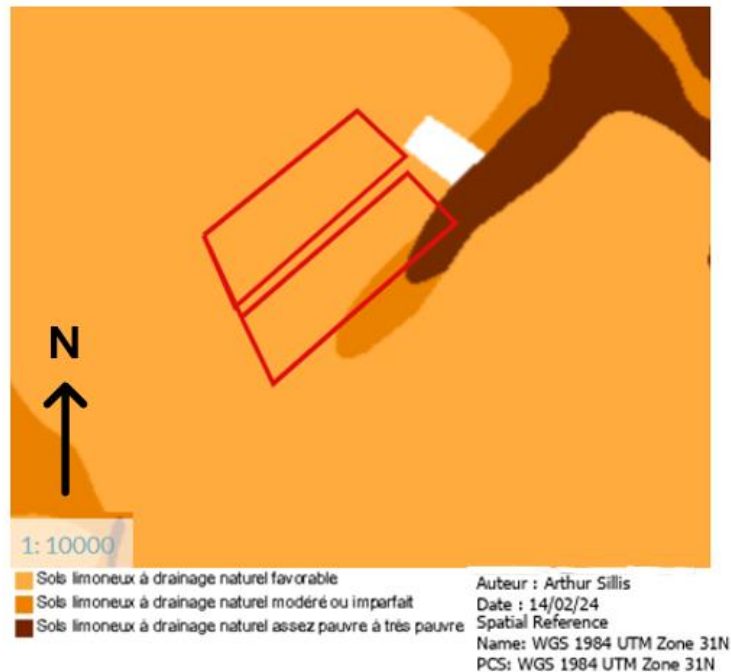


Figure 15 : Type de sol du « Domaine W »

Le sol est principalement de type limoneux à drainage naturel favorable (CNSW) (cf. Figure 15). Cependant, le coin inférieur droit de la parcelle est caractérisé par une plus haute teneur en matière organique que le reste de la parcelle car une prairie y était présente avant l'implantation des vignes. Cette information peut être utile pour tirer des conclusions dans la suite du mémoire. La parcelle se trouve dans la tuile Sentinel 31UES.

5.2 Les outils de télédétection

5.2.1 Drone

Le kit complet pour effectuer les mesures par drone se compose du drone lui-même et des appareils de mesure. Le modèle de drone utilisé est le DJI Matrice 600 de la marque DJI (Da-Jiang Innovations). Il s'agit d'un hexacoptère de dimensions 640 x 582 x 623 mm. Le drone volait à une altitude fixe de 100 m pour l'année 2022 et de 50 m pour l'année 2023. L'altitude de vol est cruciale pour la résolution des images, passant de 7 cm à 3,5 cm. Cependant, le

temps de vol devient plus long. Trois capteurs différents ont été utilisés : un pour le LiDAR, un pour le multispectral et un dernier pour la thermographie.

Les données multispectrales ont été acquises par le capteur RedEdge-M, qui mesure dans cinq bandes spectrales comme indiqué dans le tableau 3. Les cinq objectifs (un pour chaque bande) ont une distance focale de 5,4 mm et un angle de vue de 46°.

Tableau 3 : Longueur d'onde centrale des différentes bandes du capteur MicaSense RedEdge-M Sensor et Sentinel.

| Bandes | Drone (nm) | Sentinel-2 (nm) |
|-----------------|-------------------|------------------------|
| Blue | 465-485 | 490 |
| Green | 550-570 | 560 |
| Red | 663-673 | 665 |
| Red-Edge | 712-722 | 705 |
| NIR | 820-860 | 842 |
| SWIR1 | / | 1 610 |
| SWIR2 | / | 2 190 |

Les données du LiDAR proviennent d'un ensemble d'appareils composé d'un dispositif LiDAR Velodyne, d'un ordinateur embarqué, d'une unité de mesure inertielle (IMU) et d'un récepteur du système de navigation par satellite (GNSS). La solution GNSS-Inertial est fournie par l'Applanix APX-15. Les données de télémétrie sont obtenues à partir du dispositif LiDAR, tandis que les variations d'altitude sont mesurées par l'IMU. Le positionnement est assuré par le GNSS, qui garantit également la synchronisation temporelle pour tous les capteurs. Ce système multi-capteurs offre une précision qui permet le géoréférencement direct. La densité de points de la surface scannée dépend de l'altitude de vol, de la vitesse et de l'espacement/superposition des lignes de vol du drone. Mais reste tout de même de l'ordre de quelques centimètres.

5.2.2 Sentinel-2

Sentinel-2 est le nom utilisé pour décrire une série de satellites de surveillance de la Terre faisant partie du programme Copernicus. Chaque satellite circule sur une orbite héliosynchrone. Cela signifie que l'angle entre le plan de l'orbite et la direction du soleil reste à peu près constant.

Le capteur embarqué sur le satellite collecte les données en captant la réflectance TOA (top of atmosphere) dans 13 longueurs d'onde allant du bleu (0,492 μm) au SWIR (1,3-2,2 μm) (cf. Tableau 3). La résolution au sol (soil sampling distance) peut être de 10, 20 ou 60 mètres. Il convient de noter que la résolution de 60 mètres est principalement utilisée pour la correction

atmosphérique. La largeur de la bande prise à chaque passage est de 290 kilomètres. Les détails précis sur les bandes sont présentés en annexe E et les bandes utilisées dans ce travail sont reprises dans le tableau 3.

Avant d’être téléchargées, les images Sentinel ont d’abord été sélectionnées sur “EO Browser” (“EO Browser,” n.d.) afin de sélectionner les images dont les dates de passages sont les plus proches du vol de drone et qui sont exemptes de nuages. Nous avons ensuite téléchargé les bandes utiles de Sentinel via Google Earth Engine. Les images ont ensuite été soumises à une correction atmosphérique et à une correction BDRF (bidirectional reflectance function) à l’aide de l’algorithme sen2cor de l’ESA (agence spatiale européenne).

5.3 Acquisition des données

La campagne d’acquisition des données par drone se divise en deux périodes : durant l’été 2022 et durant l’été 2023. Les dates ont été spécifiquement réparties pour correspondre au début, au milieu et à la fin du stade de maturation du raisin. Nous étions dépendants de la météo pour les dates précises, mais l’idéal était de faire correspondre les vols de drone avec le passage de Sentinel. Les dates précises des vols de drone sont reprises dans le tableau 4, et les dates des images Sentinel utilisables les plus proches y sont également inscrites (NB : les heures de passage de Sentinel sont approximativement à 10h50).

Tableau 4 : Dates d’acquisition des données drone et l’image Sentinel utilisable la plus proche pour les deux domaines.

| 2022 Bousval | | | |
|-----------------------|---------|---------------------|-------------------|
| Drone | Heure | Différence de jours | Sentinel |
| 27-07-2022 | 15 : 10 | +2 | 29-07-2022 |
| 10-08-2022 | 11 : 03 | 0 | 10-08-2022 |
| 31-08-2022 | 10 : 57 | -3 | 28-08-2022 |
| 2023 Bousval | | | |
| Drone | Heure | Différence de jours | Sentinel |
| 20-07-2023 | 15 : 00 | +1 | 21-07-2022 |
| 10-08-2023 | 14 : 00 | -2 | 08-10-2023 |
| 06-09-2023 | 14 : 00 | +1 | 07-09-2023 |
| 2022 Domaine W | | | |
| Drone | Heure | Différence de jours | Sentinel |
| 31-08-2022 | 12 : 30 | +2 | 02-09-2022 |
| 2023 Domaine W | | | |
| Drone | Heure | Différence de jours | Sentinel |
| 20-07-2023 | 12 :00 | / | / |
| 10-08-2023 | / | / | / |
| 06-09-2023 | 12 :00 | +1 | 07-09-2023 |

Les données multispectrales ont été combinées pour former des orthomosaïques individuelles correspondant à chaque bande spectrale du capteur, en utilisant des techniques de photogrammétrie et de traitement d'images assisté par ordinateur dans le logiciel Pix4D. Lors de la période d'acquisition de 2022, aucun GCP (ground control point) n'a été mis en place. Les orthomosaïques ont donc été géoréférencées à la main en utilisant des GCP virtuels. Il en découle un léger décalage de quelques pixels entre les différentes dates. Lors de la période 2023, pour pallier le problème de décalage, des GCP ont été positionnés aux quatre coins des parcelles.

5.4 Les outils statistiques

5.4.1 La corrélation de Pearson

En statistique, le coefficient de corrélation mesure le degré de dépendance linéaire entre deux variables. Au plus il est proche de 1 ou -1, au plus les deux variables seront liées. S'il est égal à l'unité, cela signifie qu'une variable est une fonction de l'autre variable. Il se calcule comme cela :

$$r = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$

où le numérateur est la covariance entre les deux variables tandis que le dénominateur est l'écart-type de chacune des variables. C'est en fait la covariance normalisée.

5.4.2 Le coefficient de détermination

Le coefficient de détermination est une mesure de la qualité d'une prédiction linéaire. Il est compris entre 0 et 1. Dans le cas de régression linéaire, ce coefficient est égal au carré de la corrélation de Pearson.

5.4.3 L'intervalle de prédiction

Un intervalle de prédiction représente une fourchette de valeurs qui pourrait contenir une observation individuelle future, en se basant sur les valeurs des prédicteurs considérées dans le modèle. Ainsi, par exemple, un intervalle de prédiction à 95% de 1 signifie que 95% des valeurs réelles devraient se trouver dans une plage de +/- 1 par rapport aux valeurs prédites.

5.4.4 La stepwise linear regression

La régression linéaire pas à pas, également connue sous le nom de stepwise linear regression en anglais, est une méthode statistique utilisée pour identifier les variables significatives à inclure dans un modèle de régression. Contrairement à une régression linéaire multiple où toutes les variables sont incluses simultanément, la régression pas à pas évalue chaque variable indépendamment, en les ajoutant ou en les retirant du modèle une par une en fonction de leur contribution à l'ajustement global du modèle.

Le processus de stepwise regression se déroule généralement en deux étapes principales : forward selection (sélection ascendante) et backward elimination (élimination descendante). Dans la sélection ascendante, les variables sont ajoutées au modèle une par une, en commençant par celle qui apporte la plus grande amélioration de l'ajustement du modèle. Ensuite, dans l'élimination descendante, les variables sont retirées du modèle une par une, en commençant par celle dont la suppression entraîne la plus faible diminution de l'ajustement global du modèle (“10.2 - Stepwise Regression | STAT 501,” n.d.).

5.5 Méthodologie générale

Dans cette partie, vous trouverez les différentes étapes pour séparer le rang de l'inter-rang ainsi que la méthode pour séparer les zones d'ombres. Ensuite, la méthode utilisée pour comparer les données de drone avec les données Sentinel-2 sera présentée. Et pour finir, vous trouverez la méthode pour déterminer le potentiel de tige à partir d'images Sentinel-2.

5.5.1 Relation entre le rang et l'inter-rang

Cette section aborde l'étude et la recherche de la relation entre le rang et l'inter-rang, éléments constitutifs de la deuxième partie du système d'équation. Pour ce faire, le rang, l'inter-rang et l'ombre ont fait l'objet d'une séparation afin d'être comparés. Enfin, les variables externes influençant la variabilité du rang et de l'inter-rang seront exposées. La comparaison entre la réflectance du rang et de l'inter-rang c'est faites pour chaque bande et pour les 3 indices suivants : le modèle setpwise (section 5.6), le CLRededge et le NDVI. Le modèle setpwise a été choisi car il prédit le mieux le potentiel de tige. Le CLRedEdge prédit également le potentiel de tige et se présente sous la forme d'un ratio. Enfin, le NDVI est l'indice qui se trouve dans la plupart des études lues, surtout pour la comparaison entre drone et Sentinel-2. Le choix de ces deux derniers indices est aussi de voir l'effet d'un indice normalisé et d'un indice sous forme de rapport dans la comparaison du rang et de l'inter-rang.

a) Séparation du rang de l'inter-rang :

Cette méthode repose sur l'utilisation de l'algorithme K-means. Il s'agit d'un algorithme de clustering qui partitionne un ensemble de données en K groupes (clusters) en minimisant la variance au sein de chaque cluster et en assignant chaque point de données au centre du cluster le plus proche (Ahmed et al., 2020).

Dans un premier temps, les bandes spectrales les plus pertinentes pour distinguer les rangs de vigne de la végétation présente dans l'inter-rang ont été identifiées. Les observations sur le terrain réalisées durant l'été sec de 2022 ont montré que, dans plusieurs zones, la végétation de l'inter-rang se dégradait. Un indice de densité de végétation a donc été utilisé pour différencier l'herbe des vignes. Selon Baret et al. (1989), la biomasse et la densité de végétation sont souvent estimées à l'aide des bandes rouge et NIR, en raison de leurs

propriétés de réflectance distinctes.

Pour créer le masque des vignes, nous avons opté pour le Modified Soil Adjusted Vegetation Index (MSAVI), recommandé par Qi et al. (1994). Cet indice a été choisi pour son utilisation exclusive des bandes rouge et NIR, sa sensibilité à la densité de végétation, et sa capacité à réduire les effets de la luminosité du sol dans les cultures clairsemées (Huete 1988 ; Binte Mostafiz et al.2021).

Une fois le raster MSAVI généré, la délimitation des rangs de vigne a été réalisée manuellement dans QGIS en utilisant des polygones rectangulaires et en veillant à minimiser l'inclusion des zones inter-rangs.

Dans un premier temps, une première séparation a été effectuée sur base du CHM (canopy height model). Tous les pixels inférieurs à 1 mètre ont été supprimés afin de négliger une bonne partie de l'inter-rang. Le CHM représente la hauteur des objets situés au-dessus du sol, obtenu en soustrayant le modèle numérique de terrain (DTM) du modèle numérique de surface (DSM).

Chaque rang a ensuite été subdivisé en rectangles de 10 mètres de long pour réduire l'hétérogénéité de la densité de l'herbe. Étant donné les variations de l'état de santé de l'herbe à travers les parcelles, l'application directe de l'algorithme k-means à toute la parcelle entraînait une confusion significative entre les pixels de vigne et d'herbe. En restreignant la zone d'application de l'algorithme, la végétation non-vigne dans cette zone présentait une plus grande similitude, améliorant ainsi la discrimination entre les pixels de vigne et d'herbe. La longueur de 10 mètres représente un compromis entre la qualité de la segmentation et le temps de calcul nécessaire.

L'algorithme k-means a été appliqué à chaque rectangle, avec quatre clusters pour distinguer les pixels de vigne, de végétation autre, de sol et d'ombre. Seule la classe avec la valeur médiane de MSAVI la plus élevée a été retenue, représentant logiquement la classe de vigne en raison de sa densité de biomasse élevée.

Les résultats de l'algorithme appliqué à chaque rectangle subdivisé ont été combinés pour créer un fichier shapefile unifié. Ce fichier représente un masque binaire isolant les pixels de la canopée de vigne sur l'ensemble de la parcelle, pouvant être utilisé pour filtrer les informations non liées à la vigne des images raster d'indices de végétations.

b) Détection des zones d'ombre

Pour établir de bonnes corrélations entre le rang et l'inter-rang, nous avons envisagé une comparaison en utilisant uniquement les zones ensoleillées. Cela a nécessité la séparation des zones d'ombre. La littérature indique que des travaux similaires ont été réalisés sur les vignes en utilisant des algorithmes k-means (Poblete-Echeverría et al., 2017). Cependant, après avoir testé cette méthode, nous avons constaté qu'elle ne convenait pas à notre contexte spécifique. Deux autres méthodes ont été envisagées :

- 1) une classification supervisée (Sozzi et al., 2020)
- 2) une modélisation des zones d'ombre sur la base du CHM et de la position du soleil.

Pour effectuer la classification, l'algorithme Random Forest a été appliqué via QGIS. Cette classification a été réalisée sur des images RGB haute résolution obtenues avec une caméra Zenmuse. Il ne s'agit pas de valeurs de réflectance, chaque pixel RGB contient une valeur comprise entre 0 et 255.

Avant de lancer l'algorithme, un jeu de données d'entraînement a été créé. Des échantillons ont été sélectionnés pour deux classes distinctes : l'ombre et la lumière (cf. Figure 16). La lumière pouvait être présente aussi bien sur la vigne que dans les zones d'inter-rangs. Vingt-cinq échantillons pour chaque classe, répartis sur la parcelle, ont été sélectionnés pour l'entraînement.




Figure 16 : exemple de sélection des échantillons pour les deux classes : en bleu l'ombre et en vert la lumière.

L'algorithme Random Forest a ensuite été exécuté, produisant un raster classé en deux catégories : ombre et lumière (cf. Figure 17b). La validation de cette méthodologie a été

réalisée sur ce raster à l'aide d'une matrice de confusion, construite avec l'outil Accuracy Assessment of Thematic Map (ACATAMA) de QGIS.




Figure 17 : a) image Zenmuse RGB haute résolution, b) résultat de la classification : l'ombre en noir et la lumière en blanc, c) suppression des pixels « rang » et vectorisation. Les lignes noires représentent le quadrillage qui divisait le raster pour la vectorisation.

Étant donné que le raster était trop volumineux pour être vectorisé directement dans QGIS, cette opération a été effectuée via Python. Dans un premier temps, pour garantir l'exclusion des pixels de vigne classifiés comme ombre, tous les pixels de vigne ont été supprimés. Il en a été de même pour les pixels classifiés comme lumière.

Pour la vectorisation, le raster a été divisé en plusieurs sections à l'aide d'une grille, et la vectorisation a été effectuée pour chaque cellule de la grille afin de faciliter le traitement. Tous les fichiers shapefile résultants ont ensuite été combinés pour obtenir un masque unique.

Pour les dates d'acquisition des données où nous ne possédons pas d'image RGB haute résolution, l'ombre a été classifiée en utilisant le CHM et la position théorique du soleil. La procédure suivante comprend une explication rapide du calcul des angles solaires et une explication du processus pour passer du modèle d'élévation et de la position solaire à un masque (shp) d'ombre dans l'inter-rang.

Deux angles sont nécessaires pour décrire la position du soleil : l'angle d'élévation et l'angle d'azimut. Le premier est l'angle par rapport à la surface tandis que le deuxième est l'angle par rapport au Nord. Ces deux angles sont définis par les équations suivantes :

$$\alpha = \sin^{-1}[\sin \delta \times \sin \rho + \cos \delta \times \cos \rho \times \cos(HRA)] \quad 5.1$$

$$\theta = \sin^{-1}\left[\frac{\sin \delta \times \cos \rho - \cos \delta \times \sin \rho \times \cos(HRA)}{\cos \alpha}\right] \quad 5.2$$

où δ représente l'angle de déclinaison, φ la latitude et HRA (hour angle) contient les paramètres relatifs à l'heure solaire et la longitude. Les équations utilisées dans le calcul de ces deux angles et le script Python sont disponibles dans l'annexe M. Le tableau 5 reprend les données d'entrées utilisées dans les équations.

Tableau 5 : Variables d'entrées pour résoudre les équations de position solaire

| Variable | Valeur |
|-----------------------|----------|
| Jour | Variable |
| Local time | Variable |
| Latitude | 50.6 |
| Longitude | 4.55 |
| Inclinaison terrestre | 23.45 |

Pour modéliser l'ombre dans les vignes, les angles solaires et le modèle de hauteur de la canopée (CHM) ont été utilisés. La procédure pour convertir le CHM en un masque shapefile d'ombre à l'aide d'un code Python (annexe J) est illustrée par la figure 18.

- 1) Création de points de canopée : Un point a été créé au centre de chaque pixel du CHM ayant une hauteur supérieure à 80 centimètres, sélectionnant ainsi presque uniquement les pixels correspondant aux vignes.
- 2) Génération de points d'ombre : Pour chaque point de canopée, un point d'ombre correspondant a été généré. La distance et l'orientation par rapport au point de canopée ont été déterminées à l'aide des angles solaires. La distance est calculée en multipliant la hauteur de la canopée par la tangente de l'angle d'élévation, tandis que l'orientation est donnée par l'angle d'azimut +/- 180°. Ces valeurs ont été transformées en coordonnées, avec la composante x égale à la distance multipliée par le cosinus de l'azimut, et la composante y égale à la distance multipliée par le sinus de l'azimut.
- 3) Traçage de lignes d'ombre : Une ligne, appelée "ligne d'ombre", a été tracée entre chaque point de canopée et son point d'ombre correspondant.

- 4) Création d'une grille shapefile : Une grille shapefile dont les cellules correspondent aux pixels du raster CHM a été créée.
- 5) Sélection des cellules de la grille : Toutes les cellules de la grille interceptées par une ligne d'ombre et ayant une hauteur inférieure à 80 centimètres ont été sélectionnées pour former le masque d'ombre.

