

# 密集圃場群における超解像衛星画像特徴と空間補正を用いた病害率推定の初期検討

中川 優貴<sup>1,a)</sup> 有馬 祐二<sup>1,b)</sup> 川田 拓朗<sup>1,c)</sup> 池田 健太郎<sup>1,d)</sup> 彌富 仁<sup>1,e)</sup>

## 概要

本研究では、小規模圃場が多数密集する地域を対象に、超解像処理した低解像度衛星画像と圃場間の地理的關係を用いる GNN を統合した病害率推定手法を検討した。群馬県・松義台地約 9km<sup>2</sup> にある 321 のコンニャク圃場で評価した結果、超解像処理により画像単体モデルの性能が改善し、GNN 補正によってさらに向上した。両者を統合した提案手法は最も高い性能を示し、低コストな病害診断の実現可能性を示した。

## 1. はじめに

植物病虫害による農業被害を低減するため、コンピュータビジョン技術を用いた自動診断技術に関する研究が進められている。その中で、広域を対象とした診断技術として、ドローン等に代表される無人航空機 (UAV) や人工衛星を用いたリモートセンシング画像の活用と解析が進んでいる [6, 13]。UAV によって撮影された数センチメートル単位の高解像度画像は、高精度な病害領域のセグメンテーションや病害モニタリングを可能とし、圃場内における病害分布の詳細な可視化や重点的な防除判断を支援する [4]。一方、UAV の運用には飛行計画、操縦者の確保、法規制への対応などが必要であり、広域かつ継続的な運用には高いコストを要する。これに対し、人工衛星画像を利用する手法は広範囲を低コストかつ高頻度で観測できるため、広域モニタリングに適しており、作物生育状況の把握、農地利用の監視、収量予測などの農業応用で有効性が報告されている [12]。しかし、衛星画像は UAV 画像と比較して空間解像度が低く、大気条件や観測条件による劣化を含む。また、圃場境界や作物領域も不鮮明であり、圃場単位で病害を捉えることは困難である (図 1)。したがって、低コストな衛星画像を用いた遠隔診断では、低解像度画像から病害



図 1: 対象地域における低解像度衛星画像 (左) と高解像度 UAV 画像 (右) の例。画像中の各区画は圃場単位を示しており、UAV 画像では衛星画像に比べて圃場境界や作物領域をより明瞭に確認できる。

率推定に有用な特徴をどのように補うかが課題となる。

また、農地における病害の発生は、対象圃場内の要因だけではなく、周辺地域の状況に影響を受ける可能性がある。特に本研究が対象とする地域のように、対象となる圃場が密集して分布している場合、その影響の考慮は大きな意義がある。こうした広域の管理や調査において、温度、湿度、土壌水分、栄養状態などを計測するセンサネットワークにより、環境情報や作物状態を継続的に監視する取り組みが様々な効果をあげている [8]。このような数値センサによる環境計測は比較的容易であり、広域への展開も可能である。一方、病害や害虫の発生を詳細に把握するには、空撮画像、高解像度 RGB 画像、マルチスペクトル画像などを組み合わせた高度な画像計測と解析が必要となる場合がある [9]。そのため、機材の設置・運用や画像解析に要する負担を考慮すると、このような監視を広域の農地全体に継続的に展開することは容易ではない。

近年急激に発展している機械学習技術は、これらの課題に対する有力な手掛かりを提供している。第一に、解析対象の空間解像度の制約に対しては、超解像処理が有効な手段として検討されている。農業分野においては、リモートセンシング画像へ適用する研究が進んでおり、Sentinel-2 画像を対象とした農地マッピングでは、農地境界の識別精度や分類精度が向上することが報告されている [3]。しかし

