BỘ GIÁO DỤC VÀ ĐÀO TẠO
TRƯỜNG ĐẠI HỌC MỎ - ĐỊA CHẤT

BÁO CÁO HỌC THUẬT
KỲ 1 NĂM HỌC 2025-2026

ĐỀ XUẤT QUY TRÌNH ĐÁNH GIÁ SỨC KHỎE CÂY LÚA TỪ DỮ LIỆU ẢNH UAV ĐA PHỔ

Người báo cáo: NCS. Lê Văn Cảnh

Đơn vị: Bộ môn Trắc địa mỏ

Khoa: Trắc địa – Bản đồ và Quản lý đất đai

HÀ NỘI, 2025

BỘ GIÁO DỤC VÀ ĐÀO TẠO

TRƯỜNG ĐẠI HỌC MỎ - ĐỊA CHẤT

BÁO CÁO HỌC THUẬT
KỲ 2 NĂM HỌC 2024-2025

ĐỀ XUẤT QUY TRÌNH ĐÁNH GIÁ SỨC KHỎE CÂY LÚA TỪ DỮ LIỆU ẢNH UAV ĐA PHỔ

Phòng KHCN **Bộ môn** **Người báo cáo**

NCS. Lê Văn Cảnh

HÀ NỘI, 2025

MỤC LỤC

MỤC LỤC 3
DANH MỤC CÁC BẢNG 5
DANH MỤC CÁC HÌNH 6
1. Tổng quan về vấn đề nghiên cứu 7
2. Đề xuất quy trình nghiên cứu 8
3. Quan hệ giữa phổ phản xạ và đặc trưng sinh học cây lúa 11
3.1 Phổ phản xạ 11
3.2 Quan hệ giữa phổ phản xạ và đặc trưng sinh học của cây lúa 12
4. Phương pháp thu thập dữ liệu ảnh UAV đa phổ 15
4.1 Phương pháp bay chụp ảnh 15
4.1.1 Thành lập điểm khống chế ảnh mặt đất 15
4.1.2 Lập kế hoạch và chụp ảnh thực địa 15
4.1.3 Phương pháp xử lý ảnh thành lập ảnh trực giao đa phổ 17
4.2 Thu thập mẫu lá lúa 20
4.2.1 Phương pháp thu thập mẫu 20
4.2.2 Phương pháp chiết xuất hàm lượng dinh dưỡng trên lá lúa 20
5. Phương pháp tính và lựa chọn các chỉ số từ dữ liệu ảnh UAV đa phổ 21
5.1 Chỉ số thực vật 21
5.2 Chỉ số cấu trúc (TFs) 23
5.2.1 Chỉ số cấu trúc 23
5.2.2 Phương pháp chiết xuất chỉ số cấu trúc 24
5.3 Chỉ số nước 25
5.4 Phương pháp lựa chọn các chỉ số 25
5.5. Phương pháp kết hợp các chỉ số 28

6 Mô hình ước tính hàm lượng dinh dưỡng 28
6.1 Phương pháp đánh giá đa tiêu chí (MCE)..... 28
6.1.1 Đánh giá đa tiêu chí..... 28
6.1.2 Tính trọng số theo phương pháp phân tích thứ bậc AHP 29
6.2 Mô hình học máy..... 32
6.2.1 Hồi quy bình phương tối thiểu (PLSR)..... 32
6.2.2 Rừng ngẫu nhiên (RF)..... 33
6.2.3 Máy vector hỗ trợ (SVM)..... 34
6.2.4 Máy học cực hạn (ELM)..... 36
6.3 Phương pháp huấn luyện và hiệu chỉnh các mô hình học máy..... 37
6.4 Phương pháp đánh giá độ chính xác 40
KẾT LUẬN 42
TÀI LIỆU THAM KHẢO 43