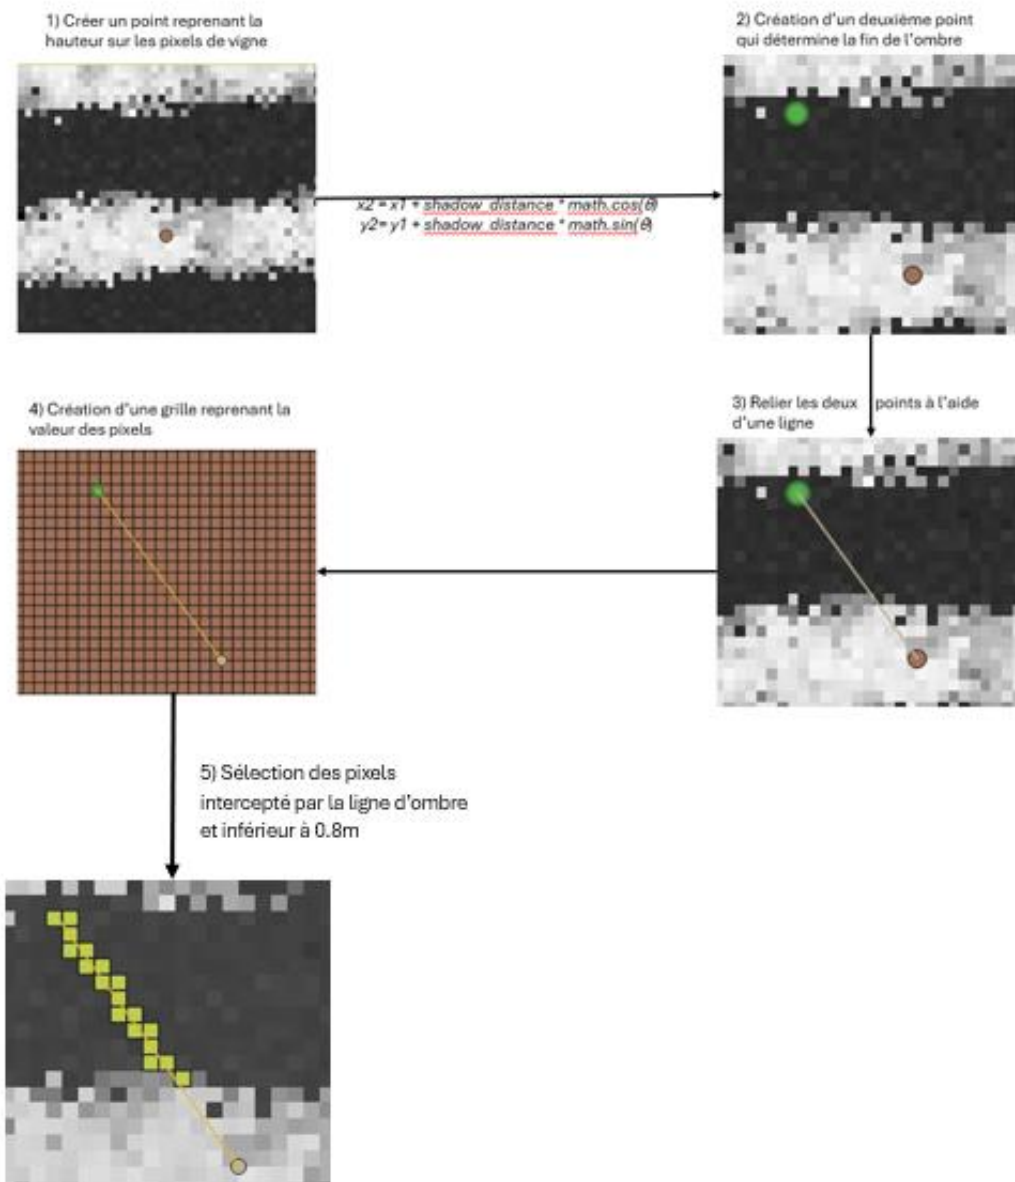


Figure 18 : méthode pour passer du CHM à un masque des surfaces d'ombre.

c) Les variables pour qualifier la variabilité du rang et de l'inter-rang au sein de la parcelle et entre dates

- 1) L'irradiance : Calculée sur la base de l'angle d'élévation et en faisant l'approximation que la parcelle est plane sur toute sa surface, l'irradiance s'obtient grâce à la formule ("Ensoleillement," n.d.):

$$Irradiance = 1000 \times \cos \theta \quad (5.3)$$

où 1 000 est la valeur de l'irradiance sur une surface perpendiculaire [W / m^2] au rayonnement et θ est l'angle complémentaire de l'angle d'élévation alpha.

Tableau 6 : irradiance et angle d'élévation solaire pour les différents vols de drone.

| 2022 Bousval | | | |
|---------------------|---------|-------------------|------------|
| Drone | Heure | Angle d'élévation | Irradiance |
| 27-07-2022 | 15 : 10 | 46.65 | 727.2 |
| 10-08-2022 | 11 : 03 | 50.57 | 772.4 |
| 31-08-2022 | 10 : 57 | 44.27 | 698.06 |
| 2023 Bousval | | | |
| Drone | Heure | Angle d'élévation | Irradiance |
| 20-07-2023 | 15 :00 | 48.59 | 750 |
| 10-08-2023 | 14 :00 | 50.8 | 775 |
| 06-09-2023 | 14 :00 | 41.4 | 661.7 |
| Domaine W | | | |
| Drone | Heure | Angle d'élévation | Irradiance |
| 31-08-2022 | 12 :30 | 47.5 | 741.7 |
| 06-09-2023 | 12 :00 | 45.3 | 710.2 |

- 2) La composante verticale de la parcelle : la parcelle étant en pente, on s'attend à voir une différence dans la distribution de l'eau entre le haut et le bas de la pente.
- 3) La teneur en eau : La teneur en eau volumique θ est le volume d'eau sur le volume total (eau + air + sol). Celle-ci est mesurée grâce à l'appareil TRIME FM-3 (*TRIME-FM3, GmbH, Ettlingen, Germany*). Il s'agit d'un équivalent d'une sonde TDR (time domain reflectometry) (International Atomic Energy Agency, 2008; Laurent et al., 2006).
- 4) La profondeur de sable : Disponible à la figure 13 (Becker et trigaux,2019).

5.6 Comparaison entre drone et Sentinel

Pour comparer les données du drone et celles de Sentinel-2, une adaptation des images était nécessaire en raison des différences de résolution spatiale (3 à 6 centimètres pour le drone et 10 à 20 mètres pour Sentinel-2). La comparaison était basée sur la localisation, c'est-à-dire que chaque pixel du drone devait correspondre à un pixel de Sentinel-2 situé au même endroit.

Dans un premier temps, en utilisant des logiciels de SIG tels que QGIS ou ArcGIS, les rasters de Sentinel-2 ont été convertis en polygones vectoriels. Seuls les polygones entièrement contenus dans la région d'intérêt (ROI) ont été conservés. Cette étape vise à éviter les effets de bordure qui peuvent introduire des erreurs dans l'analyse




Figure 19 : illustration des pixels se trouvant à l'intérieur de la ROI (à droite) et des pixels sélectionnés (à gauche).

Sur la figure 19, l'illustration de droite donnera un jeu de données plus petit mais de bien meilleure qualité que la figure de gauche. En effet, les polygones qui sont coupés sont en partie à l'extérieur de la vigne et la signature spectrale associée peut donc contenir une partie de chemin ou d'herbe. De plus, d'après Sozzi et al. (2020), les bordures peuvent être supprimées sans que cela n'impacte trop la corrélation entre les images UAV et Sentinel si la parcelle est supérieure à 0,5 hectare. D'ailleurs, la même étude montre également qu'éliminer la bordure apporte une meilleure corrélation, du moins pour le NDVI, entre le drone et Sentinel.

Ensuite, les pixels du drone ont été rééchantillonnés à la taille du pixel Sentinel en faisant la moyenne (Cogato et al., 2019; Matese et al., 2017; Sozzi et al., 2020) (cf. figure20).




Figure 20: exemple de rééchantillonnage d'un raster "drone"

5.7 Recherche d'indices Sentinel corrélés au potentiel vigne

L'approche proposée pour évaluer le potentiel sur la base des données Sentinel-2 est de tester une multitude d'indices directement avec la valeur de potentiel de tige. Ce dernier a été prédit sur toute la parcelle à partir d'une stepwise regression calculée grâce à des mesures de potentiel de tige récoltées en même temps que les vols de drone avec une chambre de Scholander. La combinaison multilinéaire d'indices spectraux a été calibrée et validée pour chaque date. Le pouvoir prédictif du modèle est de 63 %. La stepwise regression permet donc de déterminer dans une certaine mesure le statut hydrique de la vigne. Notons donc pour la suite que le potentiel de tige auquel on comparera les indices de Sentinel-2 contient déjà une certaine marge d'incertitude. Le potentiel de tige calculé avec le drone est donné par l'équation suivante :

$$\text{Stepwise} = -1.5604 + 0.8011 \times \text{CLRedEdge} + 7.9859 \times \text{green} - 1.336 \times \text{savi} + 0.009172 \times \text{ari} \quad (5.4)$$

La procédure représentée par la figure 21 est la suivante :

- a) Le potentiel de tige du rang uniquement est obtenu à partir du modèle multilinéaire (équ. 5.4) et est ensuite rééchantillonné à la résolution de Sentinel-2 en utilisant la moyenne afin de pouvoir être comparé avec ce dernier.
- b) Le potentiel a été comparé à une multitude d'indices disponibles à l'annexe I.
- c) Les indices ont fait l'objet d'une stepwise linear regression avec le potentiel (lui-même calculé avec une stepwise regression). La validation du modèle s'est effectuée sur des dates disposant de mesures de potentiel prises au sol avec la chambre de Scholander et de mesures Sentinel-2 proches de ces mêmes dates.

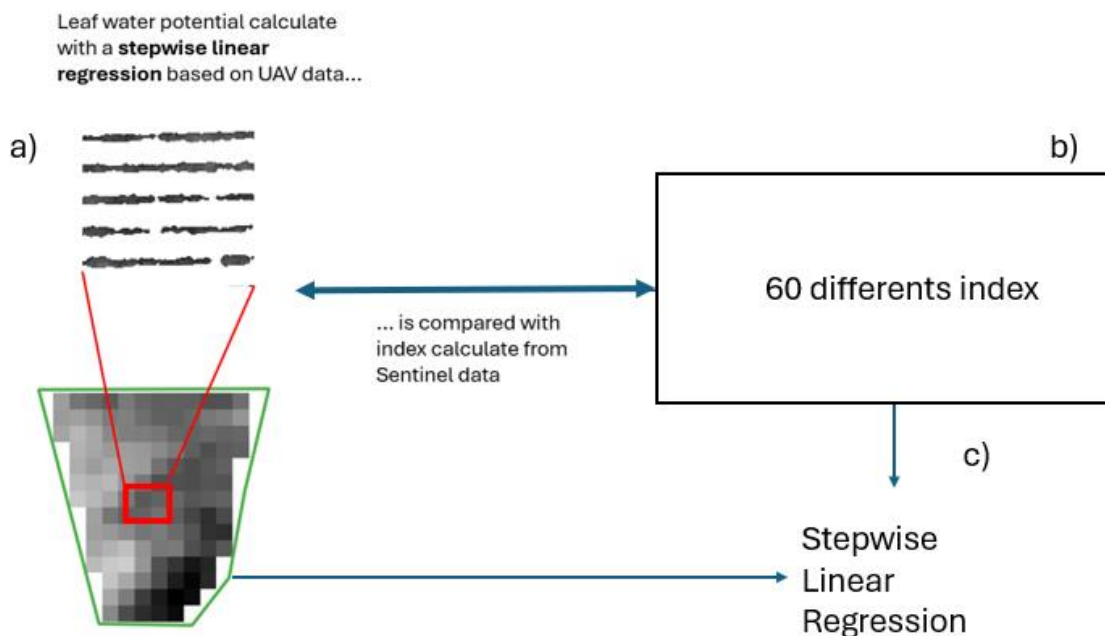


Figure 21 : Diagramme représentant la méthodologie utilisée pour étudier la corrélation entre le potentiel de tige et différents indices.

6 Résultats

6.1 Séparation de l'ombre

6.1.1 Classification supervisée

Tableau 7 : Matrice de confusion pour la classification de l'ombre avec l'outil SCP de qgis pour les 4 dates disposant d'image RGB haute résolution.

| 27/07/2022 | | | |
|-------------------------|--------------|----------------|----------------------------|
| | Ombre réelle | Lumière réelle | Précision de l'utilisateur |
| Ombre classifiée | 37 | 1 | 0.98 |
| Lumière classifiée | 0 | 12 | 1 |
| Précision du producteur | 1 | 0.92 | Précision globale : 0.98 |

| 20/07/2023 | | | |
|-------------------------|--------------|----------------|----------------------------|
| | Ombre réelle | Lumière réelle | Précision de l'utilisateur |
| Ombre classifiée | 30 | 2 | 0.94 |
| Lumière classifiée | 0 | 18 | 1 |
| Précision du producteur | 1 | 0.78 | Précision globale : 0.96 |

| 10/08/2023 | | | |
|-------------------------|--------------|----------------|----------------------------|
| | Ombre réelle | Lumière réelle | Précision de l'utilisateur |
| Ombre classifiée | 30 | 3 | 0.9 |
| Lumière classifiée | 0 | 17 | 1 |
| Précision du producteur | 1 | 0.85 | Précision globale : 0.94 |

| 06/09/2023 | | | |
|-------------------------|--------------|----------------|----------------------------|
| | Ombre réelle | Lumière réelle | Précision de l'utilisateur |
| Ombre classifiée | 36 | 3 | 0.92 |
| Lumière classifiée | 0 | 11 | 1 |
| Précision du producteur | 1 | 0.78 | Précision globale : 0.94 |

Le tableau 7 présente les matrices de confusion évaluant la performance de la classification des zones d'ombre. Les dates du 10 août 2022 et du 31 août 2022 ne sont pas incluses ici en raison de l'absence d'images RGB haute résolution Zenmuse, ce qui rend l'évaluation de la classification impossible pour ces dates. Une approche alternative sera discutée plus loin dans ce rapport.

La précision globale, définie comme la probabilité qu'une classe soit correctement identifiée (Alberg et al., 2004), varie entre 0.94 et 0.98 pour les différentes classifications. Cela indique qu'en moyenne, environ 95 % des pixels sont correctement attribués à leur catégorie respective. On observe également que l'algorithme classe très rarement un pixel comme étant éclairé lorsqu'il s'agit en réalité d'une zone d'ombre. Cependant, il arrive que des pixels soient classés comme ombre alors qu'ils sont en réalité éclairés.

Les données montrent une légère disproportion entre les instances réelles d'ombre (environ 35) et de lumière (environ 15). Cette disproportion pourrait influencer les métriques globales et nécessiter des techniques d'ajustement si l'équilibre des classes est important pour les analyses futures (Sokolova and Lapalme, 2009). Toutefois, cela ne constitue pas une contrainte majeure pour la classification actuelle.

On peut également voir que la précision du producteur est en moyenne légèrement inférieure à la précision de l'utilisateur. Cela signifie que la plupart des pixels prédits pour une classe spécifique sont corrects, mais que le modèle omet de nombreux pixels appartenant réellement à cette classe (Knudby, 2021).

Enfin, il convient de noter que les matrices de confusion sont fabriquées à vue d'œil et, donc il, n'est pas toujours évident de distinguer la frontière entre les parties ombragées et les parties éclairées. Il y a une zone de pénombre où la détermination de la classe pour la construction de la matrice est déterminée par le créateur de manière arbitraire.

6.1.2 Modélisation de l'ombre à partir du « canopy height model »

Pour les dates du 10 août 2022 et du 31 août 2022, l'ombre a été modélisée en utilisant la méthode décrite dans la section intitulée "Modélisation des zones d'ombre". Comme mentionné précédemment, il est impossible de construire une matrice de confusion pour évaluer la précision de ce modèle en raison de l'absence de données de référence, à savoir des images haute résolution RGB. De plus, pour l'année 2022, les vols de drone effectués aux alentours de 11h00 pour ces deux dates contrastent avec les vols réalisés aux alentours de 15h00 pour les dates disposant d'images RGB. Par conséquent, les directions des zones d'ombre diffèrent et ne permettent pas une comparaison directe. L'évaluation du modèle se fera donc par inspection visuelle.

La première limitation du modèle repose sur le fait que la méthode détermine les lignes d'ombre uniquement sur la base de la hauteur de la canopée, sans tenir compte de sa structure interne, notamment les trous dans celle-ci (cf. Figure 22). Par conséquent, les taches de lumière traversant la canopée, détectables par la classification supervisée, restent invisibles pour cette approche.



Figure 22 : Illustration de la limite de la modélisation de l'ombre dans la détection des trous dans la canopée.

Une deuxième limitation provient du fait que tout pixel au sol intercepté par les lignes d'ombre est classifié comme ombre, même si l'ombre s'arrête juste au début du pixel. Étant donné que les pixels du CHM ont une dimension d'environ 8 cm de côté, on peut s'attendre à une surestimation de la zone d'ombre, estimée à environ un demi-pixel par ligne d'ombre. Sur l'ensemble de la parcelle, certaines lignes d'ombre s'arrêteront au début d'un pixel, d'autres au milieu et d'autres à la fin. En postulant que cela suit une distribution uniforme, on peut estimer qu'en moyenne, la moitié d'un pixel de chaque ligne d'ombre est en réalité de la lumière. Cette hypothèse est émise en l'absence d'éléments spécifiques dans la littérature qui traitent directement de cette problématique.

Enfin, étant donné que le vol du drone n'est pas instantané, le mouvement du soleil entraîne une variation des zones d'ombre. Cette variation est prise en compte dans la classification supervisée mais pas dans cette méthode-ci. Cependant, en utilisant l'heure moyenne du vol, cette erreur peut être considérée comme négligeable.

6.2 Étude des relations entre le « drone rang », « drone inter-rang » et « drone mixte ».

Cette partie traitera des comparaisons faites entre la réflectance obtenue dans le rang et dans l'inter-rang pour les différentes bandes du capteur du drone ainsi que pour certains indices.

6.2.1 Bande par bande

Tableau 8 : Corrélation de Pearson, intervalle de prédiction à 95% (IP) et pente de la droite de régression pour les paires rang/inter, rang/light, mixte/rang et mixte/inter dans les 5 bandes du drone. La droite de régression est construite, pour chaque paire, en prenant la première variable du titre pour l'axe des x.

| Bande | | Rang/inter | Rang/Light | Mixte/rang | Mixte/inter |
|---------|-------------|------------|------------|------------|-------------|
| Rouge | Corrélation | 0.7 | 0.73 | 0.74 | 0.99 |
| | IP | 0.032 | 0.028 | 0.015 | 0.004 |
| | Pente | 1.4 | 1.37 | 0.39 | 1.06 |
| Bleue | Corrélation | 0.5 | 0.54 | 0.61 | 0.98 |
| | IP | 0.015 | 0.014 | 0.01 | 0.003 |
| | Pente | 0.73 | 0.66 | 0.46 | 1.08 |
| Verte | Corrélation | 0.17 | 0.21 | 0.43 | 0.95 |
| | IP | 0.036 | 0.025 | 0.04 | 0.01 |
| | Pente | 0.15 | 0.079 | 0.58 | 1.13 |
| NIR | Corrélation | -0.07 | 0.037 | 0.33 | 0.9 |
| | IP | 0.17 | 0.14 | 0.2 | 0.07 |
| | Pente | -0.05 | 0.025 | 0.54 | 1.12 |
| RedEdge | Corrélation | -0.21 | -0.3 | 0.23 | 0.93 |
| | IP | 0.12 | 0.1 | 0.09 | 0.04 |
| | Pente | -0.01 | -0.04 | 0.37 | 1.16 |

En lisant le tableau 8, on remarque plusieurs tendances. En règle générale, la corrélation entre le rang et l'inter-rang non ombragé est meilleure que celle calculée entre le rang et l'inter-rang total (ombre et lumière). Cela peut s'expliquer par le fait que l'intensité de l'ombre peut varier entre les différentes dates mais aussi au sein de la parcelle, avec de l'ombre fort prononcée dans le bas et de l'ombre moins prononcée dans le haut de la parcelle. Pour cause, une densité de canopée plus faible dans le haut que dans le bas de la parcelle. En regardant les intervalles de prédictions, on remarque que ceux-ci sont plus faible pour rang/light que pour rang/inter. Les points sont donc plus groupés lorsqu'on ne prend pas l'ombre en compte. La pente entre le rang et l'inter-rang est faible en général, le rang étant sur l'axe des x, on en déduit que la variabilité dans le rang est en général plus prononcée que dans l'inter-rang (cf. Figure 23a) excepté pour le rouge. Notons tout de même qu'il s'agit de la pente de la droite de régression qui mélange toutes les dates, elle met donc la variabilité temporelle en évidence. Si on regarde le graphique de la réflectance du rouge pour rang/inter (cf. Figure 23b), on constate que certaines dates présentent une plus grande variabilité dans le rang plutôt que dans l'inter-rang.