<sup>1</sup> 法政大学大学院

a) yuki.nakagawa.3k@stu.hosei.ac.jp

b) yuji.a.20010416@gmail.com

c) takuro.kawada.3g@stu.hosei.ac.jp

d) ikeda-ken@hosei.co.jp

e) iyatomi@hosei.ac.jp

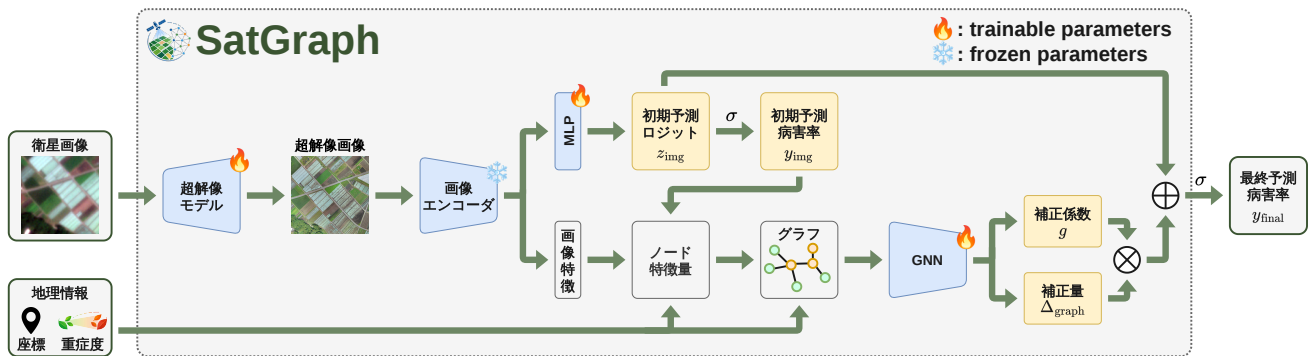


図 2: SatGraph の概要. 高解像度 UAV 画像を教師画像として学習した超解像モデルを低解像度衛星画像に適用し, 得られた超解像画像から画像特徴量と画像単体の予測を算出する. 次に, 各圃場をノード, 圃場重心間の距離に基づく関係をエッジとするグラフを構築し, 画像情報および一部圃場の既知病害率を GNN で処理する. GNN のノード表現から補正量と補正係数を算出し, 両者の積を画像単体の予測に加算することで最終的な病害率を推定する.

超解像処理は, 推定された詳細情報が正確であるとは限らない. 第二に, 周辺圃場との関係を考慮する課題に対しては, 要素間の関係を明示的に扱えるグラフニューラルネットワーク (GNN) が有効な手段として挙げられる. 農業分野では, 圃場間の地理的関係や時系列情報をグラフとして表現し, GNN を作物収量予測へ応用する研究が行われている [1]. 一方, GNN を病害推定に有効に利用するためには, 圃場間の近接性, 隣接性, 配置関係などをどのようにグラフとして表現し, 画像特徴と統合するかが課題となる.

本研究では, 小規模圃場が密集する地域を対象とした低コストで高精度な, 遠隔病害発生推定の実現性検証を行った. 我々が検証する推定枠組み SatGraph は, 衛星画像および, 各圃場から得られる情報 (発病率など) を元に GNN を構築し, 各圃場の病害発生率を予測する. 各ノードには超解像処理を施した衛星画像特徴と圃場の情報を, エッジには圃場間の地理的関係を考慮することで, 画像解析単体では捉えにくい発病傾向を考慮したより精度の高い予測を目指す. 我々は群馬県・松義台地のコンニャク圃場を対象とした評価により, SatGraph の実現可能性を検証した.

## 2. SatGraph

本研究では, 群馬県松義台地に分布する 321 のコンニャク圃場を対象として, 衛星画像と一部圃場の既知病害率を用いて, 各圃場の病害発生率を低コスト, 高精度で推定する枠組みである SatGraph を構築する. SatGraph は, 図 2 に示すように, 低解像度衛星画像に超解像処理を適用して各圃場の画像特徴を抽出したうえで, GNN により各圃場の画像情報と圃場間の地理的関係を統合し, 病害率を推定する. これにより, 画像単体では捉えきれない周辺圃場との位置関係を考慮した推定を行う.

### 2.1 解析対象データ

解析対象地域の現地調査データにおいて固有の圃場 ID が付与された栽培区画を 1 圃場と定義し, 各圃場には, 圃場 ID, 重心座標, および現地調査に基づくコンニャク根

腐病の病害率ラベルが対応付けられている. 病害率ラベルは 0% から 100% の連続値であり, 本研究では  $[0, 1]$  に正規化した回帰問題として扱う. さらに, 本データでは低病害率圃場が多数を占め, 高病害率圃場が少ないという病害率分布の不均衡が存在する.

### 2.2 SatGraph の全体構成

SatGraph では, 年度ごとに独立したグラフを構築し, 各年度のグラフを同一のモデルに個別に入力し, 学習年度の複数のグラフを用いて共通の画像モデルおよび GNN のパラメータを学習する. 各年度のグラフから得られる情報を, 共通のモデルパラメータの学習を通して統合する. 評価時には, 学習済みのパラメータを評価年度のグラフに適用し, 各圃場の病害率を推定する.