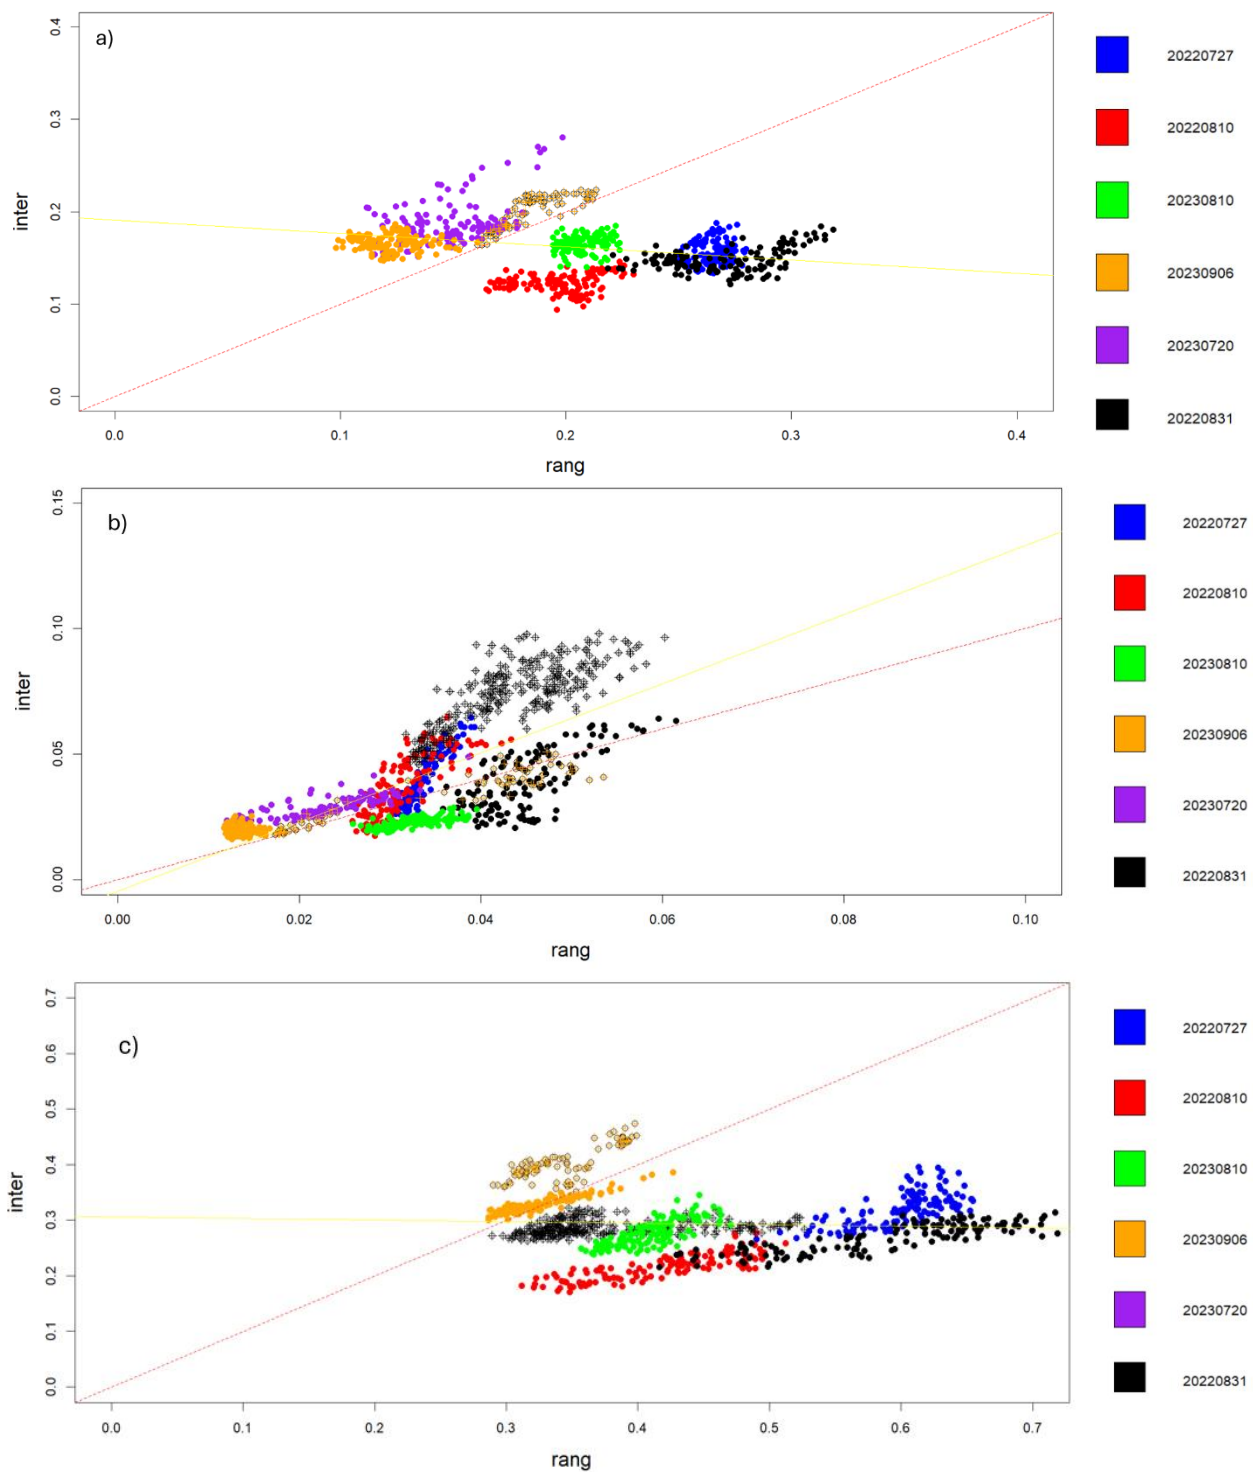


Figure 23 : a) graphique de la réflectance du RedEdge entre le rang et l'inte-rang , b) graphique de la réflectance du rouge entre le rang et l'inter-rang et c) graphique de la réflectance du NIR entre le rang et l'inter-rang. La ligne jaune correspond à la droite de régression, la rouge à la droite $y = x$. Les points pleins correspondent à Bousval et les creux au domaine W.

On remarque également que la corrélation entre le drone mixte et l'inter-rang est importante et que la pente est proche de 1. On peut en conclure qu'une grande partie de l'information qu'on trouve dans la moyenne des pixels sur 10 mètres provient donc de l'inter-rang. Ce qui peut sembler logique puisque la proportion de rang est de l'ordre de 20% en moyenne tandis que celle d'inter-rang de 80%. Enfin, il convient de noter que certaines bandes présentent des mauvaises corrélations toutes dates confondues alors que, date par date, le rang et l'inter-rang sont beaucoup plus liés. C'est le cas, par exemple, de la bande NIR qui présente ici une corrélation de -0.07 alors que la corrélation date par date varie entre 0.7 et 0.9 pour une moyenne de 0.8 et les pentes sont plus ou moins égales (entre 0.75 et 0.95) également entre dates (cf. Figure 23c).

6.2.2 Pour différents indices

Tableau 9 : Corrélation de Pearson, intervalle de prédiction à 95% et pente de la droite de régression pour les paires rang/inter, rang/light, mixte/rang et mixte/inter pour le CLRedEdge, le NDVI et le stepwise. La droite de régression est construite, pour chaque paire, en prenant la première variable du titre pour l'axe des x.

| Indices | | Rang/inter | Rang/Light | Mixte/rang | Mixte/inter |
|------------------|-------------|-------------------|-------------------|-------------------|--------------------|
| CLRedEdge | Corrélation | 0.89 | 0.91 | 0.95 | 0.99 |
| | IP | 0.39 | 0.25 | 0.28 | 0.08 |
| | Pente | 1.05 | 0.73 | 0.86 | 1.03 |
| NDVI | Corrélation | 0.63 | 0.65 | 0.69 | 0.99 |
| | IP | 0.13 | 0.12 | 0.06 | 0.02 |
| | Pente | 1.43 | 1.53 | 0.34 | 1.14 |
| Stepwise | Corrélation | 0.72 | 0.86 | 0.8 | 0.98 |
| | IP | 0.3 | 0.12 | 0.28 | 0.08 |
| | Pente | 0.8 | 0.5 | 0.78 | 1.18 |

Le même exercice a été appliqué au chlorophylle RedEdge, indice présentant la plus haute corrélation (0,66) avec le potentiel de tige dans ces deux domaines (Claessens, 2023). Le modèle stepwise, obtenu par régression linéaire pas à pas, a également été sélectionné pour sa meilleure précision dans la prédiction du potentiel de tige comparé au CLRedEdge. Enfin, le NDVI a été choisi en raison de sa capacité à représenter la vigueur et de son utilisation courante en télédétection, apparaissant dans presque toutes les études sur la vigne. Bien que le NDRE possède un pouvoir prédictif similaire au CLRedEdge, il n'a pas été retenu pour éviter une discussion redondante sur les indices normalisés, puisque le NDVI est déjà un indice normalisé.

De manière générale, les mêmes observations que pour les bandes du drone (section 6.2.1), concernant l'évolution de la corrélation et de l'intervalle de prédiction entre les différentes paires comparées, se remarquent pour les indices : la corrélation mixte/inter est supérieure à

la corrélation rang/light elle-même supérieure à la corrélation rang/inter et l'intervalle de prédiction (IP) mixte/inter est inférieur à l'IP rang/light lui-même inférieur à l'IP rang/inter. On note également que les corrélations entre le rang et l'inter-rang sont plus élevées en moyenne bien que tous les indices utilisent la bande NIR, qui seule présente une mauvaise corrélation. Cela peut être expliqué par la normalisation des indices comme le NDVI ou les rapports comme le CLRedEdge. En effet, le NDVI normalise les différences de réflectance dues aux variations d'illumination et de sol, améliorant ainsi la corrélation entre dates (Jackson et Huete, 1991) et réduisant les variations non liées à la végétation (Baret et Guyot, 1991).

Pour le CLRedEdge, les pentes date par date dans le NIR étant égales, la division par RedEdge peut potentiellement recentrer les points. Théoriquement, lorsque la réflectance dans le NIR diminue, celle du RedEdge diminue également (Pôças et al., 2015). L'astuce réside dans l'évolution de cette différence. D'après les observations des figures 23a et 23c, lorsque le NIR est approximativement égal à 0,4, le RedEdge est autour de 0,2. Et lorsque le NIR est proche de 0,2, le RedEdge se situe aux alentours de 0,1. Ainsi, les points vont avoir tendance à se recentrer.

6.3 Comparaison entre Sentinel-2 et drone

6.3.1 Bande par bande

Tableau 10 : Corrélacion et pente entre les bandes du drone rééchantillonnées à 10 mètres et Sentinel-2

| Bande | Corrélacion | Pente |
|---------|-------------|-------|
| Bleue | 0.85 | 0.99 |
| Verte | 0.82 | 0.66 |
| Rouge | 0.97 | 0.92 |
| RedEdge | 0.55 | 0.04 |
| NIR | 0.6 | 0.44 |

Le tableau 10 représente la corrélacion et la pente des différentes bandes spectrales du drone (rééchantillonnées à la taille des pixels Sentinel-2) par rapport aux mêmes bandes de Sentinel-2. On peut observer que les corrélacions sont plus élevées pour les bandes RGB que pour les bandes NIR et RedEdge. Les corrélacions plus faibles pour le NIR et le RedEdge peuvent être attribuées à une sensibilité accrue à l'atmosphère, notamment à l'humidité (Gao and Goetz, 1990). En effet, le masque de correction Sen2Cor possède certaines limitations dans la correction atmosphérique, notamment pour les canopées non uniformes et peu denses d'après l'agence spatiale européenne.

Pour le RedEdge, la variation entre les pixels de Sentinel est pratiquement inexistante (pente proche de 0). Afin de vérifier qu'il ne s'agit pas d'un artefact de la régression, les valeurs maximales et minimales ont été comparées séparément pour le drone et Sentinel-2, variant entre 0.15 et 0.20 pour Sentinel-2 et entre 0.1 et 0.3 pour le drone.

Le même exercice, effectué avec les réflectances du drone avec des angles de visée identiques à ceux de Sentinel-2 (Annexe G), montre des corrélacions légèrement supérieures aux réflectances en nadir du drone lorsqu'on les compare date par date. Cependant, en raison du manque de dates avec des réflectances en oblique, celles en nadir ont été conservées.

Il est important de noter que les différences dans l'étalonnage des capteurs et les processus de correction atmosphérique entre le drone et Sentinel-2 peuvent également entraîner des écarts dans les valeurs de réflectances. Le drone, volant à des altitudes plus basses, pourrait nécessiter une correction atmosphérique moins importante que le satellite, ce qui pourrait contribuer aux différences observées (Gao and Goetz, 1990). De plus, la différence de temps entre les mesures de drone et de Sentinel-2 introduit une source d'erreur supplémentaire. Si les mesures ne sont pas prises à la même heure, l'angle d'incidence du soleil varie. Ces variations peuvent entraîner des différences significatives dans les signatures spectrales enregistrées de la végétation (Ma et al., 2020) et dans la valeur de certains indices (Chen et al., 2020).

6.3.2 Pour les Indices

Tableau 11 : Corrélation et pente entre stepwise, CLRedEdge et NDVI du drone rééchantillonnés à 10 mètres et Sentinel-2

| Indice | Corrélation | Pente |
|-----------------|--------------------|--------------|
| Stepwise | 0.91 | 0.69 |
| Clrededge | 0.9 | 0.64 |
| NDVI (S2/mixte) | 0.92 | 0.67 |
| NDVI (S2/rang) | 0.7 | 1.09 |
| NDVI(S2/inter) | 0.89 | 0.65 |

Pour ce qui est des indices, on obtient globalement une bonne corrélation entre le drone et Sentinel-2. Afin de comparer les résultats avec ceux obtenus par les autres études, l'indice NDVI a également fait l'objet de comparaison entre Sentinel-2, le rang et l'inter-rang. Il en découle que la corrélation entre « drone rang » et Sentinel s'inscrit dans la moyenne de ce qui a déjà été observé. En effet, on observe une corrélation de 0.7 et la moyenne des études recensées dans le tableau 1 de la section 3.4 est de 0.66. En revanche, la corrélation entre Sentinel-2 et « drone mixte » est supérieure ici : 0.92 contre 0.67. De même pour la comparaison entre « drone inter » et Sentinel-2 : 0.89 contre 0.6. Notons tout de même que la plupart de ces études ne possèdent pas d'herbe dans l'inter-rang. La même observation que Sozzi et al. (2020), à propos de la variabilité du NDVI mesurée par le drone par rapport à Sentinel-2, a été détectée. En effet, l'histogramme du « drone rang » varie en moyenne entre 0.3 et 0.9 alors qu'il ne varie qu'entre 0.3 et 0.5 pour Sentinel-2.

6.4 Détermination du potentiel foliaire de base directement depuis les bandes Sentinel

Les résultats du modèle stepwise du drone (équ. 5.4) pour le rang rééchantillonné à 10 mètres ont été comparés avec une multitude d'indices Sentinel-2 repris dans l'annexe I. Ensuite, une stepwise linear regression (SLR) a été effectuée sur ces indices. Dans la suite du travail, le « stepwise model » rééchantillonné à 10 mètres sera appelé comme étant le « potentiel de rang calculé-rééchantillonné » et le « stepwise model » pour chaque pixel de drone sera appelé « potentiel de rang calculé ».

6.4.1 Résultats pour les différents indices

Tableau 12 : de gauche à droite : indice, corrélation de Pearson entre l'indice et le modèle stepwise, coefficient de détermination entre l'indice et le modèle stepwise, corrélation de Pearson moyenne pour le modèle stepwise et l'indice pour chaque date, corrélation de Pearson entre le rang et l'inter-rang pour l'indice. Les indices sélectionnés sont les indices présentant un r^2 supérieur à 0.6.

| Indice | R | R ² | Corrélation par date (moyenne) | Corrélation entre rang/inter |
|------------|------|----------------|--------------------------------|------------------------------|
| SRnirred | 0.81 | 0.6561 | 0.71 | 0.36 |
| SRnirgreen | 0.8 | 0.64 | 0.75 | 0.62 |
| MSR | 0.8 | 0.64 | 0.78 | 0.44 |
| gNDVI | 0.8 | 0.64 | 0.82 | 0.97 |
| NDWI2 | -0.8 | 0.64 | 0.82 | 0.83 |
| NDVI | 0.79 | 0.6241 | 0.78 | 0.23 |
| SIPI | 0.78 | 0.6084 | 0.77 | 0.54 |
| OSAVI | 0.78 | 0.6084 | 0.76 | 0.19 |
| STI | 0.78 | 0.6084 | 0.61 | / |
| NDTI | 0.78 | 0.6084 | 0.61 | / |
| Srnirblue | 0.78 | 0.6084 | 0.77 | 0.6 |

Le tableau 12 présente dans les deux premières colonnes la corrélation de Pearson et le coefficient de détermination entre l'indice Sentinel et le « potentiel de rang calculé-rééchantillonné ». Il convient de noter que la corrélation est établie sur une variable (« potentiel de rang calculé-rééchantillonné ») qui comporte déjà une certaine marge d'erreur. Pour les indices eux-mêmes, on observe que la majorité d'entre eux utilise la bande NIR. Les seuls indices ne l'utilisant pas sont le STI (Soil Tillage Index) et le NDTI (Normalized Difference Tillage Index), qui exploitent les bandes SWIR (1 et 2). Cependant, lorsqu'on considère uniquement les bandes, la corrélation de la bande NIR ($r = 0.57$) est inférieure à celle des bandes rouge et bleue ($r = 0.75$).

La troisième colonne du tableau 12 présente la corrélation moyenne entre le potentiel de rang et l'indice, calculée date par date. L'objectif est d'évaluer si l'indice fonctionne à travers les différentes dates (temporellement) ainsi qu'à l'intérieur même de la parcelle (spatialement). On remarque que les indices ayant la meilleure corrélation toutes dates confondues ne sont pas nécessairement ceux qui présentent la meilleure corrélation pour chaque date individuelle. Il a également été observé que la corrélation date par date est généralement moins bonne pour l'année 2023 que pour l'année 2022 (environ 20% de différence).

La quatrième colonne présente la corrélation entre le rang et l'inter-rang pour les différents indices testés. En effet, étant donné que l'on compare un indice Sentinel, qui combine des informations du rang et de l'inter-rang, avec des données provenant uniquement du rang, on pourrait supposer qu'un indice montrant une forte corrélation entre le rang et l'inter-rang pourrait apporter plus de robustesse au modèle. Ce modèle sera d'ailleurs proposé plus loin et ne seront sélectionnés que les indices présentant une bonne corrélation entre le rang et l'inter-rang ainsi qu'entre les indices Sentinel-2 et le potentiel de rang.

6.4.2 Stepwise linear regression

Sur la base des indices testés pour trouver le potentiel de base, une SLR a été effectuée. Le but était de créer un modèle permettant d'estimer au mieux ce potentiel directement depuis Sentinel-2.




Figure 24 : Potentiel prédit par SLR sur la base des indices Sentinel en fonction du potentiel.

La figure 24 représente le potentiel prédit par le modèle obtenu avec la SLR en fonction des valeurs du « potentiel de rang calculé-rééchantillonné ». La corrélation est de 0.91 (soit un coefficient de détermination r^2 de 0.83). L'intervalle de prédiction à 95 % est de 0.14 MPa. Cela signifie que dans 95 % des cas, la valeur réelle sera comprise dans un intervalle de +/- 0.14 autour de la valeur prédite.

La figure 25 répète le même exercice que la SLR précédente, mais en ne sélectionnant préalablement que les indices présentant un coefficient de détermination supérieur à 0.6 avec le potentiel, ainsi qu'entre son rang et son inter-rang. Le but est d'avoir un modèle plus robuste, même si ce dernier pourrait probablement être moins précis. En effet, si l'on sait que le rang évolue toujours de la même manière que l'inter-rang, on peut s'attendre à ce que le modèle soit plus robuste lorsqu'on l'applique à d'autres dates.




Figure 25 : Potentiel prédit par SLR sur base des indices Sentinel possédant un coefficient de détermination supérieure à 0.6 avec le « potentiel de rang calculé-rééchantillonné » et dont la corrélation entre le rang et l'inter-rang est également supérieure à 0.6.

On obtient ici une corrélation de 0.72 et un intervalle de prédiction à 95 % de 0.18 MPa, ce qui est nettement inférieur à la qualité du modèle obtenu à partir de tous les indices.

6.4.3 Validation

La validation se porte sur certains pixels où des mesures de potentiel de tige ont été prises grâce à une chambre de Scholander (annexe N). La validation s'est portée sur des dates disposant de mesures au sol et de vol Sentinel proche de ces dates. Dans cette section, le potentiel fait référence au potentiel mesuré.




Figure 26 : Potentiel prédit par SLR en fonction du potentiel mesuré pour les dates ne disposant pas de vol de drone.

La racine de l'erreur quadratique moyenne (RMSE) est de 0.28. Si l'on retranche la date du 25/08/2022 (en rouge sur le graphique), la RMSE tombe à 0.16. Comme on peut le constater sur la figure 26, les valeurs prédites sont dans un intervalle plus grand que l'intervalle de prédiction décrit dans la section supérieure. En effet, le modèle avait calculé un intervalle de prédiction à 95 % de 0.14. Cependant, on remarque que beaucoup de points dépassent cet intervalle pour la validation.

On pourrait expliquer cela, outre le côté fort empirique du modèle qui se base sur 8 jeux de mesures, par le fait que la variabilité du potentiel intra-pixel est non négligeable (bien qu'inférieure tout de même à la variabilité entre les pixels). Donc, les données utilisées pour la validation étant ponctuelles (mesurées sur la parcelle avec la chambre de Scholander en une dizaine de point) et le modèle étant construit sur la moyenne des « stepwise rang » sur la surface d'un pixel Sentinel, on a une probabilité accrue de tomber sur des mesures qui s'écartent de cette moyenne. Autrement dit, la valeur mesurée sur le terrain peut fortement différer du « potentiel de rang calculé-rééchantillonné » étant donné la variabilité non négligeable du « potentiel de rang calculé » au sein de la surface. La figure 27 représente la

variabilité qu'il peut exister au sein d'un pixel. Autrement dit, il s'agit de la gamme de potentiel de tous les pixels drone mesurés qu'on peut trouver dans la surface d'un pixel Sentinel-2.

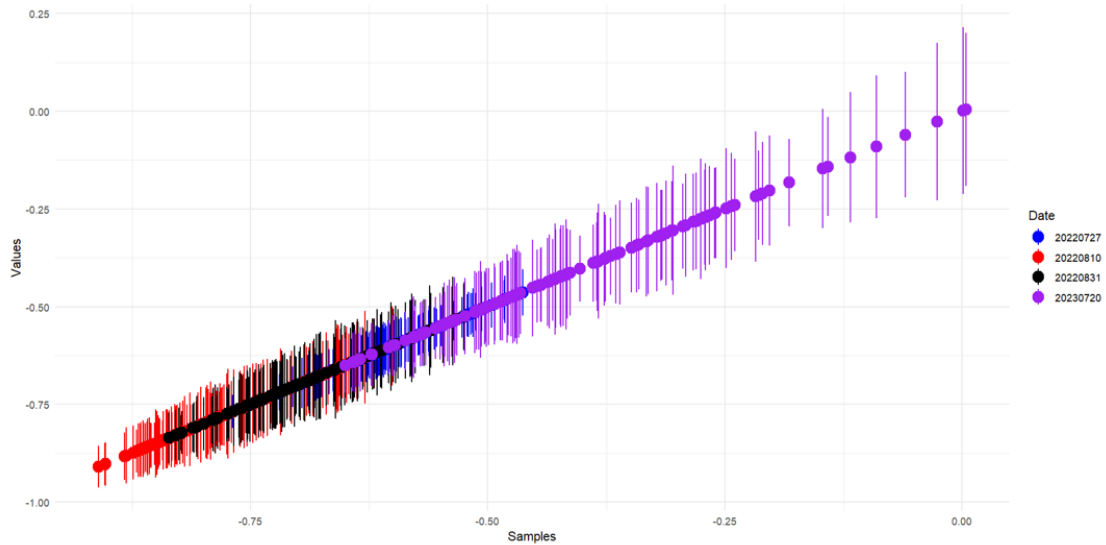


Figure 27 : graphique représentant la variabilité intra-pixel du potentiel (stepwise model) du rang. Les points correspondent à la moyenne des pixels de drone dans la surface d'un pixel Sentinel (« stepwise rang ») et les lignes verticales correspondent au premier écart-type de la gamme de valeurs trouvée au sein de ce pixel.

Sur la figure 27, l'axe des abscisses reprend simplement la valeur du potentiel moyen afin de tout classer par ordre croissant. On voit donc que le modèle est construit sur la moyenne, mais que les valeurs peuvent en dévier. Cette erreur s'ajoute donc à l'erreur déjà présente du modèle. Enfin, l'écart-type signifie qu'environ 66 pourcents des valeurs sont comprises dans cet intervalle. Pour voir toutes les gammes de valeurs qui peuvent réellement exister, il faut se référer au maximum et au minimum (annexe B), mais cela prend donc également en compte les valeurs aberrantes. En plus de cela, n'oublions pas que les potentiels moyens utilisés pour effectuer la SLR sont basés également sur une régression, ce qui ajoute une couche d'erreur potentielle supplémentaire.

7 Discussion

7.1 L'évolution du rang et de l'inter-rang

Nous avons comparé la réflectance entre le rang et l'inter-rang pour plusieurs bandes et plusieurs indices dont les résultats sont repris dans les tableaux 9 et 10. Ce qu'il en ressort est que la corrélation entre le rang et l'inter-rang est en générale élevée pour les indices (0.63 à 0.89) mais moins pour les bandes seules (en dessous de 0.5) mise à part la bande rouge qui possède une corrélation de 0.7. Ces bandes ne permettent donc pas de prédire le rang en fonction de l'inter-rang et inversement. Cela peut être expliqué par plusieurs facteurs.

Premièrement, la variabilité de la disponibilité en eau influence différemment l'herbe et la vigne, qui possèdent des systèmes racinaires distincts (Barros et al., 2022; Palazzi et al., 2023b). En effet, les racines des vignes peuvent atteindre plusieurs mètres de profondeur, permettant à la plante de puiser de l'eau dans les couches profondes du sol, ce qui la rend plus résistante aux sécheresses prolongées (White, 2003). En revanche, les herbes ont des racines superficielles, ce qui les rend plus sensibles aux variations d'humidité du sol en surface (Brown et al., 2010). Cela implique que la réflectance ne va pas évoluer de la même manière en fonction de la disponibilité en eau. Une étude plus approfondie du lien entre l'évolution séparée de l'herbe et de la vigne selon la disponibilité en eau pourrait apporter plus de précision. La proportion de sol nu ou d'herbe complètement sénescente, dont la signature spectrale diffère significativement de celle d'une feuille verte, peut également affecter cette corrélation (Palazzi et al., 2023b).

Ensuite, les variations d'ombre dans les parcelles peuvent compliquer les mesures de réflectance. Une canopée moins dense laisse passer plus de lumière, ce qui modifie la réflectance dans le rang. Cet effet est plus prononcé dans les bandes NIR et RedEdge, qui sont influencées par l'épaisseur de la canopée, contrairement aux bandes rouge et bleue qui sont rapidement absorbées par la chlorophylle.

Il est important de noter que certaines bandes qui présentent des mauvaises corrélations dans le temps, comme c'est le cas pour le NIR et le RedEdge, montrent de bien meilleures corrélations lorsqu'elles sont comparées date par date (cf. Tableau 13). Cela peut s'expliquer en partie par la sensibilité plus importante de ces deux indices aux variations atmosphériques, notamment l'humidité et les aérosols. Il serait nécessaire d'examiner le taux d'humidité présent dans l'air à chaque date pour en savoir davantage (Gao and Goetz, 1990). Le changement dans l'angle solaire ou le changement de l'angle d'incidence sur la feuille peut également entraîner des différences dans les valeurs de réflectances. Bien que l'influence en fonction de la longueur d'onde ne soit pas vraiment déterminée (Remer et al., 2001).

Il est difficile d'expliquer la raison pour laquelle certaines bandes, comme la verte ou la bleue, présentent des variations importantes dans leur corrélation. Une approche a été explorée où les réflectances du rang et de l'inter-rang ont été mises en relation avec différentes variables énumérées au point 5.1.1 à savoir l'irradiance, la profondeur de sable et la teneur en eau. Mais rien n'a permis d'expliquer les variations dans les corrélations.

Enfin, les corrélations de la parcelle ont été calculées en séparant cette dernière en deux parties : une partie haute où la profondeur d'apparition du sable est plus faible et une partie basse où la profondeur d'apparition du sable est plus élevée (annexe G pour la corrélation, figure 13 pour la profondeur d'apparition du sable). Il est constaté que les corrélations dans le visible pour la partie haute sont meilleures que pour la partie basse. Le fait que le visible est fortement influencé par la chlorophylle, et celle-ci par la disponibilité en eau (Kara and Brinis, 2012), peut renforcer l'idée que la variabilité en eau affecte différemment l'herbe et la vigne. Surtout dans la partie haute, où l'herbe souffrira probablement plus en raison de son système racinaire moins profond. Enfin, dans la partie basse, la disponibilité en eau du sol étant plus élevée, l'herbe comme la vigne sont moins impactées et les signatures spectrales moins variables pour l'une comme pour l'autre. C'est pourquoi on y observe, du moins pour le visible, de meilleure corrélation que dans le haut de la parcelle.

Tableau 13 : corrélation de Pearson entre rang/inter et rang/light pour le rouge, vert, bleu, NIR et RedEdge date par date.

| Bande | Lieu | Date | Rang/inter | Rang/light |
|-------|-----------|------------|------------|------------|
| Rouge | Bousval | 27/07/2022 | 0.93 | 0.93 |
| | | 10/08/2022 | 0.86 | 0.8 |
| | | 31/08/2022 | 0.67 | 0.7 |
| | | 20/07/2023 | 0.8 | 0.78 |
| | | 10/08/2023 | 0.51 | 0.55 |
| | | 06/09/2023 | 0.78 | 0.61 |
| | Domaine W | 31/08/2022 | 0.8 | 0.85 |
| | | 06/09/2023 | 0.94 | 0.95 |
| Bleue | Bousval | 27/07/2022 | 0.22 | 0.28 |
| | | 10/08/2022 | 0.25 | 0.27 |
| | | 31/08/2022 | -0.13 | -0.16 |
| | | 20/07/2023 | 0.87 | 0.54 |
| | | 10/08/2023 | 0.12 | 0.5 |
| | | 06/09/2023 | 0.69 | 0.72 |
| | Domaine W | 31/08/2022 | 0.71 | 0.71 |
| | | 06/09/2023 | 0.94 | 0.94 |
| Verte | Bousval | 27/07/2022 | 0.77 | 0.31 |
| | | 10/08/2022 | 0.22 | 0.029 |
| | | 31/08/2022 | -0.15 | 0.033 |
| | | 20/07/2023 | 0.66 | 0.27 |
| | | 10/08/2023 | 0.67 | 0.28 |

| | | | | |
|---------|-----------|------------|-------|-------|
| | | 06/09/2023 | 0.75 | 0.19 |
| | Domaine W | 31/08/2022 | 0.066 | 0.066 |
| | | 06/09/2023 | 0.06 | 0.06 |
| NIR | Bousval | 27/07/2022 | 0.67 | 0.77 |
| | | 10/08/2022 | 0.82 | 0.86 |
| | | 31/08/2022 | 0.83 | 0.9 |
| | | 20/07/2023 | 0.85 | 0.74 |
| | | 10/08/2023 | 0.75 | 0.86 |
| | | 06/09/2023 | 0.92 | 0.94 |
| | Domaine W | 31/08/2022 | 0.69 | 0.69 |
| | | 06/09/2023 | 0.72 | 0.72 |
| RedEdge | Bousval | 27/07/2022 | 0.56 | 0.58 |
| | | 10/08/2022 | 0.86 | 0.8 |
| | | 31/08/2022 | 0.29 | 0.39 |
| | | 20/07/2023 | 0.84 | 0.85 |
| | | 10/08/2023 | 0.6 | 0.63 |
| | | 06/09/2023 | 0.96 | 0.94 |
| | Domaine W | 31/08/2022 | 0.94 | 0.94 |
| | | 06/09/2023 | 0.68 | 0.68 |

7.2 Les indices spectraux et les prises de mesures

Le problème majeur avec l'utilisation d'indices spectraux dans la détermination du potentiel hydrique est que l'on ne mesure pas directement ce potentiel, mais les caractéristiques physiologiques de la feuille associées au potentiel et aux différents stress (Carter and Knapp, 2001). Ainsi, la réflectance dans le visible sera grandement influencée par la teneur en chlorophylle. Cette dernière étant liée d'une part au potentiel, mais également à d'autres facteurs comme la teneur en azote (Celette, 2007). Par exemple, un stress azoté peut faire chuter la teneur en chlorophylle que nous détecterions comme étant une diminution de la disponibilité en eau de la plante. La réflectance sera aussi influencée par la vigueur et la structure de la plante qui peuvent également donner des informations sur le statut hydrique cumulé. Il convient donc d'insister sur le fait que l'historique du potentiel de la plante aura certainement plus d'impact, et c'est une hypothèse, sur la réponse spectrale qu'un changement dans la demande évaporative de l'atmosphère d'un jour à l'autre. Autrement dit, d'un jour à l'autre, la structure de la feuille au même titre que sa teneur en chlorophylle auront certainement peu bouger tandis que le potentiel aurait pu changer plus fortement en passant d'un air humide à un air plus sec.

Ceci explique en partie pourquoi l'utilisation d'images Sentinel prises à des dates différentes (de l'ordre de quelques jours) n'influence pas trop la corrélation avec le potentiel. En effet, les conditions hydriques antérieures ont un impact sur l'évolution de la teneur en eau et en

chlorophylle (Jiao et al., 2023). De même, l'évolution de la teneur en eau du sol ne change pas spontanément d'un jour à l'autre (Otkin et al., 2019). On pourrait penser que si la pluie tombe entre les prises de mesures et le passage de Sentinel, on obtiendrait des mesures totalement différentes. Cependant, le taux de réapparition de la chlorophylle est assez lent (et dépend de la durée et la sévérité de l'épisode sec) après des épisodes de sécheresse (Li et al., 2024), de ce fait, les indices utilisant des longueurs d'onde du visible ne seront pas affectés. Il peut donc y avoir un délai entre les mesures au sol et le passage de Sentinel, pourvu que celui-ci soit raisonnable afin d'assurer une certaine consistance dans les données (Li et al., 2022).

En revanche, l'heure de prise des mesures a une importance en raison du caractère fort empirique de l'approche. En effet, le potentiel de la feuille va varier au cours de la journée, mais pas la teneur en chlorophylle. L'heure de la prise de mesure du potentiel au sol n'a donc pas énormément d'importance, mais il est préférable de la garder constante tout au long des comparaisons avec les données spectrales pour s'affranchir de l'effet de l'heure. Pour l'heure de la prise de mesure spectrale, il est également préférable de la garder constante pour s'affranchir des effets d'irradiance et d'angle qui influencent la réflectance (Baret et al., 1989). De plus, bien que l'on travaille avec des réflectances, la feuille va absorber d'autant plus de lumière en proportion lorsque le rayonnement est faible, jusqu'à ce que le CO₂ devienne l'élément limitant (Kromdijk et al., 2016).

7.3 Stepwise linear regression



Pour caractériser les incertitudes d'un modèle multilinéaire, différentes approches sont possibles. On peut, par exemple, calculer l'intervalle de prédiction qui nous donne la probabilité que le potentiel de tige prédit se trouve dans une certaine gamme de valeurs. Pour le modèle développé à la section 6.4.2 et représenté par la figure 24, l'intervalle de prédiction varie entre 0.138 MPa et 0.145 MPa avec une moyenne établie à 0.139 MPa. Autrement dit, il est pratiquement constant. Notons bien que cela ne signifie pas que la valeur prédite sera égale à la valeur mesurée plus ou moins 0.139 mais que, 95 % du temps, la valeur prédite se trouvera dans un intervalle compris entre la valeur mesurée plus ou moins l'intervalle de 0.139. Cela étant valable pour toutes les valeurs de potentiel mesurées étant donné que l'intervalle est pratiquement constant. Il est donc difficile de caractériser les endroits où le modèle surestime ou sous-estime le potentiel par exemple.

Pour ce faire, l'erreur résiduelle, qui se définit comme étant la différence entre la valeur prédite et la valeur observée d'un modèle, a été calculée pour chaque date au domaine de Bousval (cf. Figure 28a). Le but étant de voir si des erreurs reviennent aux mêmes endroits ou pas. Le domaine W a expressément été omis car les deux dates différentes ne reprenant pas la même surface, la comparaison devenait difficile. Sur la figure 28a, les valeurs positives représentent les lieux où le modèle a surestimé le potentiel. En revanche, les valeurs négatives correspondent aux lieux sous-estimés par le modèle. Une analyse visuelle nous permet de constater que le modèle semble sous-évaluer le potentiel au même endroit pour l'année 2022 (dans le haut à droite). En regardant la figure 28b qui représente le potentiel mesuré, on constate que cette zone correspond à des potentiels mesurés élevés. La même observation peut se faire pour le 20/07/2023. Inversement, les zones où le potentiel semble plus fortement surévalué semblent correspondre à des zones où le potentiel mesuré est le plus faible. On peut conclure que le modèle prédit moins bien les valeurs de potentiel les plus faibles et les plus élevées. Bien que l'intervalle de prédiction soit constant.

Tableau 14 : RMSE de la prédiction du potentiel de tige pour chacune des dates de mesures.

| Lieux | Dates | RMSE |
|---------|------------|------|
| Bousval | 27/07/2022 | 0.06 |
| | 10/08/2022 | 0.05 |
| | 31/08/2022 | 0.05 |
| | 20/07/2023 | 0.1 |
| | 10/08/2023 | 0.11 |
| W | 31/08/2022 | 0.04 |
| | 06/09/2023 | 0.08 |

Enfin, le RMSE peut également être calculé date par date afin de voir si le modèle prédit globalement mieux à certaines dates plutôt qu'à d'autres. On constate en regardant le tableau 14 que le RMSE est en général plus faible pour les dates de l'année 2022 que pour celles de l'année 2023.






Figure 28 : a) Différence entre le potentiel prédit et le potentiel mesuré (b-a), b) potentiel mesuré et c) potentiel prédits par SLR sur base des données Sentinel-2.

Finalement, pour parler de la méthode même de modélisation, on peut dire que la stepwise linear regression, bien que souvent utilisée lorsque de nombreuses variables sont corrélées entre elles, présente des avantages mais aussi des limites. Par exemple, il est crucial de garder des variables faiblement corrélées avec la cible mais fortement corrélées entre elles pour éviter des erreurs de rejet d'hypothèses valides (Adjustment and Horst, 1941). Cette méthode peut également entraîner des biais dans les coefficients et un surajustement (overfitting), rendant le modèle peu exportable (Whittingham et al., 2006). Il pourrait donc être intéressant d'explorer d'autres modèles tels que la régression bayésienne, par exemple (Rouder and Morey, 2012). De même, des méthodes d'apprentissage comme le support vector machine (SVM) pourraient être envisagées pour voir si les résultats de la validation sont plus satisfaisants.

8 Conclusion

L'objectif de ce travail était de caractériser l'évolution du rang par rapport à l'inter-rang et de quantifier le potentiel hydrique sur la base de données Sentinel et du drone. Cela nous a amenés à travailler sur la séparation de l'ombre, par exemple.

La séparation de l'ombre de la vigne par la classification supervisée montre des résultats très satisfaisants avec une précision globale d'environ 95 %. La deuxième méthode, bien que possédant la qualité de pouvoir être utilisée à n'importe quelle heure/date, possède une moins bonne précision et surestime beaucoup l'ombre, notamment en ne détectant pas les trous dans la canopée.

L'évolution du rang et de l'inter-rang est difficile à quantifier car les corrélations varient beaucoup lorsque l'on compare date par date et pour la plupart des bandes. La corrélation, lorsque toutes les dates sont mélangées, est également peu satisfaisante, notamment pour les bandes NIR et RedEdge qui sont fortement influencées par les variations atmosphériques. Les indices, quant à eux, présentent de meilleures corrélations car ils normalisent les différences de réflectance dues aux variations d'illumination et de sol, améliorant ainsi la corrélation entre dates et réduisant les variations non liées à la végétation.

Enfin, la détermination du potentiel directement depuis l'indice Sentinel calculé par SLR, en utilisant cette fois-ci le drone comme support plus que comme intermédiaire, montre des résultats plus ou moins corrects même sur la validation. Le modèle demeure tout de même très empirique et dépendant des variables d'entraînement, caractérisé par une faible exportabilité à d'autres domaines où dates.

Références bibliographiques

- 10.2 - Stepwise Regression | STAT 501 [WWW Document], n.d. URL
<https://online.stat.psu.edu/stat501/lesson/10/10.2> (accessed 5.4.24).
- Acevedo-Opazo, C., n.d. Extrapolation spatialisée d'une mesure locale de l'état hydrique de la vigne à partir de données auxiliaires.
- Ahmed, M., Seraj, R., Islam, S., 2020. The k-means Algorithm: A Comprehensive Survey and Performance Evaluation. *Electronics* 9, 1295. <https://doi.org/10.3390/electronics9081295>
- Alberg, A.J., Park, J.W., Hager, B.W., Brock, M.V., Diener-West, M., 2004. The Use of "Overall Accuracy" to Evaluate the Validity of Screening or Diagnostic Tests. *J. Gen. Intern. Med.* 19, 460. <https://doi.org/10.1111/j.1525-1497.2004.30091.x>
- Allan, R., Pereira, L., Smith, M., 1998. Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56.
- Apel, K., Hirt, H., 2004. Reactive oxygen species: metabolism, oxidative stress, and signal transduction. *Annu. Rev. Plant Biol.* 55, 373–399. <https://doi.org/10.1146/annurev.arplant.55.031903.141701>
- Attia, F., 2007. Effet du stress hydrique sur le comportement écophysiological et la maturité phénolique de la vigne *Vitis vinifera* L. : étude de cinq cépages autochtones de Midi-Pyrénées (phd).
- Baluja, J., Diago, M.-P., Balda, P., Zorer, R., Meggio, F., Morales, F., Tardaguila, J., 2012. Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). *Irrig. Sci.* 30, 511–522. <https://doi.org/10.1007/s00271-012-0382-9>
- Baret, F., Olioso, A., Luciani, J.L., Hanocq, J.F., Monterrot, J.C., 1989. Estimation à partir de mesures de réflectance spectrale du rayonnement photosynthétiquement actif absorbé par une culture de blé. *Agronomie* 9, 885–895. <https://doi.org/10.1051/agro:19890906>
- Barros, T., Conde, P., Gonçalves, G., Premevida, C., Monteiro, M., Ferreira, C.S.S., Nunes, U.J., 2022. Multispectral vineyard segmentation: A deep learning comparison study. *Comput. Electron. Agric.* 195, 106782. <https://doi.org/10.1016/j.compag.2022.106782>
- Becker, C., 2019. Dynamique de la teneur en eau dans deux vignobles wallons enherbés dans l'inter-rang.
- Bellvert, J., Jofre-Čekalović, C., Pelechá, A., Mata, M., Nieto, H., 2020. Feasibility of Using the Two-Source Energy Balance Model (TSEB) with Sentinel-2 and Sentinel-3 Images to Analyze the Spatio-Temporal Variability of Vine Water Status in a Vineyard. *Remote Sens.* 12, 2299. <https://doi.org/10.3390/rs12142299>
- Benyahia, F., Bastos Campos, F., Ben Abdelkader, A., Basile, B., Tagliavini, M., Andreotti, C., Zanotelli, D., 2023. Assessing Grapevine Water Status by Integrating Vine Transpiration, Leaf Gas Exchanges, Chlorophyll Fluorescence and Sap Flow Measurements. *Agronomy* 13, 464. <https://doi.org/10.3390/agronomy13020464>
- Berry, A., Vivier, M.A., Poblete-Echeverría, C., 2024. Evaluation of canopy fraction-based vegetation indices, derived from multispectral UAV imagery, to map water status variability in a commercial vineyard. *Irrig. Sci.* <https://doi.org/10.1007/s00271-023-00907-1>
- Besnard, G., n.d. Potentiel hydrique et conductance stomatique des feuilles de frêne (*Fraxinus excelsior* L) dans une forêt alluviale du Haut-Rhône français.
- Borgogno-Mondino, E., Lessio, A., Tarricone, L., Novello, V., de Palma, L., 2018. A comparison between multispectral aerial and satellite imagery in precision viticulture. *Precis. Agric.* 19, 195–217. <https://doi.org/10.1007/s11119-017-9510-0>
- Bourgeon, M.-A., 2015. Conception et évaluation d'un dispositif d'imagerie multispectrale de proxidtection embarqué pour caractériser le feuillage de la vigne (These de doctorat). Dijon.
- Brown, R.N., Percivalle, C., Narkiewicz, S., DeCuollo, S., 2010. Relative Rooting Depths of Native Grasses and Amenity Grasses with Potential for Use on Roadsides in New England. *HortScience* 45, 393–400. <https://doi.org/10.21273/HORTSCI.45.3.393>