各年度のグラフを用いた病害率推定では, 超解像画像から算出した画像単体の病害率予測を, 圃場間の地理的関係と一部圃場の既知病害率に基づいて補正する. まず, 後述の方法で各圃場の超解像画像から画像特徴と画像単体予測を算出する. 次に, 各圃場をノード, 圃場間の地理的関係をエッジとするグラフを年度ごとに構築する. グラフを GNN に入力することによって各圃場のノード表現を算出し, 画像単体の予測に対する補正量  $\Delta_{graph,i}$  と補正係数  $g_i$  を求める. これらをシグモイド関数の適用前に画像単体の予測値へ加算し, その後シグモイド関数を適用することで, 最終的な病害率を予測する.

圃場  $i$  の画像には, 超解像画像から固有の圃場 ID が付与された栽培区画を含む領域を切り出した画像を用いる. この画像を画像エンコーダに入力し, 圃場  $i$  の画像情報を表す  $D$  次元の画像特徴ベクトルを抽出する. さらに, 画像特徴ベクトルを出力次元を 1 とする単一の全結合層からなる予測ヘッドに入力し, シグモイド関数適用前の予測値  $z_{img,i}$  を算出する.  $z_{img,i}$  は圃場  $i$  ごとの 1 次元スカラーであり, 値域に制限のない実数値をとる. これにシグモイド関数  $\sigma$  を適用することで, 0 から 1 の範囲の画像単体の病

害率予測値を得る．ここで算出した画像単体の病害率予測値を後段のノード特徴量の一部として使用する．

本研究では，病徴が顕著な圃場が現地調査等で優先的に把握される状況を模擬するため，各年度について重症圃場は病害率が既知であり，その情報を用いて残りの未知圃場の病害率を推定する半教師あり条件を想定する．

各年度のすべての圃場をノードとするグラフを構築する．圃場  $i$  のノード特徴量は， $D$  次元の画像特徴ベクトル，画像単体の病害率予測値，病害率が既知であるかを表す二値マスク，および既知病害率を結合した  $D+3$  次元のベクトルとする．画像単体の病害率予測値および既知病害率は，ともに  $[0, 1]$  のスカラー値である．既知圃場では二値マスクを 1 として既知病害率を入力し，未知圃場では二値マスクと病害率をともに 0 とする．これにより，観測された病害率 0 と，未観測を表す入力値 0 とを区別する．

次に，同一年度に含まれるすべての圃場対  $(i, j)$  について，圃場重心間の距離  $d_{ij}$  をハバーサイン公式により算出する．空間的影響が半分となる距離を半減距離  $\alpha$  とし， $d_{ij}$  が  $4\alpha$  以下の条件を満たす圃場  $i$  と圃場  $j$  の間にエッジを設定する．接続された圃場間には，距離に応じたエッジ強度  $a_{ij}$  を次式により付与する．

$$a_{ij} = 2^{-(d_{ij}/\alpha)^2} \quad (1)$$

エッジ強度  $a_{ij}$  は近い圃場ほど大きく，近傍圃場の情報を集約する際の重みとして用いる．これにより，情報集約の範囲と距離に応じた反映度を制御する．

### 2.3 GNN による補正と学習

GNN は，各圃場のノード特徴量と近傍圃場のノード特徴量を，エッジ強度に基づいて重み付けして集約する．これにより，各圃場自身の画像情報および既知ラベル情報に，地理的に近い圃場の情報を強く反映したノード表現を得る．

得られたノード表現を，補正量出力層と補正係数出力層にそれぞれ入力し，画像単体の予測を増減させる補正量  $\Delta_{\text{graph},i}$  と，補正量の最終予測への反映を調整する補正係数  $g_i$  を算出する．補正係数は周辺圃場の情報がすべての圃場に対して同程度に有効であるとは限らないために用いる．補正量  $\Delta_{\text{graph},i}$  は 1 次元のスカラー値であり，補正係数  $g_i$  はシグモイド関数により  $[0, 1]$  の値をとる．

$z_{\text{img},i}$ ,  $\Delta_{\text{graph},i}$ , および  $g_i$  はいずれも圃場  $i$  ごとの 1 次元スカラーであるため， $g_i \Delta_{\text{graph},i}$  を  $z_{\text{img},i}$  に加算できる．最終的な予測を  $z_{\text{final},i}$ ，最終的な病害率予測値を  $\hat{y}_{\text{final},i}$  とし，次式で算出する．

$$\hat{y}_{\text{final},i} = \sigma(z_{\text{img},i} + g_i \Delta_{\text{graph},i}) \quad (2)$$