- Carter, G.A., Knapp, A.K., 2001. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *Am. J. Bot.* 88, 677–684.
- Caruso, G., Palai, G., 2023. Assessing grapevine water status using Sentinel-2 images. *Italus Hortus* 30, 70. <https://doi.org/10.26353/j.itahort/2023.3.7079>
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., Grégoire, J.-M., 2001. Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sens. Environ.* 77, 22–33. [https://doi.org/10.1016/S0034-4257\(01\)00191-2](https://doi.org/10.1016/S0034-4257(01)00191-2)
- Celette, F., 2007. Dynamique des fonctionnements hydrique et azoté dans une vigne enherbée sous le climat méditerranéen.
- Chaves, M.M., Flexas, J., Pinheiro, C., 2009. Photosynthesis under drought and salt stress: regulation mechanisms from whole plant to cell. *Ann. Bot.* 103, 551–560. <https://doi.org/10.1093/aob/mcn125>
- Chen, J., Zhang, Q., Chen, B., Zhang, Y., Ma, L., Li, Z., Zhang, X., Wu, Y., Wang, S., A. Mickler, R., 2020. Evaluating Multi-Angle Photochemical Reflectance Index and Solar-Induced Fluorescence for the Estimation of Gross Primary Production in Maize. *Remote Sens.* 12, 2812. <https://doi.org/10.3390/rs12172812>
- Choné, X., Van Leeuwen, C., Dubourdieu, D., Gaudillère, J.P., 2001. Stem Water Potential is a Sensitive Indicator of Grapevine Water Status. *Ann. Bot.* 87, 477–483. <https://doi.org/10.1006/anbo.2000.1361>
- Cogato, A., Pagay, V., Marinello, F., Meggio, F., Grace, P., De Antoni Migliorati, M., 2019. Assessing the Feasibility of Using Sentinel-2 Imagery to Quantify the Impact of Heatwaves on Irrigated Vineyards. *Remote Sens.* 11, 2869. <https://doi.org/10.3390/rs11232869>
- "Combining Hyperspectral Imaging and Small Unmanned Aerial Systems for " by Rinaldo R. Izzo [WWW Document], n.d. URL <https://repository.rit.edu/theses/10162/> (accessed 2.23.24).
- Create a Canopy Height Model With Lidar Data [WWW Document], 2017. . *Earth Data Sci. - Earth Lab.* URL <https://www.earthdatascience.org/courses/earth-analytics/lidar-raster-data-r/lidar-chm-dem-dsm/> (accessed 5.22.24).
- Dauriac, F., 2004. Suivi multi-échelle par télédétection et spectroscopie de l'état hydrique de la végétation méditerranéenne pour la prévention du risque de feu de forêt.
- de Torgny - S'ABONNER GRATUITEMENT.pdf, n.d.
- de Torgny, V., n.d. S'ABONNER GRATUITEMENT.
- Delrot, S., Gambetta, G., Goutouly, J.-P., 2015. Effets du déficit hydrique sur les flux d'eau et la teneur en sucres dans les raisins.
- Ensoleillement, n.d. . *Energ. Plus Site.* URL <https://energieplus-lesite.be/theories/climat8/ensoleillement-d8/> (accessed 5.22.24).
- EO Browser [WWW Document], n.d. URL <https://www.sentinel-hub.com/explore/eobrowser/> (accessed 2.6.24).
- Escudier, J.-L., Bes, M., Salmon, J.-M., Caillé, S., Samson, A., 2014. Stress hydrique prolongé des vignes : comment adapter les pratiques œnologiques en conséquence ?
- Fabien, D., Deshayes, M., Dominique, G., Roger, J.-M., 2001. Suivi de la teneur en eau de la végétation méditerranéenne par télédétection. Application au risque de feu de forêt.
- Freeman, B.M., Kliwer, W.M., 1983. Effect of Irrigation, Crop Level and Potassium Fertilization on Carignane Vines. II. Grape and Wine Quality. *Am. J. Enol. Vitic.* 34, 197–207. <https://doi.org/10.5344/ajev.1983.34.3.197>
- Gao, B., 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* 58, 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gao, B.-C., Goetz, A.F.H., 1990. Column atmospheric water vapor and vegetation liquid water retrievals from Airborne Imaging Spectrometer data. *J. Geophys. Res. Atmospheres* 95, 3549–3564. <https://doi.org/10.1029/JD095iD04p03549>

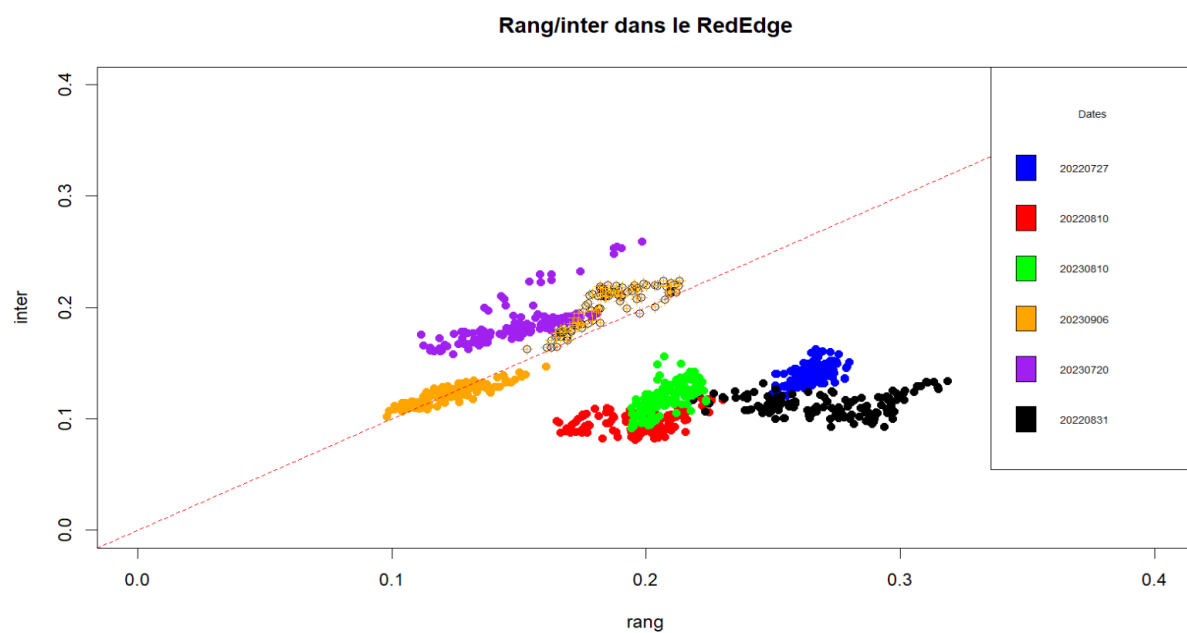

- Girona, J., Mata, M., Goldhamer, D.A., Johnson, R.S., DeJong, T.M., 1993. Patterns of Soil and Tree Water Status and Leaf Functioning during Regulated Deficit Irrigation Scheduling in Peach. *J. Am. Soc. Hortic. Sci.* 118, 580–586. <https://doi.org/10.21273/JASHS.118.5.580>
- Gitelson, A.A., Merzlyak, M.N., Lichtenthaler, H.K., 1996. Detection of Red Edge Position and Chlorophyll Content by Reflectance Measurements Near 700 nm. *J. Plant Physiol.* 148, 501–508. [https://doi.org/10.1016/S0176-1617\(96\)80285-9](https://doi.org/10.1016/S0176-1617(96)80285-9)
- González-Fernández, A.B., Sanz-Ablanedo, E., Gabella, V.M., García-Fernández, M., Rodríguez-Pérez, J.R., 2019. Field Spectroscopy: A Non-Destructive Technique for Estimating Water Status in Vineyards. *Agronomy* 9, 427. <https://doi.org/10.3390/agronomy9080427>
- Govi, D., Pappalardo, S.E., De Marchi, M., Meggio, F., 2024. From Space to Field: Combining Satellite, UAV and Agronomic Data in an Open-Source Methodology for the Validation of NDVI Maps in Precision Viticulture. *Remote Sens.* 16, 735. <https://doi.org/10.3390/rs16050735>
- Hannah, L., Roehrdanz, P.R., Ikegami, M., Shepard, A.V., Shaw, M.R., Tabor, G., Zhi, L., Marquet, P.A., Hijmans, R.J., 2013. Climate change, wine, and conservation. *Proc. Natl. Acad. Sci.* 110, 6907–6912. <https://doi.org/10.1073/pnas.1210127110>
- Hmida, S.B., n.d. Inversion des formes d'ondes LiDAR pour l'estimation des caractéristiques des cultures et des forêts par des techniques probabilistes et variationnelles.
- International Atomic Energy Agency, 2008. Field estimation of soil water content A practical guide to methods, instrumentation and sensor technology (No. 1018–5518). International Atomic Energy Agency (IAEA).
- Jiao, S., Zeng, F., Huang, Y., Zhang, L., Mao, J., Chen, B., 2023. Physiological, biochemical and molecular responses associated with drought tolerance in grafted grapevine. *BMC Plant Biol.* 23, 110. <https://doi.org/10.1186/s12870-023-04109-x>
- Jones, H.G., 2004. Irrigation scheduling: advantages and pitfalls of plant-based methods. *J. Exp. Bot.* 55, 2427–2436. <https://doi.org/10.1093/jxb/erh213>
- Kara, K., Brinis, L., 2012. Réponse physiologique au stress hydrique de variétés de blé tendre (*Triticum aestivum* L.) cultivées en Algérie. *Eur. J. Sci. Res.* 81, 524–532.
- Khaliq, A., Comba, L., Biglia, A., Ricauda Aimonino, D., Chiaberge, M., Gay, P., 2019. Comparison of Satellite and UAV-Based Multispectral Imagery for Vineyard Variability Assessment. *Remote Sens.* 11, 436. <https://doi.org/10.3390/rs11040436>
- Knudby, A., 2021. Accuracy assessment.
- Kouassi, K.H., Konan-Waidhet, A.B., Yao, A.B., Koffi, B., Kadjo, E.D., 2020. Simulation of the Dynamics of Land Cover and Land Use in the Lobo River Watershed Upstream of Nibéhibé (Center-West of Côte d'Ivoire). *J. Geogr. Inf. Syst.* 12, 519–530. <https://doi.org/10.4236/jgis.2020.125030>
- Kromdijk, J., Głowacka, K., Leonelli, L., Gabilly, S.T., Iwai, M., Niyogi, K.K., Long, S.P., 2016. Improving photosynthesis and crop productivity by accelerating recovery from photoprotection. *Science* 354, 857–861. <https://doi.org/10.1126/science.aai8878>
- Laurent, J.-P., Ruelle, P., Delage, L., Zairi, A., Bechir, B.N., Adjmi, T., 2006. Monitoring Soil Water Content Profiles with a Commercial TDR System: Comparative Field Tests and Laboratory Calibration. *Vadose Zone J. - VADOSE ZONE J* 5. <https://doi.org/10.2136/vzj2006.0043L>
- Lawlor, D.W., 2002. Limitation to photosynthesis in water-stressed leaves: stomata vs. metabolism and the role of ATP. *Ann. Bot.* 89 Spec No, 871–885. <https://doi.org/10.1093/aob/mcf110>
- LE VIN EN BELGIQUE [WWW Document], n.d. . Vin Pays Herve. URL <https://www.vindupaysdeherve.be/un-peu-d-histoire> (accessed 5.3.24).
- Lebon, E., Pellegrino, A., Louarn, G., Jeremie, L., 2006. Branch Development Controls Leaf Area Dynamics in Grapevine (*Vitis vinifera*) Growing in Drying Soil. *Ann. Bot.* 98, 175–85. <https://doi.org/10.1093/aob/mcl085>
- Li, P., Jia, L., Lu, J., Jiang, M., Zheng, C., Menenti, M., 2024. Investigating the Response of Vegetation to Flash Droughts by Using Cross-Spectral Analysis and an Evapotranspiration-Based Drought Index. *Remote Sens.* 16, 1564. <https://doi.org/10.3390/rs16091564>

- Lillesaeter, O., 1982. Spectral reflectance of partly transmitting leaves: Laboratory measurements and mathematical modeling. *Remote Sens. Environ.* 12, 247–254. [https://doi.org/10.1016/0034-4257\(82\)90057-8](https://doi.org/10.1016/0034-4257(82)90057-8)
- Loggenberg, K., Strever, A., Greyling, B., Poona, N., 2018. Modelling Water Stress in a Shiraz Vineyard Using Hyperspectral Imaging and Machine Learning. *Remote Sens.* 10, 202. <https://doi.org/10.3390/rs10020202>
- Ma, X., Huete, A., Nguyen Tran, N., Bi, J., Gao, S., Zeng, Y., 2020. Sun-Angle Effects on Remote-Sensing Phenology Observed and Modelled Using Himawari-8. *Remote Sens.* 12, 1339. <https://doi.org/10.3390/rs12081339>
- Matese, A., Di Gennaro, S.F., Miranda, C., Berton, A., Santesteban, L.G., 2017. Evaluation of spectral-based and canopy-based vegetation indices from UAV and Sentinel 2 images to assess spatial variability and ground vine parameters. *Adv. Anim. Biosci.* 8, 817–822. <https://doi.org/10.1017/S2040470017000929>
- Matese, A., Toscano, P., Di Gennaro, S., Genesio, L., Vaccari, F., Primicerio, J., Claudio, B., Zaldei, A., Bianconi, R., Gioli, B., 2015. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sens.* 7, 2971–2990. <https://doi.org/10.3390/rs70302971>
- Matthews, M.A., Boyer, J.S., 1984. Acclimation of Photosynthesis to Low Leaf Water Potentials 1. *Plant Physiol.* 74, 161–166. <https://doi.org/10.1104/pp.74.1.161>
- Otkin, J.A., Zhong, Y., Hunt, E.D., Basara, J., Svoboda, M., Anderson, M.C., Hain, C., 2019. Assessing the Evolution of Soil Moisture and Vegetation Conditions during a Flash Drought–Flash Recovery Sequence over the South-Central United States. *J. Hydrometeorol.* 20, 549–562. <https://doi.org/10.1175/JHM-D-18-0171.1>
- Pádua, L., Marques, P., Hruška, J., Adão, T., Bessa, J., Sousa, A., Peres, E., Morais, R., Sousa, J.J., 2018. Vineyard properties extraction combining UAS-based RGB imagery with elevation data. *Int. J. Remote Sens.* 39, 5377–5401. <https://doi.org/10.1080/01431161.2018.1471548>
- Palazzi, F., Biddoccu, M., Borgogno Mondino, E.C., Cavallo, E., 2023a. Use of Remotely Sensed Data for the Evaluation of Inter-Row Cover Intensity in Vineyards. *Remote Sens.* 15, 41. <https://doi.org/10.3390/rs15010041>
- Palazzi, F., Biddoccu, M., Borgogno Mondino, E.C., Cavallo, E., 2023b. Use of Remotely Sensed Data for the Evaluation of Inter-Row Cover Intensity in Vineyards. *Remote Sens.* 15, 41. <https://doi.org/10.3390/rs15010041>
- Pinel, E.L., 2021. Suivi du statut hydrique de la vigne par télédétection hyper et multispectrale (phdthesis). Institut National Polytechnique de Toulouse - INPT.
- Poblete-Echeverría, C., Olmedo, G.F., Ingram, B., Bardeen, M., 2017. Detection and Segmentation of Vine Canopy in Ultra-High Spatial Resolution RGB Imagery Obtained from Unmanned Aerial Vehicle (UAV): A Case Study in a Commercial Vineyard. *Remote Sens.* 9, 268. <https://doi.org/10.3390/rs9030268>
- Pôças, I., Rodrigues, A., Gonçalves, S., Costa, P.M., Gonçalves, I., Pereira, L.S., Cunha, M., 2015. Predicting Grapevine Water Status Based on Hyperspectral Reflectance Vegetation Indices. *Remote Sens.* 7, 16460–16479. <https://doi.org/10.3390/rs71215835>
- Ramos, M.C., Pérez-Álvarez, E.P., Peregrina, F., Martínez de Toda, F., 2020. Relationships between grape composition of Tempranillo variety and available soil water and water stress under different weather conditions. *Sci. Hortic.* 262, 109063. <https://doi.org/10.1016/j.scienta.2019.109063>
- Rapaport, T., Hochberg, U., Shoshany, M., Karnieli, A., Rachmilevitch, S., 2015. Combining leaf physiology, hyperspectral imaging and partial least squares-regression (PLS-R) for grapevine water status assessment. *ISPRS J. Photogramm. Remote Sens.* 109, 88–97. <https://doi.org/10.1016/j.isprsjprs.2015.09.003>
- Remer, L., Wald, A., Kaufman, Y.J., 2001. Angular and seasonal variation of spectral surface reflectance ratios: Implications for the remote sensing of aerosol over land. *Geosci. Remote Sens. IEEE Trans. On* 39, 275–283. <https://doi.org/10.1109/36.905235>


- Remorini, D., Massai, R., 2003. Comparison of water status indicators for young peach trees. *Irrig. Sci.* 22, 39–46. <https://doi.org/10.1007/s00271-003-0068-4>
- Romero, M., Luo, Y., Su, B., Fuentes, S., 2018. Vineyard water status estimation using multispectral imagery from an UAV platform and machine learning algorithms for irrigation scheduling management. *Comput. Electron. Agric.* 147, 109–117. <https://doi.org/10.1016/j.compag.2018.02.013>
- Sassu, A., Gambella, F., Ghiani, L., Mercenaro, L., Caria, M., Pazzona, A.L., 2021. Advances in Unmanned Aerial System Remote Sensing for Precision Viticulture. *Sensors* 21, 956. <https://doi.org/10.3390/s21030956>
- Serrano, L., Gorchs, G., 2022. Water Availability Affects the Capability of Reflectance Indices to Estimate Berry Yield and Quality Attributes in Rain-Fed Vineyards. *Agronomy* 12, 2091. <https://doi.org/10.3390/agronomy12092091>
- Snapshot, n.d.
- Sokolova, M., Lapalme, G., 2009. A systematic analysis of performance measures for classification tasks. *Inf. Process. Manag.* 45, 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Sozzi, M., Kayad, A., Marinello, F., Taylor, J., Tisseyre, B., 2020. Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform. *OENO One* 54, 189–197. <https://doi.org/10.20870/oeno-one.2020.54.1.2557>
- SPW, n.d. Programme wallon de Développement Rural 2014-2020 - PwDR - Portail de l'agriculture wallonne [WWW Document]. *Agric. En Wallonie*. URL <http://agriculture.wallonie.be/cms/render/live/fr/sites/agriculture/home/politique-economie/programme-de-developpement-rural/politique-et-details-des-mesures/programme-wallon-de-developpement-rural-2014-2020.html> (accessed 10.13.23).
- Stolarski, O., Fraga, H., Sousa, J.J., Pádua, L., 2022. Synergistic Use of Sentinel-2 and UAV Multispectral Data to Improve and Optimize Viticulture Management. *Drones* 6, 366. <https://doi.org/10.3390/drones6110366>
- van Leeuwen, C., Vivin, P., 2008. Alimentation hydrique de la vigne et qualité des raisins.
- Vega, F.A., Ramírez, F.C., Saiz, M.P., Rosúa, F.O., 2015. Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. *Biosyst. Eng.* 132, 19–27. <https://doi.org/10.1016/j.biosystemseng.2015.01.008>
- Vélez, S., Poblete-Echeverría, C., Rubio, J.A., Vacas, R., Barajas, E., 2021. Estimation of Leaf Area Index in vineyards by analysing projected shadows using UAV imagery. *OENO One* 55, 159–180. <https://doi.org/10.20870/oeno-one.2021.55.4.4639>
- White, R.E., 2003. The Vine Root Habitat, in: White, R.E. (Ed.), *Soils for Fine Wines*. Oxford University Press, p. 0. <https://doi.org/10.1093/oso/9780195141023.003.0005>
- Williams, L., Araujo, F.J., 2002. Correlations among Predawn Leaf, Midday Leaf, and Midday Stem Water Potential and their Correlations with other Measures of Soil and Plant Water Status in *Vitis vinifera*. *J. Am. Soc. Hortic. Sci.* 127, 448–454. <https://doi.org/10.21273/JASHS.127.3.448>
- Zarco-Tejada, P.J., Berjón, A., López-Lozano, R., Miller, J.R., Martín, P., Cachorro, V., González, M.R., de Frutos, A., 2005. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sens. Environ.* 99, 271–287. <https://doi.org/10.1016/j.rse.2005.09.002>
- Zufferey, V., Verdenal, T., Dienes-Nagy, A., Belcher, S., Lorenzini, F., Koestel, C., Blackford, M., Bourdin, G., Gindro, K., Spangenberg, J.E., Rösti, J., Viret, O., Carlen, C., Changins, A., 2009. Effet du régime hydrique sur le comportement de la vigne et la qualité des vins de petite Arvine.

Annexes

Annexe A : Comparaison des réflectances entre le rang et l'inter-rang pour le NIR et le RedEdge



Annexe B : Gamme de valeur de potentiel trouver dans la surface d'un pixel Sentinel.



Annexe C : Résultat de la stepwise linear regression

Residuals:

| Min | 1Q | Median | 3Q | Max |
|-----------|-----------|----------|----------|----------|
| -0.273478 | -0.041183 | 0.002841 | 0.039949 | 0.314540 |


Coefficients:

| | Estimate | Std. Error | t value | Pr(> t) | |
|----------------------|------------|------------|---------|----------|-----|
| (Intercept) | -1.153e+01 | 2.484e+00 | -4.641 | 3.93e-06 | *** |
| srnirgreen | -1.702e+01 | 1.580e+00 | -10.768 | < 2e-16 | *** |
| nhi | 9.910e+01 | 6.607e+00 | 15.000 | < 2e-16 | *** |
| `B12-2022-07-29_10m` | -2.319e+01 | 3.892e+00 | -5.958 | 3.54e-09 | *** |
| lanthoc | -3.383e-02 | 3.247e-03 | -10.419 | < 2e-16 | *** |
| gndvi | -2.366e+02 | 2.326e+01 | -10.170 | < 2e-16 | *** |
| ndwi1 | 1.091e+02 | 8.297e+00 | 13.154 | < 2e-16 | *** |
| `B02-2022-07-29` | 2.338e+01 | 4.812e+00 | 4.859 | 1.37e-06 | *** |
| rtvicore | -2.802e-02 | 5.560e-03 | -5.038 | 5.58e-07 | *** |
| srnirred | 1.159e+01 | 1.234e+00 | 9.392 | < 2e-16 | *** |
| ndvi | 1.665e+02 | 2.113e+01 | 7.882 | 8.47e-15 | *** |
| ngrdi | -1.599e+02 | 2.363e+01 | -6.768 | 2.24e-11 | *** |
| evi | -7.127e+00 | 1.007e+00 | -7.077 | 2.78e-12 | *** |
| msi | 7.739e+00 | 1.165e+00 | 6.643 | 5.08e-11 | *** |
| redswir1 | -2.840e+01 | 4.436e+00 | -6.402 | 2.37e-10 | *** |
| ndti | -9.224e+00 | 1.696e+00 | -5.437 | 6.81e-08 | *** |
| exr | 4.058e+01 | 1.356e+01 | 2.993 | 0.00283 | ** |

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.07035 on 988 degrees of freedom
 Multiple R-squared: 0.8216, Adjusted R-squared: 0.8188
 F-statistic: 284.5 on 16 and 988 DF, p-value: < 2.2e-16

Annexe D : Résultat de l'unmixing.



Annexe E : bandes Sentinel-2

| Sentinel-2 Bands | Central Wavelength (µm) | Resolution (m) |
|-------------------------------|-------------------------|----------------|
| Band 1 - Coastal aerosol | 0.443 | 60 |
| Band 2 - Blue | 0.490 | 10 |
| Band 3 - Green | 0.560 | 10 |
| Band 4 - Red | 0.665 | 10 |
| Band 5 - Vegetation Red Edge | 0.705 | 20 |
| Band 6 - Vegetation Red Edge | 0.740 | 20 |
| Band 7 - Vegetation Red Edge | 0.783 | 20 |
| Band 8 - NIR | 0.842 | 10 |
| Band 8A - Vegetation Red Edge | 0.865 | 20 |
| Band 9 - Water vapour | 0.945 | 60 |
| Band 10 - SWIR - Cirrus | 1.375 | 60 |
| Band 11 - SWIR | 1.610 | 20 |
| Band 12 - SWIR | 2.190 | 20 |

Annexe F : Tableau reprenant les principaux indices utilisés pour détecter le potentiel hydrique.

Table 1 Spectral indices used in the present study calculated using MCA sensor set of bands

| Index | Equation | References |
|--|---|--|
| Chlorophyll absorption ratio | $CAR = \frac{[(R700 - R500) + 670 + R670 + (R550 - ((R700 - R500) + 670) + 550)]}{\sqrt{((R700 - R500) + 670)^2}}$ | Broge and Leblanc (2001) |
| Chlorophyll absorption ratio | $CAR1 = CAR * \frac{R700}{R670}$ | Kim et al. (1994); Broge and Leblanc (2001) |
| Greenness index | $GI = \frac{R550}{R670}$ | Zarco-Tejada et al. (2005a, b) |
| Green normalized difference vegetation index | $GNDVI = \frac{R800 - R550}{R800 + R550}$ | Gitelson and Merzlyak (1998) |
| Modified chlorophyll absorption in reflectance | $MCARI = [(R700 - R670) - 0.2 * (R700 - R550)] * (R700/R670)$ | Daughtry et al. (2000) |
| Modified chlorophyll absorption in reflectance | $MCARI1 = 1.2 * [2.5 * (R800 - R670) - 1.3 * (R800 - R550)]$ | Haboudane et al. (2004) |
| Modified chlorophyll absorption in reflectance | $MCARI2 = \frac{1.2 * [2.5 * (R800 - R670) - 1.3 * (R800 - R550)]}{\sqrt{(2 * R800 + 1)^2 - 6 * (R800 - 5 * R670) - 0.5}}$ | Haboudane et al. (2004) |
| Improved SAVI (soil-adjusted VI) with self-adjustment factor L | $MSAVI = \frac{1}{2} * \left(2 * R800 + 1 - \sqrt{(2 * R800 + 1)^2 - 8 * (R800 - R670)} \right)$ | Qi et al. (1994) |
| Modified simple ratio | $MSR = \frac{(R800/R670) - 1}{\sqrt{(R800/R670) + 1}}$ | Chen (1996) |
| Modified triangular VI | $MTVI3 = 1.2 * [1.2 * (R800 - R550) - 2.5 * (R670 - R550)]$ | Rodríguez-Pérez et al. (2007) |
| Normalized difference vegetation index | $NDVI = \frac{R800 - R670}{R800 + R670}$ | Rouse et al. (1974) |
| Optimized soil-adjusted vegetation index | $OSAVI = (1 + 0.16) * (R800 - R670) / (R800 + R670 + 0.16)$ | Rondeaux et al. (1996) |
| Simple ratio index | $SRI = \frac{R800}{R550}$ | Jordan (1969) |
| Photochemical reflectance index | $PRI = \frac{R530 - R570}{R530 + R570}$ | Fuentes et al. (2001); Gamon and Surfus (1999) |
| Renormalized difference VI | $RDVI = \frac{R800 - R670}{\sqrt{R800 + R670}}$ | Reujean and Breon (1995) |
| Transformed chlorophyll absorption in reflectance | $TCARI = 3 * [(R700 - R670) - 0.2 * (R700 - R550)] * (R700/R670)$ | Haboudane et al. (2002) |
| TCARI/OSAVI | $TCARI/OSAVI = \frac{3 * [(R700 - R670) - 0.2 * (R700 - R550)] * (R700/R670)}{(1 + 0.16) * (R800 - R670) / (R800 + R670 + 0.16)}$ | Haboudane et al. (2002) |

Source : (Pinel, 2021)

Annexe G : Valeurs de plusieurs comparaisons pour d'autres pistes envisagées

Corrélation entre Sentinel et mixte nadir/oblique

| Bleu | | | S2/mixte | S2/oblique | Mixte/oblique |
|---|-----------|----------|----------|------------|---------------|
| Comparaison sent/mixte/oblique coefficient de corrélation | Bousval | 27-07-22 | / | / | / |
| | | 10-08-22 | 0.638 | 0.769 | 0.837 |
| | | 31-08-22 | 0.66 | 0.81 | 0.88 |
| | Domaine W | 31-08-22 | 0.949 | 0.95 | 0.989 |
| Rouge | | | S2/mixte | S2/oblique | Mixte/oblique |
| Comparaison sent/mixte/oblique coefficient de corrélation Rouge | Bousval | 27-07-22 | / | / | / |
| | | 10-08-22 | 0.85 | 0.92 | 0.94 |
| | | 31-08-22 | 0.84 | 0.9 | 0.96 |
| | Domaine W | 31-08-22 | 0.96 | 0.979 | 0.986 |
| NIR | | | S2/mixte | S2/oblique | Mixte/oblique |
| Comparaison sent/mixte/oblique coefficient de corrélation | Bousval | 27-07-22 | / | / | / |
| | | 10-08-22 | 0.948 | 0.958 | 0.972 |
| | | 31-08-22 | 0.918 | 0.973 | 0.939 |
| | Domaine W | 31-08-22 | 0.94 | 0.958 | 0.96 |
| Vert | | | S2/mixte | S2/oblique | Mixte/oblique |
| Comparaison sent/mixte/oblique coefficient de corrélation | Bousval | 27-07-22 | / | / | / |
| | | 10-08-22 | 0.078 | 0.46 | 0.57 |
| | | 31-08-22 | 0.145 | 0.725 | 0.45 |
| | Domaine W | 31-08-22 | 0.95 | 0.97 | 0.98 |

Division de la parcelle

| Corrélation entre rang/inter pour parcelle divisée en 2 | Lieux | Date | Partie du haut | Partie du bas | Toute la parcelle |
|---|---------|----------|----------------|---------------|-------------------|
| Rouge | Bousval | 27-07-22 | 0.69 | 0.92 | 0.93 |
| | | 10-08-22 | 0.68 | 0.82 | 0.85 |
| | | 31-08-22 | 0.72 | 0.78 | 0.67 |
| | | 27-07-23 | 0.83 | 0.93 | 0.91 |
| | | 10-08-23 | 0.66 | 0.22 | 0.52 |
| | | 06-09-23 | 0.43 | 0.79 | 0.81 |
| Verte | Bousval | 27-07-22 | 0.69 | 0.81 | 0.77 |
| | | 10-08-22 | 0.12 | 0.33 | 0.22 |
| | | 31-08-22 | -0.22 | 0.4 | -0.15 |
| | | 27-07-23 | 0.56 | 0.82 | 0.66 |
| | | 10-08-23 | 0.42 | 0.6 | 0.67 |
| | | 06-09-23 | 0.63 | 0.76 | 0.75 |
| Bleue | Bousval | 27-07-22 | 0.19 | 0.52 | 0.22 |
| | | 10-08-22 | 0.27 | 0.43 | 0.25 |
| | | 31-08-22 | 0.35 | 0.26 | -0.13 |
| | | 27-07-23 | 0.72 | 0.92 | 0.87 |
| | | 10-08-23 | 0.13 | 0.34 | 0.12 |
| | | 06-09-23 | 0.53 | 0.78 | 0.69 |
| NIR | Bousval | 27-07-22 | 0.65 | 0.62 | 0.67 |
| | | 10-08-22 | 0.78 | 0.76 | 0.82 |
| | | 31-08-22 | 0.79 | 0.84 | 0.83 |
| | | 27-07-23 | 0.69 | 0.75 | 0.83 |
| | | 10-08-23 | 0.71 | 0.78 | 0.75 |
| | | 06-09-23 | 0.88 | 0.84 | 0.92 |
| RedEdge | Bousval | 27-07-22 | 0.61 | 0.59 | 0.56 |
| | | 10-08-22 | 0.84 | 0.82 | 0.86 |
| | | 31-08-22 | 0.25 | 0.27 | 0.29 |
| | | 27-07-23 | 0.7 | 0.78 | 0.84 |
| | | 10-08-23 | 0.69 | 0.67 | 0.6 |
| | | 06-09-23 | 0.88 | 0.91 | 0.96 |

Annexe H : Valeurs des signatures spectrales utilisées pour l'unmixing

| 27-07-22 | | | | | | | | |
|------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|--|
| rang | | | | | | | | |
| | GI | NDVI | OSAVI | Srbnir | Srrnir | msavi | savi | |
| haut | 3.191145773 | 0.874895593 | 0.789465272 | 18.44825204 | 16.07363856 | 1.256325634 | 0.69635282 | |
| bas | 3.830185382 | 0.907450759 | 0.852039454 | 20.4631743 | 20.7830093 | 1.355439877 | 0.784736489 | |
| all | 3.539712832 | 0.892652957 | 0.823596644 | 19.54730055 | 18.64238624 | 1.310387948 | 0.744562094 | |
| inter-rang | | | | | | | | |
| | GI | NDVI | OSAVI | Srbnir | Srrnir | msavi | savi | |
| haut | 1.214536673 | 0.669816462 | 0.509252778 | 9.597000942 | 5.436688421 | 0.855261801 | 0.380419792 | |
| bas | 2.415979774 | 0.862037409 | 0.702766981 | 17.91635551 | 15.14178657 | 1.085578288 | 0.558110339 | |
| all | 1.882005062 | 0.776605877 | 0.616760669 | 14.21886459 | 10.82840962 | 0.983215405 | 0.479136763 | |

| 20-07-23 | | | | | | | | |
|----------|------------|------------|------------|------------|------------|------------|------------|--|
| rang | | | | | | | | |
| | GI | NDVI | OSAVI | Srbnir | Srrnir | msavi | savi | |
| haut | 3.22490749 | 0.89339632 | 0.81270538 | 21.3986564 | 18.2165247 | 1.28755439 | 0.72414886 | |
| bas | 3.20779817 | 0.90125732 | 0.81677391 | 21.9998551 | 19.9438507 | 1.29409692 | 0.72413355 | |
| all | 3.21701088 | 0.89702447 | 0.81458317 | 21.6761327 | 19.0137521 | 1.29057402 | 0.72414179 | |
| inter | | | | | | | | |
| | GI | NDVI | OSAVI | Srbnir | Srrnir | msavi | savi | |
| haut | 2.56033563 | 0.87666669 | 0.73386291 | 21.5317316 | 16.3922749 | 1.13981185 | 0.59748032 | |
| bas | 2.98665261 | 0.90271003 | 0.75889921 | 25.0385522 | 21.7109625 | 1.17741544 | 0.62086912 | |
| all | 2.75709731 | 0.88868681 | 0.74541813 | 23.1502642 | 18.8470538 | 1.15716736 | 0.60827515 | |

Annexe I : Indices utilisés pour la stepwise

| index | | | | | |
|------------|-----------|----------|----------|-------------|-----------|
| SRnirred | srnirre1 | evi | B07 | tcari | lcaroc |
| SRnirgreen | clrededge | dvi | B08 | srbluere1 | B12 |
| MSR | lchloc | ndvire | vari | ari | B05 |
| gNDVI | sipi | rtvicore | ngrdi | nhi | B03 |
| NDWI2 | ndvi | mcari2 | gi | cive | B04 |
| NDVI | osavi | mtvi2 | gcc | lanthoc | msi |
| SIPI | evi2 | mcari1 | exg | tcari_osavi | B02 |
| OSAVI | msavi | mtvi1 | car | B11-2022-07 | srbluere3 |
| STI | rdvi | ndwi1 | srnirre3 | grvi | ndwi2 |
| NDTI | savi | sti | mcari | red/green | |
| Srnirblue | savi.1 | ndti | redswir1 | exr | |

Annexe J : Script python

Pour la modélisation de l'ombre :

```
##### fonction pour créer Les point des hauteur supérieur au seuil

# 1) Importer Le raster et remplacer Les valeurs inférieures à 0.5 par 0
raster_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpour mémoire/clip.tif'

def preprocess_raster(raster_path):
    dataset = gdal.Open(raster_path)
    raster_array = dataset.ReadAsArray()
    raster_array[raster_array < 1.9] = 0
    raster_transform = dataset.GetGeoTransform() # Obtenir La transformation géographique du raster
    return raster_array, raster_transform

# 2) Itérer sur chaque pixel du raster

def iterate_pixels(raster_array, raster_transform):
    rows, cols = raster_array.shape
    points = []

    for row in range(rows):
        for col in range(cols):
            if raster_array[row, col] > 0:
                # Convertir Les coordonnées du pixel en coordonnées géographiques (ou de projection)
                x, y = gdal.ApplyGeoTransform(raster_transform, col, row)
                # Créer Le point à partir des coordonnées converties
                points.append(Point(x, y, raster_array[row, col]))

    return points

def iterate_pixels(raster_array, raster_transform):
    rows, cols = raster_array.shape
    points = []

    for row in range(rows):
        for col in range(cols):
            if raster_array[row, col] > 0:
                # Appliquer La transformation géographique sur Les indices de ligne et de colonne
                x, y = raster_transform[0] + col * raster_transform[1] + row * raster_transform[2], \
                    raster_transform[3] + col * raster_transform[4] + row * raster_transform[5]
                # Créer Le point à partir des coordonnées converties et ajouter La valeur du pixel comme propriété
                point = Point(x, y)
                point.pixel_value = raster_array[row, col]
                points.append(point)
                #print(point.pixel_value)

    return points
```

```

output_points_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpour mémoire/points.shp'

# Prétraitement du raster
#raster_array = preprocess_raster(raster_path)
raster_array, raster_transform = preprocess_raster(raster_path)

# Itérer sur Les pixels du raster et extraire Les points d'entrée
#points = iterate_pixels(raster_array)
points = iterate_pixels(raster_array, raster_transform)

# Créer un schéma pour Les fichiers shapefile
schema = {'geometry': 'Point', 'properties': {}}

# Exporter Les points d'entrée vers un fichier Shapefile
with fiona.open(output_points_path, 'w', 'ESRI Shapefile', schema, crs=from_epsg(32631)) as output_points:
    for point in points:
        output_points.write({'geometry': {'type': 'Point', 'coordinates': (point.x, point.y)}, 'properties': {}})

```

```

#####fonction pour créer Les point d'ombre

# 3) Itérer sur tous Les points et créer de nouveaux points d'ombre
alpha_degrees = 55
beta = -36
beta_degrees = 90-beta
def generate_shadow_points(points, raster_array, raster_transform, alpha_degrees, beta_degrees):
    shadow_points = []

    for point in points:

        # Récupérer La valeur de hauteur à partir du tableau raster
        hauteur = point.pixel_value

        angle_beta = math.radians(beta_degrees)
        angle_alpha = math.radians(alpha_degrees)

        # Distance entre Les points divisée par La tangente de L'angle alpha
        shadow_distance = hauteur / math.tan(angle_alpha)
        #print(shadow_distance)

        # Coordonnées du nouveau point d'ombre
        shadow_x = point.x + shadow_distance * math.cos(angle_beta)
        shadow_y = point.y + shadow_distance * math.sin(angle_beta)

        # Créer un nouveau point d'ombre et L'ajouter à La Liste
        shadow_points.append(Point(shadow_x, shadow_y))

    return shadow_points

```

```

# Chemin vers Le raster
#raster_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/Lidar/bousval/CHM_clip_clip_Bousval_270722.tif'

# Chemin de sortie pour Les points d'entrée et Les points d'ombre
output_shadow_points_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpour mémoire/points_ombre.shp'

# Générer Les points d'ombre
shadow_points = generate_shadow_points(points, raster_array, raster_transform, alpha_degrees, beta_degrees)

# Créer un schéma pour Les fichiers shapefile
schema = {'geometry': 'Point', 'properties': {}}

# Exporter Les points d'ombre vers un fichier Shapefile
with fiona.open(output_shadow_points_path, 'w', 'ESRI Shapefile', schema, crs=from_epsg(32631)) as output_shadow_points:
    for shadow_point in shadow_points:
        output_shadow_points.write({'geometry': {'type': 'Point', 'coordinates': (shadow_point.x, shadow_point.y)}, 'properties': {}})

```

```

#### créer Les ligne d'ombre

from shapely.geometry import LineString
import fiona
from shapely.geometry import LineString, mapping
from fiona.crs import from_epsg

output_line_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpour mémoire/line.shp'

# Créer une liste de segments de droite
lines = []

# Parcourir Les points et Les points d'ombre correspondants
for point, shadow_point in zip(points, shadow_points):
    # Créer un segment de droite entre Le point et son point d'ombre correspondant
    line = LineString([point, shadow_point])
    # Ajouter Le segment à La liste des segments
    lines.append(line)

# Créer un schéma pour Les fichiers shapefile des lignes
schema_line = {'geometry': 'LineString', 'properties': {}}

# Exporter Les lignes vers un fichier Shapefile
with fiona.open(output_line_path, 'w', 'ESRI Shapefile', schema_line, crs=from_epsg(32631)) as output_lines:
    for line in lines:
        output_lines.write({'geometry': mapping(line), 'properties': {}})

# Maintenant, vous avez une liste de segments de droite. Vous pouvez Les utiliser comme vous Le souhaitez.