SatGraph の学習は二段階で行う．第 1 段階では，画像エンコーダの末尾 2 ブロックと正規化層，および予測ヘッドを学習対象とする．画像単体の予測  $z_{\text{img},i}$  と正解病害率

$y_{\text{true},i} \in [0, 1]$  に BCEWithLogitsLoss を適用し，画像エンコーダのその他のパラメータは固定する．

第 2 段階では，学習済みの画像エンコーダおよび予測ヘッドを固定し，GNN，補正量出力層，および補正係数出力層を学習する．低病害率圃場が多いデータの偏りを考慮し，第 2 段階では高病害率圃場の誤差を重視する重み付き MSE を用いる．補正量と補正係数には個別の正解ラベルを与えず，最終予測値と正解病害率との誤差に基づいてパラメータを更新する．既知圃場は損失計算から除外し，未知ノードのみを学習対象とする．

未知ノードの集合を  $\mathcal{V}_{\text{unknown}}$ ，そのノード数を  $N = |\mathcal{V}_{\text{unknown}}|$ ，損失関数を  $L$ ，圃場  $i$  に対する重みを  $w_i$  とし，次式で定義する．

$$L = \frac{1}{N} \sum_{i \in \mathcal{V}_{\text{unknown}}} w_i (\hat{y}_{\text{final},i} - y_{\text{true},i})^2, \quad (3)$$

$$w_i = 1 + \beta y_{\text{true},i}^2 \quad (4)$$

ここで， $\beta$  は高病害率圃場の予測誤差を重視する度合いを制御する係数であり，本研究では  $\beta = 8.0$  とした．このとき，正解病害率が  $\theta$  の圃場には重み 1，正解病害率が 1 の圃場には重み 9 が与えられる．

各評価分割では，第 1 段階の画像モデルと第 2 段階の補正モデルのいずれも，評価対象年を除く年度のデータのみを用いて学習する．評価対象年では，一部の既知圃場の観測済み病害率のみを GNN に入力し，未知圃場の正解病害率はパラメータ更新に用いない．既知圃場は評価指標の計算から除外し，未知圃場のみを評価対象とする．

### 3. 評価実験

**学習および評価設定．** 実験には，2022 年から 2024 年に取得された群馬県松義台地のコンニャク圃場データを用いた．2023 年および 2024 年のデータを画像モデルおよび GNN の学習に使用し，2022 年のデータを評価対象とした．評価対象である 2022 年のデータでは，病害率 0–10% の圃場が 52.3%，病害率 60–100% の圃場は 7.5% であり，低病害率圃場に偏った分布となっている．評価対象年の深刻な病害発生が分かっている圃場を 5 圃場，病害率を既知圃場として GNN に入力した．全比較手法について，既知圃場を除く未知ノード集合を評価対象とした．学習時には，ランダムクロップ，左右反転，上下反転，および色調変化によるデータ拡張を適用した．超解像モデルには DiffBIR [7] を用い，超解像倍率は 7 倍とした．画像からの特徴抽出には，事前学習済み DINOv3 [10] を用いた．

**比較実験と評価指標．** 提案フレームワークにおける空間補正の有効性を検証するため，GNN 構成および半減距離  $\alpha$  の違いによる性能を比較した．この比較は，低解像度衛星画像による画像単体予測に対して，圃場間の空間関係をどのように統合することが有効かを検討するために行った．

GNN モデルとして，GAT [11]，GCN [5]，GraphSAGE [2]

表 1: GNN 構成の比較結果. 半減距離を  $\alpha = 30\text{m}$  に固定し, GNN モデルおよび GAT の層数の違いによる性能を比較した. 太字は各評価指標における最良値を示す.

GNN 構成	$R^2$	Acc( $\pm 10\%$ )	MAE	MAE on severe <sup>†</sup>
GAT (1 層) [11]	0.5059	67.1	9.56	35.8
GAT (2 層) [11]	<b>0.6374</b>	<b>71.6</b>	<b>8.32</b>	<b>21.8</b>
GAT (3 層) [11]	0.5281	68.7	9.44	29.6
GCN [5]	0.5753	68.7	9.27	28.7
GraphSAGE [2]	0.4932	67.4	9.67	39.4

†: 病害率 60–100% の圃場に対する MAE

を比較した. GAT は近傍ノードごとの重要度を注意機構により重み付けできるため, 本研究では主な候補モデルとして扱い, 近傍情報の集約範囲の影響を確認するために 1 層, 2 層, 3 層の構成を比較した. 一方, GCN および GraphSAGE については, 代表的な比較対象として 2 層構成を用いた. また, 半減距離  $\alpha$  の影響を確認するため, GAT 2 層構成に対して,  $\alpha = 15\text{m}, 30\text{m}, 60\text{m}$  を評価した. これらの比較で最良の性能を示した構成を, 提案手法の代表構成として用いた.

さらに, 超解像処理と GNN による空間補正が推定性能に与える影響を確認するため, SR と GNN の有無を組み合わせた 4 条件を比較した. SR は超解像画像を用いる条件, GNN は GNN により画像単体予測に対する補正を行う条件を表す. 両方を用いる条件を提案フレームワーク SatGraph とし, 低解像度衛星画像のみを用いる画像単体モデルを基準条件とした. 評価指標には, 決定係数  $R^2$ , 平均絶対誤差 (MAE), 誤差が  $\pm 10\%$  以内である圃場の割合, および高病害率帯である 60%–100% の MAE を用いた.

#### 4. 結果と考察

表 1 に, GNN 構成比較の結果を示す. 比較した 15 条件のうち, GAT 2 層,  $\alpha = 30\text{m}$  が最も良好な性能を示し,  $R^2 = 0.6374$ , MAE = 8.32, Acc ( $\pm 10\%$ ) = 71.6%, 60–100% 帯の MAE = 21.8 を達成した. GAT では注意機構によって近傍圃場ごとの寄与を調整できるため, この性質が密集地域の病害分布の推定に寄与した可能性がある.

図 3 より, GAT 2 層における半減距離の比較では,  $\alpha = 30\text{m}$  が最も高い  $R^2$  を示した. これは, 参照範囲が狭い場合には周辺情報を十分に利用できず, 広い場合には病害発生との関連が弱い圃場まで集約されるため, 本データセットでは中程度の参照範囲が有効であったと考えられる. 以上から, 以降の比較では GAT 2 層,  $\alpha = 30\text{m}$  を用いた.

表 2 に, 超解像処理および GNN による空間補正の要素比較を示す. 超解像処理のみを用いた画像単体モデルでは, 低解像度衛星画像を用いたモデルと比較して,  $R^2$  および 60–100% 帯の MAE が改善した一方, 全体 MAE および Acc ( $\pm 10\%$ ) は低下した. この結果は, 超解像処理は高病害率圃場の特徴抽出に寄与する一方, 画像単体での

表 2: 超解像処理および GNN による空間補正の有無による性能比較. SR は超解像画像の使用, GNN は GNN による空間補正の使用を示す.

SR	GNN	$R^2$	Acc( $\pm 10\%$ )	MAE	MAE on severe <sup>†</sup>
–	–	0.4751	62.9	11.61	41.7
✓	–	0.5529	55.8	11.73	26.5
–	✓	0.5119	31.7	10.70	31.7
✓	✓	<b>0.6374</b>	<b>71.6</b>	<b>8.32</b>	<b>21.8</b>

†: 病害率 60–100% の圃場に対する MAE




図 3: GAT 2 層における半減距離  $\alpha$  の違いによる  $R^2$  の比較をした.  $\alpha = 30\text{m}$  のとき最も高い性能を示した.

推定には限界があることを示唆する.

重症圃場 5 件の病害率を既知ラベルとして利用する条件において, SatGraph は低解像度衛星画像を用いた画像単体モデルをすべての評価指標で上回った. 超解像画像特徴, 圃場間の地理的關係, および既知圃場の病害率を統合することで, 未知圃場の推定性能が改善したと考えられる.

本研究は, 密集圃場地域において, 衛星画像特徴, 圃場間の地理的關係, および一部圃場の現地調査結果を統合する病害率推定手法の初期検討であり, 画像単体予測を周辺圃場の情報により補正する枠組みの実現可能性を示した. 一方, グラフは圃場間距離のみでの構築のため, 今後は風向, 水流, 標高, 土壌条件, 圃場管理情報などをノード特徴量やエッジ特徴量として導入する必要がある. また, 超解像画像が病害特徴を還元しているか検証が必要である.