```

```

####créer une grille qui représente Le raster

import os
import ogr
import osr
from osgeo import gdal
# Chemin vers Le raster
raster_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/clip.tif'
# Chemin de sortie pour Le shapefile
output_shapefile_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/shapefile1.shp'
if os.path.exists(output_shapefile_path):
    print("Le fichier shapefile de sortie existe déjà.")
    print("Veuillez supprimer ou déplacer le fichier existant avant de continuer.")
    exit()
# Ouvrir Le raster
raster_ds = gdal.Open(raster_path)
raster_band = raster_ds.GetRasterBand(1)
rows, cols = raster_band.YSize, raster_band.XSize
geotransform = raster_ds.GetGeoTransform()
# Calculer La taille des cellules
cell_size_x = geotransform[1]
cell_size_y = abs(geotransform[5]) # La taille de La cellule en y est généralement négative
# Créer un shapefile de polygones
driver = ogr.GetDriverByName('ESRI Shapefile')
output_ds = driver.CreateDataSource(output_shapefile_path)
spatial_ref = osr.SpatialReference()
spatial_ref.ImportFromWkt(raster_ds.GetProjectionRef())
layer = output_ds.CreateLayer('grid', srs=spatial_ref)
print(layer)
field_defn = ogr.FieldDefn('value', ogr.OFTString) # Utiliser OFTString pour stocker Les valeurs en tant que chaînes de caractères
layer.CreateField(field_defn)
# Convertir Le raster en polygones
for row in range(rows):
    for col in range(cols):
        # Calculer Les coordonnées des coins de La cellule
        x_min = geotransform[0] + col * cell_size_x
        x_max = x_min + cell_size_x
        y_max = geotransform[3] - row * cell_size_y # Inverser La direction y
        y_min = y_max - cell_size_y

        # Récupérer La valeur du pixel correspondant dans Le raster
        pixel_value = raster_band.ReadAsArray(col, row, 1, 1)[0][0]

        # Convertir La valeur du pixel en chaîne de caractères
        pixel_value_str = str(pixel_value)

        # Créer Le polygone
        ring = ogr.Geometry(ogr.wkbLinearRing)
        ring.AddPoint(x_min, y_min)
        ring.AddPoint(x_max, y_min)
        ring.AddPoint(x_max, y_max)
        ring.AddPoint(x_min, y_max)
        ring.AddPoint(x_min, y_min) # Fermer Le polygone
        poly = ogr.Geometry(ogr.wkbPolygon)
        poly.AddGeometry(ring)

        # Créer La feature et L'ajouter à La couche
        feature_defn = layer.GetLayerDefn()
        feature = ogr.Feature(feature_defn)
        feature.SetGeometry(poly)
        feature.SetField('value', pixel_value_str) # Assigner La valeur du pixel à La cellule de La grille en tant que chaîne de caractères
        layer.CreateFeature(feature)
        feature = None

```

```

#### sélectionner Les cellules croiser par Les ligne d'ombre ####

import geopandas as gpd

# Chemin vers Le shapefile de La grille
grid_shapefile_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/shapefile1.shp'
# Chemin vers Le shapefile contenant vos lignes
lines_shapefile_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/line.shp'
# Chemin de sortie pour Le nouveau shapefile
output_shapefile_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/shapefile_ombre.shp'

# Charger Le shapefile de La grille
grid = gpd.read_file(grid_shapefile_path)

# Charger Le shapefile contenant vos lignes
lines = gpd.read_file(lines_shapefile_path)

# Créer une liste pour stocker Les cellules interceptées
intercepted_cells = []
# Initialiser Le compteur d'itérations
# Compteur d'itérations
iteration_count = 0

# Parcourir chaque cellule de La grille
# Parcourir chaque cellule de La grille
for index, cell in grid.iterrows():
    # Vérifier si La cellule est interceptée par au moins une des lignes
    if any(cell.geometry.intersects(line.geometry) for _, line in lines.iterrows()):
        intercepted_cells.append(cell)

    # Incrémenter Le compteur d'itérations
    iteration_count += 1

    # Afficher Le nombre d'itérations jusqu'à présent
    print(f"Iteration {iteration_count}")

# Créer un GeoDataFrame à partir des cellules interceptées
intercepted_cells_gdf = gpd.GeoDataFrame(intercepted_cells, crs=grid.crs)

# Enregistrer Le nouveau shapefile contenant Les cellules interceptées
intercepted_cells_gdf.to_file(output_shapefile_path)

```

```

##### sélectionner Les cellules inférieure à La hauteur de La canopée

import geopandas as gpd

# Chemin vers Le shapefile précédent contenant toutes Les cellules interceptées
input_shapefile_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/shapefile_ombre.shp'
# Chemin de sortie pour Le nouveau shapefile contenant Les cellules inférieures au seuil
output_shapefile_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/lidar/bousval/testpouremémoire/nouveau_shapefile_inf_seuil.shp'
# Seuil
seuil = 0.5 # Remplacez par votre seuil

# Charger Le shapefile précédent
intercepted_cells_gdf = gpd.read_file(input_shapefile_path)

# Créer une liste pour stocker Les entités inférieures au seuil
cells_below_threshold = []
iteration_count = 0
# Parcourir chaque entité du shapefile précédent
for index, cell in intercepted_cells_gdf.iterrows():
    # Extraire La valeur associée à cette cellule (vous devez avoir une colonne contenant Les valeurs)
    cell_value_str = cell['value'] # Remplacez 'value' par Le nom de votre colonne contenant Les valeurs
    # Convertir La valeur en nombre
    cell_value = float(cell_value_str)
    # Vérifier si La valeur est inférieure au seuil
    if cell_value < seuil:
        # Ajouter cette entité à La liste
        cells_below_threshold.append(cell)
    # Incrémenter Le compteur d'itérations
    iteration_count += 1

    # Afficher Le nombre d'itérations jusqu'à présent
    if iteration_count % 2 == 0:
        print(f"Iteration {iteration_count}")
# Créer un GeoDataFrame à partir des entités inférieures au seuil
cells_below_threshold_gdf = gpd.GeoDataFrame(cells_below_threshold, crs=intercepted_cells_gdf.crs)

# Enregistrer Le nouveau shapefile contenant Les entités inférieures au seuil
cells_below_threshold_gdf.to_file(output_shapefile_path)

```

Pour transformer la classification SCP en masque shapefile (car trop lourd pour qgis)

```
from osgeo import gdal, ogr
import pandas as pd
import fiona

##### couper pour supprimer la vigne

import rasterio
from rasterio import mask

# Chemin vers Le raster d'entrée
input_raster = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/classif.tif"

# Chemin vers Le shapefile de découpe
cutline_shapefile = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/rang/W/Rangs DomaineW/grande_zone/20220831/interang/interang.shp"

# Chemin de sortie pour Le raster clipé
output_raster = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/classif_clip_inter.tif"

# Ouvrir Le shapefile de découpe
with fiona.open(cutline_shapefile, "r") as shapefile:
    shapes = [feature["geometry"] for feature in shapefile]

# Ouvrir Le raster d'entrée
with rasterio.open(input_raster) as src:
    # Découper Le raster en utilisant Le shapefile de découpe
    out_image, out_transform = mask.mask(src, shapes, crop=True) ##### ATTENTION, C'EST L'INVERSE DU SHAPFILE QUI EST PRIX ICI #####
    ##### crop = True pour prendre ce qu'il y a en dessous #####

# Écrire Le raster découpé dans un fichier
with rasterio.open(output_raster, "w", **src.meta) as dest:
    dest.write(out_image)
```

```
### reclassifier pour ne prendre en compte que Les pixel d'ombre

import numpy as np
from osgeo import gdal

# Chemin vers votre raster clipé
input_raster = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/classif.tif"

# Chemin de sortie pour Le raster reclassifié
output_raster = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/classif_reclass.tif"

# Ouvrir Le raster clipé
input_ds = gdal.Open(input_raster)

# Lire Les données du raster
data = input_ds.ReadAsArray()

# Reclassifier Les valeurs
data_reclassed = np.where(data == 2, np.nan, data)

# Créer un nouveau fichier raster avec Les valeurs reclassifiées
driver = gdal.GetDriverByName("GTiff")
output_ds = driver.Create(output_raster, input_ds.RasterXSize, input_ds.RasterYSize, 1, gdal.GDT_Float32)
output_ds.SetProjection(input_ds.GetProjection())
output_ds.SetGeoTransform(input_ds.GetGeoTransform())
output_ds.GetRasterBand(1).WriteArray(data_reclassed)

# Fermer Les datasets
input_ds = None
output_ds = None
```

```

#itérer sur La grille pour diminuer Les taille de r.to.vect

from osgeo import gdal, ogr
# Chemin vers votre raster
input_raster = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/classif_reclass.tif"
# Chemin vers votre grille shapefile
shapefile = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/pixels_w_10_mètre.shp"
# Dossier de sortie pour Les fichiers raster extraits
output_folder = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/shadow_par_cellule"
# Ouvrir Le raster
raster_ds = gdal.Open(input_raster)

# Ouvrir La grille shapefile
shapefile_ds = ogr.Open(shapefile)
layer = shapefile_ds.GetLayer()

# Créer Le dossier de sortie s'il n'existe pas
if not os.path.exists(output_folder):
    os.makedirs(output_folder)

# Obtenir Les informations de transformation du raster
transform = raster_ds.GetGeoTransform()

# Boucle à travers chaque feature de La grille shapefile
for index, feature in enumerate(layer):
    # Extraire La géométrie de La feature
    geom = feature.GetGeometryRef()

    # Obtenir Les coordonnées de L'enveloppe de La feature
    minX, maxX, minY, maxY = geom.GetEnvelope()

    # Calculer Les indices des pixels pour L'enveloppe
    ulX, ulY = int((minX - transform[0]) / transform[1]), int((maxY - transform[3]) / transform[5])
    lrX, lrY = int((maxX - transform[0]) / transform[1]), int((minY - transform[3]) / transform[5])

    # Lire Les données raster pour La cellule
    data = raster_ds.ReadAsArray(ulX, ulY, lrX - ulX + 1, lrY - ulY + 1)

    # Vérifier si Les données ont été lues avec succès
    if data is not None:
        # Vérifier La dimension de La matrice
        if len(data.shape) != 2:
            # Si La dimension n'est pas 2, convertir La matrice en 2D
            data = data[0]

        # Définir Le nom de fichier de sortie
        output_filename = os.path.join(output_folder, f"raster_cell_{index}.tif")

        # Créer Le fichier de sortie
        driver = gdal.GetDriverByName("GTiff")
        output_ds = driver.Create(output_filename, lrX - ulX + 1, lrY - ulY + 1, 1, gdal.GDT_Float32)
        output_ds.SetProjection(raster_ds.GetProjection())
        output_ds.SetGeoTransform((minX, transform[1], 0, maxY, 0, transform[5]))
        output_ds.GetRasterBand(1).WriteArray(data)
        output_ds.GetRasterBand(1).SetNoDataValue(1) # Définir La valeur nodata
        output_ds = None

        print(f'Raster clip créé : {output_filename}')
    else:
        print("Erreur: Impossible de lire les données raster pour la cellule.")

# Fermer Les datasets
raster_ds = None
shapefile_ds = None

```

```

#transformer chaque raster en shapefile
import os
import rasterio
from rasterio.features import shapes
from shapely.geometry import shape, mapping
from fiona import collection

# Chemin vers Le dossier contenant Les rasters créés
raster_folder = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/shadow_par_cellule"

# Chemin vers Le dossier où vous souhaitez enregistrer Les shapefiles
shapefile_output_folder = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/shadow_shapefiles_par_cellules"

# Créer Le dossier de sortie s'il n'existe pas
if not os.path.exists(shapefile_output_folder):
    os.makedirs(shapefile_output_folder)

# Dictionnaire pour mapper Les valeurs de pixel aux classes
class_mapping = {
    1: "Classe_1",
}

# Itérer à travers Les fichiers raster dans Le dossier
for filename in os.listdir(raster_folder):
    if filename.endswith(".tif"):
        # Ouvrir Le raster avec rasterio
        with rasterio.open(os.path.join(raster_folder, filename)) as src:
            # Lire Les valeurs du raster
            image = src.read(1)

            # Transformer Les valeurs de pixel en polygones
            mask = image != 0
            shapes_result = list(shapes(image, mask=mask, transform=src.transform))

            # Créer un fichier shapefile pour Les polygones
            schema = {
                "geometry": "Polygon",
                "properties": {"class": "str"}
            }
            with collection(
                os.path.join(shapefile_output_folder, f"{os.path.splitext(filename)[0]}.shp"),
                "w",
                "ESRI Shapefile",
                schema
            ) as output:
                for i, (geom, val) in enumerate(shapes_result):
                    # Mapper La valeur de pixel à une classe
                    class_value = class_mapping.get(val, "Inconnu")
                    output.write({
                        "geometry": mapping(shape(geom)),
                        "properties": {"class": class_value}
                    })

print('ok')

```

```

#merge mon shapefile

import geopandas as gpd
import os

# Chemin vers Le dossier contenant Les shapefiles
folder_path = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/shadow_shapefiles_par_cellules"

# Liste pour stocker Les données de tous Les shapefiles
gdfs = []

# Itérer sur chaque fichier shapefile dans Le dossier
for filename in os.listdir(folder_path):
    if filename.endswith(".shp"):
        # Lire Le shapefile et L'ajouter à La Liste
        filepath = os.path.join(folder_path, filename)
        gdf = gpd.read_file(filepath)
        gdfs.append(gdf)

# Fusionner tous Les GeoDataFrames en un seul
merged_gdf = gpd.GeoDataFrame(pd.concat(gdfs, ignore_index=True), crs=gdfs[0].crs)

# Chemin de sortie pour Le fichier shapefile fusionné
output_path = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/merged_shapefile.shp"

# Écrire Le GeoDataFrame fusionné au format shapefile
merged_gdf.to_file(output_path)

print("Fusion de tous les shapefiles terminée.")

```

Fusion de tous les shapefiles terminée.

```

#selectionner L'ombre

import geopandas as gpd

# Chemin vers Le fichier shapefile fusionné
input_path = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/merged_shapefile.shp"

# Lire Le fichier shapefile fusionné
merged_gdf = gpd.read_file(input_path)

# Filtrer Les entités pour ne garder que celles de La classe "classe_1"
class_1_gdf = merged_gdf[merged_gdf["class"] == "Classe_1"]

# Chemin de sortie pour Le nouveau fichier shapefile
output_path = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shadow/dw/20230810/class1_shapefile.shp"

# Écrire Le GeoDataFrame filtré au format shapefile
class_1_gdf.to_file(output_path)

print("Création du nouveau shapefile 'class1_shapefile.shp' terminée.")

```

Réchantillonné à 10 m :

```
import rasterio
from rasterio.enums import Resampling
from rasterio.transform import from_origin
from rasterio.transform import Affine
import numpy as np
# Chemin d'accès au raster d'origine
input_raster_path = output_raster_path_clip
# Chemin d'accès au raster redimensionné (à enregistrer)
output_raster_path = output_raster_path_20m

# Facteur d'aggrégation (de 10 par 10 à 20 par 20)
aggregation_factor = 2

# Ouvrir Le raster d'origine
with rasterio.open(input_raster_path) as src:
    # Récupérer Les métadonnées du raster d'origine
    profile = src.profile

    # Dimensions du raster d'origine
    orig_width = src.width
    orig_height = src.height

    # Dimensions du raster redimensionné
    new_width = orig_width // aggregation_factor
    new_height = orig_height // aggregation_factor

    # Redimensionner Les métadonnées
    new_transform = Affine(src.transform.a * aggregation_factor, src.transform.b, src.transform.c,
                          src.transform.d, src.transform.e * aggregation_factor, src.transform.f)
    profile.update(width=new_width, height=new_height, transform=new_transform)

# Ouvrir Le raster redimensionné en mode écriture
with rasterio.open(output_raster_path, 'w', **profile) as dst:
    # Parcourir Le raster d'origine en agrégeant Les pixels
    for i in range(0, orig_height, aggregation_factor):
        for j in range(0, orig_width, aggregation_factor):
            # Lire Les valeurs des 4 pixels
            window = src.read(window=((i, i + aggregation_factor), (j, j + aggregation_factor)))

            # Calculer La moyenne des valeurs des 4 pixels
            aggregated_value = window.mean()

            # Convertir La valeur agrégée en uint16
            aggregated_value_uint16 = np.uint16(aggregated_value)

            # Créer une matrice contenant La valeur agrégée pour chaque bande
            aggregated_matrix = np.full((profile['count'], 1, 1), aggregated_value_uint16, dtype=np.uint16)

            # Écrire La valeur agrégée dans Le raster redimensionné
            dst.write(aggregated_matrix, window=((i // aggregation_factor, (i + aggregation_factor) // aggregation_factor),
                                                (j // aggregation_factor, (j + aggregation_factor) // aggregation_factor)))

print("Raster redimensionné enregistré avec succès.")
```

```
import rasterio
from rasterio.enums import Resampling

# Chemin du raster d'entrée et de sortie
input_raster = output_raster_path_20m
output_raster = output_raster_path_10m

# Facteur de division de La taille des pixels
scale_factor = 0.5 # Nous allons diviser La taille des pixels par ce facteur

with rasterio.open(input_raster) as src:
    # Lecture des métadonnées du raster d'entrée
    profile = src.profile

    # Calcul des nouvelles dimensions du raster de sortie
    new_width = src.width * 2
    new_height = src.height * 2

    # Calcul de La transformation pour Le raster de sortie avec une résolution accrue
    transform = rasterio.Affine(src.transform.a / 2, src.transform.b, src.transform.c,
                                src.transform.d, src.transform.e / 2, src.transform.f)

    # Mise à jour des métadonnées du raster de sortie
    profile.update(width=new_width, height=new_height, transform=transform)

    # Rééchantillonnage du raster d'entrée pour obtenir Le raster de sortie
    with rasterio.open(output_raster, 'w', **profile) as dst:
        dst.write(src.read(
            out_shape=(src.count, new_height, new_width),
            resampling=Resampling.bilinear
        ))

print("Raster upscaled avec succès.")
```

Calculer les Indices et sortir les statistiques

```
from osgeo import gdal, ogr
import pandas as pd
import fiona
import geopandas as gpd
import rasterio
from rasterio import mask
from rasterio.mask import mask
from shapely.geometry import mapping
import numpy as np
import os
```

```
...
...
```

```
input_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/Image drone/2022/Bousval/mixte'
output_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/unmixing/indice'
grille_path = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/pixels_bousval_10_mètre.shp"
grille_path = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/pixels_w_10_mètre.shp"
grille_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/Parcelle/W/grille_louis_20230906.shp'
#rang_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/rang/bousval/Rangs Bousval/grande_zone/rang_bousval_20220727.shp'
#rang_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/rang/RowsInterrows/RowBousval060923.shp'
#rang_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/rang/W/Rangs DomaineW/grande_zone/20220831/rang/DomaineW_20220831_ALL_ParcelLe_Mask.shp'
#rang_path = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/rang/RowsInterrows/RowDomaineW060923.shp'
#20220727 20220810 20220831 20230720 20230810 20230906 W20220831 W20230906
date = 'W20230906'
indice = 'ndwil'
raster_folder = os.path.join(input_path, f"{date}/")
print(raster_folder)
raster_folder_unmixing = os.path.join(output_path, f"{date}/")
print(raster_folder_unmixing)
raster_folder_unmixing_indice = os.path.join(output_path, f"{date}/{indice}/")
print(raster_folder_unmixing_indice)
excel_mean = os.path.join(output_path, f"{date}/{indice}/mean.xlsx")
print(excel_mean)
rang_path = os.path.join('C:/Users/sillis/OneDrive/Documents/Unif/mémoire/shapefile/rang/rang/{date}.shp')
print(rang_path)
dossier_vers_excel = os.path.join(output_path, f"{indice}/")
print(dossier_vers_excel)
if not os.path.exists(dossier_vers_excel):
    # Créer Le dossier s'il n'existe pas
    os.makedirs(dossier_vers_excel)

excel_mean_ok = os.path.join(output_path, f"{indice}/mean_{indice}_{date}.xlsx")
print(excel_mean_ok)
```

```
import os
from osgeo import gdal

# Chemin vers Le dossier contenant Les rasters

# Liste pour stocker Les chemins des rasters correspondants
blue_path = None
clred_path = None
green_path = None
savi_path = None
ari_path = None
re_path = None
nir_path = None
red_path = None

# Parcours des fichiers dans Le dossier
for file in os.listdir(raster_folder_unmixing):
    # Vérification si Le fichier correspond au raster blue
    if "blue" in file and file.endswith(".tif"):
        blue_path = os.path.join(raster_folder_unmixing, file)
        print(blue_path)
    # Vérification si Le fichier correspond au raster red
    elif "CL" in file:
        clred_path = os.path.join(raster_folder_unmixing, file)
        print(clred_path)

    elif "green" in file and file.endswith(".tif"):
        green_path = os.path.join(raster_folder_unmixing, file)
        print(green_path)

    elif "SAVI" in file and file.endswith(".tif"):
        savi_path = os.path.join(raster_folder_unmixing, file)
        print(savi_path)

    elif "ARI" in file and file.endswith(".tif"):
        ari_path = os.path.join(raster_folder_unmixing, file)
        print(ari_path)

    elif "red edge" in file and file.endswith(".tif"):
        re_path = os.path.join(raster_folder_unmixing, file)
        print(re_path)

    elif "nir" in file and file.endswith(".tif"):
        nir_path = os.path.join(raster_folder_unmixing, file)
        print(nir_path)

    elif "red." in file and file.endswith(".tif"):
        red_path = os.path.join(raster_folder_unmixing, file)
        print(red_path)
```

```

# Chargement des rasters s'ils ont été trouvés
if blue_path:
    blue = gdal.Open(blue_path)
else:
    print("Raster blue introuvable dans le dossier spécifié.")

if clred_path:
    clred = gdal.Open(clred_path)
else:
    print("Raster red introuvable dans le dossier spécifié.")

if green_path:
    green = gdal.Open(green_path)
else:
    print("Raster green introuvable dans le dossier spécifié.")

if savi_path:
    savi = gdal.Open(savi_path)
else:
    print("Raster savi introuvable dans le dossier spécifié.")

if ari_path:
    ari = gdal.Open(ari_path)
else:
    print("Raster ari introuvable dans le dossier spécifié.")

if re_path:
    re = gdal.Open(re_path)
else:
    print("Raster ari introuvable dans le dossier spécifié.")

if nir_path:
    nir = gdal.Open(nir_path)
else:
    print("Raster ari introuvable dans le dossier spécifié.")

if red_path:
    red = gdal.Open(red_path)
else:
    print("Raster ari introuvable dans le dossier spécifié.")