#### 5. おわりに

本研究では, 小規模圃場が密集する地域を対象として, 低解像度衛星画像および圃場間の地理的關係を統合する SatGraph を構築した. 重症圃場の一部が既知である半教師あり条件において, SatGraph は画像単体モデルをすべての評価指標で上回り, 超解像画像特徴と周辺圃場の情報を統合することの有効性が示された. 今後は, 環境要因や管理要因をグラフに組み込み, 超解像画像が病害率推定に与える影響を検証する.

## 参考文献

- [1] Fan, J., Bai, J., Li, Z., Ortiz-Bobea, A. and Gomes, C. P.: A GNN-RNN Approach for Harnessing Geospatial and Temporal Information: Application to Crop Yield Prediction, *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI): Social Impact Track* (2022).
- [2] Hamilton, W., Ying, Z. and Leskovec, J.: Inductive Representation Learning on Large Graphs, *Proceedings of the International Conference on Neural Information Processing Systems (NIPS)* (2017).
- [3] Jia, X., Hao, Z., Shi, L., Wang, Z., Chen, S., Du, Y. and Ling, F.: Super-Resolution Cropland Mapping with Sentinel-2 Images Based on a Self-Training Learning Network, *Remote Sensing Letters*, Vol. 15, No. 11, pp. 1143–1152 (2024).
- [4] Kerkech, M., Hafiane, A. and Canals, R.: Vine Disease Detection in UAV Multispectral Images Using Optimized Image Registration and Deep Learning Segmentation Approach, *Computers and Electronics in Agriculture*, Vol. 174, 105446 (2020).
- [5] Kipf, T. N. and Welling, M.: Semi-Supervised Classification with Graph Convolutional Networks, *Proceedings of the International Conference on Learning Representations (ICLR)* (2017).
- [6] Kouadio, L., El Jarroudi, M., Belabess, Z., Laasli, S.-E., Roni, M. Z. K., Amine, I. D. I., Mokhtari, N., Mokrini, F., Junk, J. and Lahlali, R.: A Review on UAV-Based Applications for Plant Disease Detection and Monitoring, *Remote Sensing*, Vol. 15, No. 17, p. 4273 (2023).
- [7] Lin, X., He, J., Chen, Z., Lyu, Z., Dai, B., Yu, F., Qiao, Y., Ouyang, W. and Dong, C.: DiffBIR: Towards Blind Image Restoration with Generative Diffusion Prior, *Proceedings of the European Conference on Computer Vision (ECCV)* (2024).
- [8] Musa, P., Sugeru, H. and Wibowo, E. P.: Wireless Sensor Networks for Precision Agriculture: A Review of NPK Sensor Implementations, *Sensors*, Vol. 24, No. 1, p. 51 (2024).
- [9] Shi, H., Hou, K. M., Diao, X., Xing, L., Li, J.-J. and De Vault, C.: A Wireless Multimedia Sensor Network Platform for Environmental Event Detection Dedicated to Precision Agriculture, *Proceedings of the New and Smart Information Communication Science and Technology to Support Sustainable Development (NICST)* (2013).
- [10] Siméoni, O., Vo, H. V., Seitzer, M., Baldassarre, F., Oquab, M., Jose, C., Khalidov, V., Szafraniec, M., Yi, S., Ramamonjisoa, M., Massa, F., Haziza, D., Wehrstedt, L., Wang, J., Darcet, T., Moutakanni, T., Sentana, L., Roberts, C., Vedaldi, A., Tolan, J., Brandt, J., Couprie, C., Mairal, J., Jégou, H., Labatut, P. and Bojanowski, P.: DINOv3, *arXiv preprint arXiv:2508.10104* (2025).
- [11] Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P. and Bengio, Y.: Graph Attention Networks, *Proceedings of the International Conference on Learning Representations (ICLR)* (2018).
- [12] Weiss, M., Jacob, F. and Duveiller, G.: Remote Sensing for Agricultural Applications: A Meta-Review, *Remote Sensing of Environment*, Vol. 236, 111402 (2020).
- [13] Zhu, H., Lin, C., Liu, G., Wang, D., Qin, S., Li, A., Xu, J.-L. and He, Y.: Intelligent Agriculture: Deep Learning in UAV-Based Remote Sensing Imagery for Crop Diseases and Pests Detection, *Frontiers in Plant Science*, Vol. 15, 1435016 (2024).