```

```

if not os.path.exists(raster_folder_unmixing_indice):
    os.makedirs(raster_folder_unmixing_indice)
# Chemin vers Le dossier contenant Les rasters
# Lecture des rasters chargés précédemment
blue_band = blue.GetRasterBand(1)
#clred_band = clred.GetRasterBand(1)
green_band = green.GetRasterBand(1)
#savi_band = savi.GetRasterBand(1)
#ari_band = ari.GetRasterBand(1)
red_band = red.GetRasterBand(1)
nir_band = nir.GetRasterBand(1)
re_band = re.GetRasterBand(1)
# Lecture des données de chaque bande
blue_data = blue_band.ReadAsArray()
#clred_data = clred_band.ReadAsArray()
green_data = green_band.ReadAsArray()
#savi_data = savi_band.ReadAsArray()
#ari_data = ari_band.ReadAsArray()
red_data = red_band.ReadAsArray()
nir_data = nir_band.ReadAsArray()
re_data = re_band.ReadAsArray()
# Calcul du nouveau raster en additionnant Les valeurs des bandes
#stepwise = -1.780491 + (0.832711 * clred_data) + (7.86664 * green_data) + (-1.411018 * savi_data) + (0.014327 * ari_data) + (6.646016 * blue_data)
#stepwise2 = -1.5604 + (0.0011 * clred_data) + (7.9859 * green_data) + (-1.35638 * savi_data) + (0.009172 * ari_data)
#CLRedEdge = (nir_data/re_data)-1
#SAVI = (nir_data-red_data)/(nir_data+red_data+0.5)*(1+0.5)
#ari = (1/green_data)-(1/re_data)
#TCARI = 3*((re_data-red_data)-0.2*(re_data-green_data)*(re_data/red_data))#
#OSAVI = (1+0.16)*(nir_data-red_data)/(nir_data+red_data+0.16)
#NDRE = (nir_data-re_data)/(nir_data+re_data)
#EXR = (1.4 * red_data - green_data) / (red_data + green_data + blue_data)
#TCARI_OSAVI = TCARI/OSAVI
#stepwiseoLiver = 1.3 + 10.26 * (TCARI_OSAVI) * (TCARI_OSAVI) - 0.73*(1/NDRE) + 0.025*(1/EXR)
#srnirgreen = nir_data/green_data
#srnirred = nir_data/red_data
#OSAVI = (1+0.16)*(nir_data-red_data)/(nir_data+red_data+0.16)
#NDVI = (nir_data-red_data)/(nir_data+red_data)
#msr = ((nir_data / red_data) - 1) / np.sqrt((nir_data / red_data) + 1)
#exg = (2*green_data-red_data-blue_data)
#ani = (1/green_data)-(1/nir_data)
#greenratio = 1/green_data
#sipi = (nir_data - blue_data)/(nir_data + red_data)
#osavi = (1+0.16)*(nir_data-red_data)/(nir_data+red_data+0.16)
srnirblue = nir_data/blue_data
ndwil = (green_data-nir_data)/(green_data+nir_data)
# Création d'un nouveau fichier raster avec Les mêmes propriétés que Les rasters d'entrée
driver = gdal.GetDriverByName('GTiff')
output_raster_path = os.path.join(raster_folder_unmixing_indice, f"{indice}.tif")
output_raster = driver.Create(output_raster_path, blue.RasterXSize, blue.RasterYSize, 1, gdal.GDT_Float32)
print(output_raster_path)
print(output_raster)
# Copie des informations géoréférencées et de projection du raster d'entrée
output_raster.SetProjection(blue.GetProjection())
output_raster.SetGeoTransform(blue.GetGeoTransform())

# Écriture des données dans La bande du nouveau raster
output_band = output_raster.GetRasterBand(1)
indices = eval(indice)
output_band.WriteArray(indices)

```

```
#####rang/inter#####u

# Ouvrir Le shapefile de découpe
with fiona.open(rang_path, "r") as shapefile:
    shapes = [feature["geometry"] for feature in shapefile]

with rasterio.open(os.path.join(raster_folder_unmixing_indice, f'{indice}.tif')) as src:
    # Découper Le raster en fonction du shapefile
    out_image, out_transform = mask(src, shapes, crop=True, invert = False)
    out_meta = src.meta.copy()

    # Mettre à jour Les métadonnées pour Le nouveau raster découpé
    out_meta.update({"driver": "GTiff",
                    "height": out_image.shape[1],
                    "width": out_image.shape[2],
                    "transform": out_transform})

    # Écrire Le nouveau raster découpé dans un fichier
    output_filename = os.path.join(raster_folder_unmixing_indice, f'{indice}_rang.tif')
    with rasterio.open(output_filename, "w", **out_meta) as dest:
        dest.write(out_image)

    print(f"Raster découpé enregistré : {output_filename}")

with rasterio.open(os.path.join(raster_folder_unmixing_indice, f'{indice}.tif')) as src:
    # Découper Le raster en fonction du shapefile
    out_image, out_transform = mask(src, shapes, crop=False, invert = True)
    out_meta = src.meta.copy()

    # Mettre à jour Les métadonnées pour Le nouveau raster découpé
    out_meta.update({"driver": "GTiff",
                    "height": out_image.shape[1],
                    "width": out_image.shape[2],
                    "transform": out_transform})

    # Écrire Le nouveau raster découpé dans un fichier
    output_filename = os.path.join(raster_folder_unmixing_indice, f'{indice}_inter.tif')
    with rasterio.open(output_filename, "w", **out_meta) as dest:
        dest.write(out_image)

    print(f"Raster découpé enregistré : {output_filename}")
```

```
import os
import rasterio
import numpy as np
import pandas as pd
import geopandas as gpd
from rasterio.features import geometry_window

# Chemin vers Le dossier contenant Les rasters créés
raster_folder = raster_folder_unmixing_indice

# Chemin vers Le fichier shapefile de La grille
shapefile_path = grille_path

# Créer une liste pour stocker Les moyennes de pixels
data = []

# Charger Le shapefile de La grille
grid = gpd.read_file(shapefile_path)

# Itérer sur chaque raster dans Le dossier
for filename in os.listdir(raster_folder):
    if filename.endswith(".tif"):
        raster_path = os.path.join(raster_folder, filename)
        raster_name = os.path.splitext(filename)[0]

        # Ouvrir Le raster avec rasterio
        with rasterio.open(raster_path) as src:
            # Itérer sur chaque cellule de La grille
            for index, cell in grid.iterrows():
                # Récupérer La géométrie de La cellule
                cell_geometry = cell.geometry

                # Calculer La fenêtre correspondant à La géométrie de La cellule
                window = geometry_window(src, [cell_geometry])

                # Lire Les valeurs des pixels dans La fenêtre
                raster_data = src.read(window=window, masked=True)

                # Exclure Les pixels ayant une valeur de zéro
                raster_data = np.ma.masked_where(raster_data == 0, raster_data)
                raster_data = np.ma.masked_where(raster_data == -19998.5, raster_data)
                # Calculer La moyenne des valeurs des pixels non nuls
                if raster_data.count() > 0:
                    average_pixel_value = np.mean(raster_data)
                else:
                    average_pixel_value = np.nan # Si tous Les pixels sont zéro, assigner NaN

                # Ajouter Les informations à La liste de données
                data.append({"Raster": raster_name, "Cell_ID": cell["id"], "Mean_Pixel_Value": average_pixel_value})

# Créer un DataFrame à partir des données
df = pd.DataFrame(data)

# Pivoter Le DataFrame pour avoir une colonne par raster
pivot_df = df.pivot(index="Cell_ID", columns="Raster", values="Mean_Pixel_Value").reset_index()

# Afficher Le DataFrame pivoté
print(pivot_df)
```

```

# Specify the name of the excel file
file_name = excel_mean
#file_name = excel_mean
# saving the excelsheet
pivot_df.to_excel(file_name)

# Chemin vers votre fichier Excel
mean = excel_mean
#mean = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/unmixing/indice/step/mean.xlsx'
fid = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/test.xlsx"
fid = "C:/Users/sillis/OneDrive/Documents/Unif/mémoire/testw.xlsx"
# Charger Le fichier Excel dans un DataFrame en utilisant openpyxl
df1 = pd.read_excel(mean, engine='openpyxl')
df2 = pd.read_excel(fid, sheet_name=1, engine='openpyxl')

# Fusionner Les deux DataFrames sur La colonne "id" dans df1 et "FID" dans df2
merged_df = pd.merge(df2, df1, how='left', left_on='FID', right_on='Cell_ID')
merged_df = merged_df.dropna()
# Afficher Le DataFrame fusionné
print(merged_df)
os.remove(mean)
#file_name = excel_mean_ok
file_name = excel_mean_ok
merged_df.to_excel(file_name)

```

Linear Spectral Unmixing

```

import numpy as np
from osgeo import gdal

# Définir Les valeurs moyennes des indices pour Les endmembers
# Remplacez ces valeurs par Les moyennes que vous avez obtenues
mean_indices_rang = np.array([3.217010877, 0.897024472, 0.814583165, 21.67613274, 19.01375212, 1.290574018, 0.724141795])
mean_indices_inter = np.array([2.757097313, 0.888686808, 0.745418127, 23.15026423, 18.84705378, 1.157167357, 0.608275148])

# Fonction pour Le mélange spectral Linéaire
def linear_spectral_unmixing(input_image, endmember1, endmember2):
    # Initialiser Le tableau de résultats
    rows, cols, bands = input_image.shape
    abundance_maps = np.zeros((rows, cols, 2)) # 2 endmembers

    # Préparer Les matrices d'endmembers
    endmembers = np.vstack((endmember1, endmember2))

    # Pour chaque pixel dans L'image
    for i in range(rows):
        for j in range(cols):
            # Extraire Le vecteur spectral du pixel
            pixel_spectrum = input_image[i, j, :]

            # Calculer Les fractions d'abondance par mélange spectral Linéaire
            # (Utilisation de La formule des moindres carrés)
            fractions = np.linalg.lstsq(endmembers.T, pixel_spectrum, rcond=None)[0]

            # Normaliser Les fractions d'abondance pour qu'elles soient dans La plage [0, 1]
            fractions = np.clip(fractions, 0, 1)

            # Stocker Les fractions d'abondance dans Le tableau de résultats
            abundance_maps[i, j, :] = fractions

    return abundance_maps

def read_raster(file_path):
    raster_dataset = gdal.Open(file_path, gdal.GA_ReadOnly)
    raster_array = np.zeros((raster_dataset.RasterYSize, raster_dataset.RasterXSize, raster_dataset.RasterCount))
    for i in range(1, raster_dataset.RasterCount + 1):
        band = raster_dataset.GetRasterBand(i)
        raster_array[:, :, i-1] = band.ReadAsArray()
    return raster_array

# Chemin d'accès à votre raster
raster_file = 'C:/Users/sillis/OneDrive/Documents/Unif/mémoire/unmixing/indice/20220727/resample/st/multiband_raster_10m.tif'

# Lecture du raster en tant qu'objet numpy array
input_raster = read_raster(raster_file)

# Exécution du mélange spectral Linéaire
abundance_maps = linear_spectral_unmixing(input_raster, mean_indices_rang, mean_indices_inter)
#print(abundance_maps)

```

```
import matplotlib.pyplot as plt

# Affichage des fractions d'abondance pour l'endmember "rang"
plt.imshow(abundance_maps[:, :, 0], cmap='gray')
plt.title('Fractions d\'abondance pour l\'endmember "rang"')
plt.colorbar(label='Fraction d\'abondance')
plt.show()

# Affichage des fractions d'abondance pour l'endmember "inter"
plt.imshow(abundance_maps[:, :, 1], cmap='gray')
plt.title('Fractions d\'abondance pour l\'endmember "inter"')
plt.colorbar(label='Fraction d\'abondance')
plt.show()
```

Annexe K : Script Rstudio

Stepwise linear regression :

```
# Charger les données
data <- read_excel("C:/Users/sillis/OneDrive/Documents/Unif/mémoire/svm/svm.xlsx", 5)
data <- data[-c(650:780),]
data <- subset(data, select = -c(date,lieu,dates))
#data <- subset(data, select = c(stepwise2_rang,ndwi2,gndvi,srnirblue,srnirgreen))
#define intercept-only model
intercept_only <- lm(stepwise2_rang ~ 1, data= data)

#define model
all <- lm(stepwise2_rang ~ ., data= data)

# forward stepwise regression
forward <- step(intercept_only, direction='both', scope=formula(all), trace=0, test="F",
k=log(nrow(data)))
summary(forward)

#view results
forward$anova
forward$coefficients

data$stepwise_prediction <- predict(forward, newdata = data)

plot(data$stepwise_prediction,data$stepwise2_rang)
print(cor(data$stepwise_prediction,data$stepwise2_rang))
```

Code pour plot les graphiques :

```
Pixel <- read_excel("C:/Users/sillis/OneDrive/Documents/Unif/mémoire/excel/ACP.xlsx", 7)
```

```

#nouveau_dataframe <- subset(Pixel, date %in%
c(20220727,20220810,20230810,20230906,20230720,20220831))

#nouveau_dataframe <- subset(Pixel, date !=20220810)

# nouveau_dataframe <- Pixel

nouveau_dataframe <- Pixel

nouveau_dataframe <- Pixel[!(Pixel$date == "20220831" & Pixel$lieu == "w"), ]

x1 <- nouveau_dataframe$re_rang_mean
y1 <- nouveau_dataframe$re_inter_mean
fit1 <- lm(y1 ~ x1)
correlation1 <- cor(x1, y1)
print(correlation1)
coef1 <- coef(fit1)
print(coef1)

# Define colors based on dates
date_colors <- c("20220727" = "blue", "20220810" = "red", "20230810" = "green", "20230906" =
"orange", "20230720" = "purple", "20220831" = "black")

# Define symbols based on lieu
lieu_symbols <- c("bousval" = 19, "w" = 3)

# Plot points for each date separately
plot(x1, y1, xlim = c(0, 0.4), ylim = c(0, 0.4), xlab = "rang", ylab = "inter", main = 'Rang/inter dans le
RedEdge')

for (date_value in unique(nouveau_dataframe$date)) {
  points_subset <- nouveau_dataframe[nouveau_dataframe$date == date_value, ]
  for (lieu_value in unique(points_subset$lieu)) {
    points_subset_lieu <- points_subset[points_subset$lieu == lieu_value, ]
    points(points_subset_lieu$re_rang_mean, points_subset_lieu$re_inter_mean,
          col = date_colors[as.character(date_value)],

```

```

    pch = lieu_symbols[as.character(lieu_value)]
  }
}

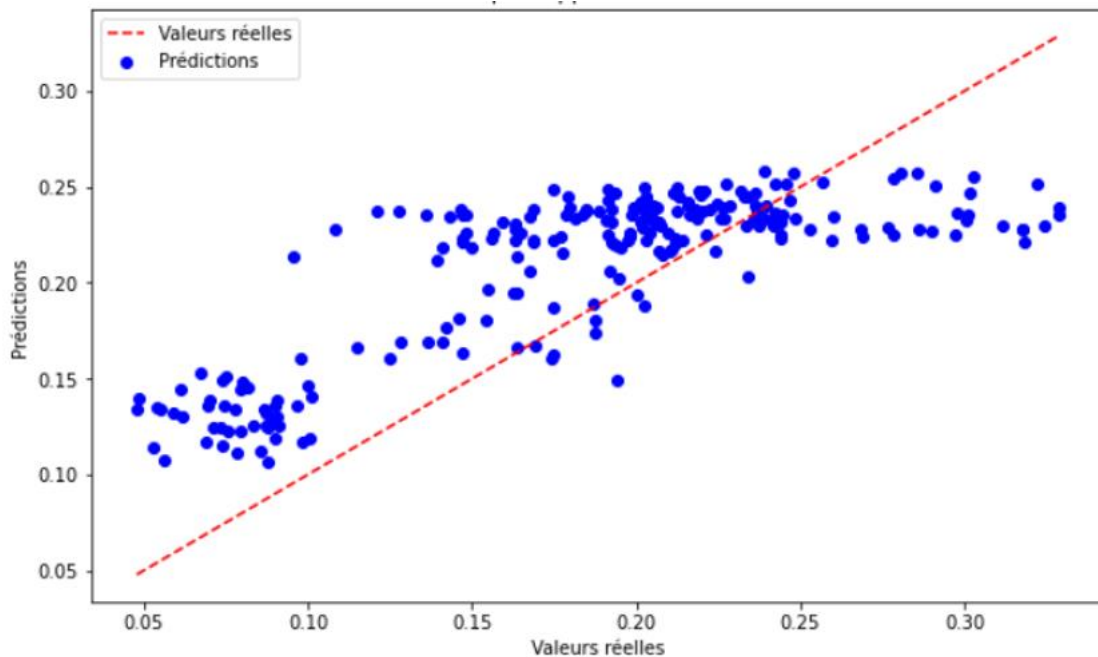
abline(a = 0, b = 1, col = "red", lty = 2)
abline(fit1, col = "yellow")

# Add legend for date colors
legend_text <- c("20220727", "20220810", "20230810", "20230906", "20230720", "20220831")
#legend_text <- c("20220803", "20220825", "20230705", "20230712", "20220801", "20220824", "20230628")
legend_colors <- c("blue", "red", "green", "orange", "purple", "black")
#legend_colors <- c("blue", "red", "green", "orange", "purple", "black", "pink")
legend("topright", legend = legend_text, fill = legend_colors, title = "Dates", cex = 0.6)

# Add legend
legend_text <- c(paste("27/07/22", " (Corrélation =", round(correlation1, 2), ",", "Pente =",
round(coef1[2], 2), ")", sep = ""))
legend("topright", legend = legend_text, cex = 0.4)

```

Annexe L : SVM pour la quantification de la proportion de rang.



Annexe M : Equation et code pour le calcul d'angle solaire

Mathematical description of the Earth-Sun movement: summary of the model

- Input data:**
- day number (d = number of days since the beginning of the year)
 - local time (LT)
 - geographical position: Latitude (φ) and Longitude

Sun position calculation procedure:

Intermediate quantities for the calculation:

- ΔT_{UTC} = difference of the Local Time (LT) from Universal Coordinated Time (UTC), in hours
 - Local Standard Time Meridian (LSTM): $LSTM = 15^{\circ} \Delta T_{UTC}$
 - Equation of time: $B = \frac{360}{365}(d - 81)$
 $EoT = 9.87 \sin(2B) - 7.53 \cos(B) - 1.5 \sin(B)$
- Time correction factor: $TC = 4(\text{Longitude} - LSTM) + EoT$
- Local Solar Time & Hour Angle: $LST = LT + \frac{TC}{60}$ $HRA = 15^{\circ}(LST - 12)$
- Declination angle: $\delta = -23.45^{\circ} \times \cos\left(\frac{360}{365} \times (d + 10)\right)$

Source : Lenvi2007,uclouvain

```

# -*- coding: utf-8 -*-
"""
Created on Thu Mar  7 08:28:27 2024

@author: sillis
"""
#%% jour depuis le premier janvier

from datetime import datetime

def jours_depuis_janvier(date):
    # Convertir la date en objet datetime
    date_obj = datetime.strptime(date, "%Y-%m-%d")

    # Créer une date pour le premier janvier de la même année
    premier_janvier = datetime(date_obj.year, 1, 1)

    # Calculer la différence entre la date donnée et le premier janvier
    difference = date_obj - premier_janvier

    # Extraire le nombre de jours à partir de la différence
    jours = difference.days

    return jours

# Exemple d'utilisation
date = "2023-09-01"
jours = jours_depuis_janvier(date)
print("Nombre de jours depuis Le premier janvier :", jours)

```

```

%%
import numpy as np

# Données
d = jours # Jour de l'année
latitude = 50.6 # Latitude en degrés
longitude = 4.55 # Longitude en degrés
LT = 12.5 # Heure locale (en heures)

# Conversion en heures décimales
dUTC = 1
LSTM = 15 * dUTC
LT_decimal = LT + LSTM / 60

# Correction pour l'équation du temps
B = 2 * np.pi * (d - 1) / 365
EoT = 229.18 * (0.000075 + 0.001868 * np.cos(B) - 0.032077 * np.sin(B) - 0.014615 * np.cos(2 * B) - 0.040849 * np.sin(2 * B))

# Temps solaire local
TC = 4 * (longitude - 15 * dUTC) + EoT
LST = LT_decimal + TC / 60

# Déclinaison solaire
DA = 23.45 * np.sin(2 * np.pi * (284 + d) / 365)

# Angle horaire
HRA = 15 * (LST - 12)

# Calcul de l'élévation solaire
sin_alpha = np.sin(np.deg2rad(latitude)) * np.sin(np.deg2rad(DA)) + np.cos(np.deg2rad(latitude)) * np.cos(np.deg2rad(DA)) * np.cos(np.deg2rad(HRA))
alpha = np.arcsin(sin_alpha)
print("Angle d'élévation solaire (alpha) :", np.rad2deg(alpha))

# Calcul de l'azimut solaire
cos_teta = (np.sin(np.deg2rad(DA)) - np.sin(np.deg2rad(latitude)) * np.sin(alpha)) / (np.cos(np.deg2rad(latitude)) * np.cos(alpha))
teta = np.arccos(cos_teta)
print("Azimut solaire (teta) :", np.rad2deg(teta))

%% calcul de l'irradiance

irradiance = 1000 * np.cos((3.14159/180) * (90 - np.rad2deg(alpha)))
print("irradiance = ", irradiance)

```

Comment améliorer la quantification du statut hydrique de la vigne par satellite grâce aux données multispectrales de drone : cas d'étude de deux vignobles belges.

Arthur Sillis

Résumé :

Cette étude explore la détermination du potentiel hydrique de base des vignobles à partir d'images Sentinel-2, en utilisant des drones comme intermédiaires. Les méthodes traditionnelles étant chronophages et limitées, la télédétection offre une collecte rapide et exhaustive des données. Sentinel-2, bien que limité en résolution, fournit des mesures régulières et gratuites, tandis que les drones, plus coûteux, offrent une haute résolution. L'objectif principal est d'utiliser les drones pour séparer les données des rangs et des inter-rangs, permettant ainsi une estimation plus précise du potentiel hydrique. Les sous-objectifs incluent l'étude de l'évolution des rangs et des inter-rangs et l'influence de l'ombre. La méthodologie comprend la détection des ombres à partir d'images RGB et de modèles numériques de surface (CHM), la quantification des proportions de rangs et d'inter-rangs, et l'utilisation des drones pour affiner les données Sentinel-2. Les résultats montrent l'efficacité de ces méthodes et comparent ces données avec les calculs directs du potentiel hydrique à partir de Sentinel-2. La discussion aborde les principales sources d'erreur et les limitations, soulignant la nécessité de valider le modèle dans d'autres domaines. Bien que des avancées méthodologiques aient été réalisées, des défis subsistent pour prédire avec précision le potentiel hydrique des vignobles, notamment en raison de la variabilité de l'ombrage et de la couverture du sol.

UNIVERSITÉ CATHOLIQUE DE LOUVAIN

Faculté des bioingénieurs

Croix du Sud, 2 bte L7.05.01, 1348 Louvain-la-Neuve, Belgique | www.uclouvain.be/agro