DANH MỤC CÁC BẢNG

Bảng 1 Chỉ số thực vật 22

Bảng 2 Các chỉ số cấu trúc [75] 23

Bảng 3. Mức độ tương quan [20] 26

Bảng 4 Phương án kết hợp các chỉ số 28

Bảng 5 Mức độ so sánh giữa các chỉ số [60] 30

Bảng 6 Ma trận so sánh giữa các chỉ số [14] 30

Bảng 7 Chỉ số ngẫu nhiên RI [10] 31

Bảng 8 Tính hệ số riêng 31

Bảng 9 Tiêu chí đánh giá hiệu suất mô hình theo rRMSE [73] 40

DANH MỤC CÁC HÌNH

Hình 1. Quy trình đánh giá sức khỏe cây lúa từ dữ liệu ảnh UAV đa phổ 9
Hình 2 Sơ đồ tương tác ánh mặt trời 11
Hình 3 Cấu trúc tế bào của lá cây và sự tương tác với bức xạ điện từ [56] 12
Hình 4 Sơ đồ phổ phản xạ của thực vật [30] 13
Hình 5 Thay đổi phản xạ phổ của lá cây 14
Hình 6 Độ phủ trùm của ảnh bay chụp UAV [1] 16
Hình 7. Quy trình xử lý ảnh UAV đa phổ 17
Hình 8 Sơ đồ thu nhận và hiệu chỉnh phổ ảnh UAV đa phổ [3] 18
Hình 9 Các bước thực hiện chính trong thuật toán SIFT 19
Hình 10 Nguyên lý giải thuật SFM [47] 19
Hình 11. Khu vực lấy mẫu lá tại một điểm mẫu 20
Hình 12 Sơ đồ quy trình chiết xuất chỉ số cấu trúc 25
Hình 13 Vùng thống kê giá trị phổ trên ảnh các chỉ số tại điểm mẫu J_{01} 26
Hình 15 Quy trình xác định trọng số theo AHP 29
Hình 16 Thuật toán rừng ngẫu nhiên (sửa từ nguồn: https://learnetutorials.com) 34
Hình 17 Siêu phẳng phân tách dữ liệu trong không gian hai chiều 35
Hình 18 Siêu phẳng phân tách dữ liệu trong không gian ba chiều 35
Hình 19 Cấu trúc của ELM 36
Hình 20 Nguyên lý K-Fold Cross-validation [46] 38
Hình 21 Sơ đồ ước tính hàm lượng dinh dưỡng cây lúa bằng mô hình học máy 39

1. Tổng quan về vấn đề nghiên cứu

Tong bối cảnh biến đổi khí hậu diễn biến ngày càng phức tạp, sản xuất nông nghiệp nói chung và canh tác lúa nói riêng đang phải đối mặt với nhiều thách thức như sâu bệnh gia tăng, hạn hán, ngập úng, suy thoái đất và việc sử dụng tài nguyên chưa hiệu quả. Lúa là cây trồng chủ lực, giữ vai trò đặc biệt quan trọng đối với an ninh lương thực quốc gia và sinh kế của hàng triệu nông hộ tại Việt Nam. Do đó, việc theo dõi, đánh giá và quản lý sức khỏe cây lúa một cách kịp thời, chính xác là yêu cầu cấp thiết nhằm nâng cao năng suất, chất lượng và tính bền vững của sản xuất lúa.

Các phương pháp đánh giá sức khỏe cây lúa truyền thống chủ yếu dựa trên điều tra thực địa, quan sát trực quan và kinh nghiệm của người sản xuất. Những phương pháp này tuy đơn giản nhưng tồn tại nhiều hạn chế như tốn thời gian, chi phí cao, phạm vi quan sát hẹp và mang tính chủ quan, khó đáp ứng yêu cầu giám sát trên diện rộng và theo thời gian thực. Trong khi đó, sự phát triển nhanh chóng của công nghệ viễn thám, đặc biệt là thiết bị bay không người lái (UAV) kết hợp với cảm biến đa phổ, đã mở ra hướng tiếp cận mới trong giám sát cây trồng với độ phân giải không gian và thời gian cao.

Dữ liệu ảnh UAV đa phổ cho phép thu nhận thông tin chi tiết về trạng thái sinh trưởng, mức độ stress, tình trạng dinh dưỡng và sâu bệnh của cây lúa thông qua các chỉ số thực vật và đặc trưng phổ với độ phân giải không gian và thời gian cao. Tuy nhiên, khối lượng dữ liệu lớn và tính phức tạp của mối quan hệ giữa tín hiệu phổ và trạng thái sinh lý của cây trồng đặt ra yêu cầu cần có các phương pháp phân tích dữ liệu tiên tiến để khai thác hiệu quả nguồn thông tin này. Trong bối cảnh đó, các mô hình học máy (machine learning) như hồi quy đa biến, cây quyết định, rừng ngẫu nhiên, máy vector hỗ trợ và mạng nơ-ron nhân tạo đã chứng minh tiềm năng vượt trội trong việc nhận dạng mẫu, mô hình hóa các mối quan hệ phi tuyến và dự báo sức khỏe cây trồng từ dữ liệu viễn thám.

Việc kết hợp dữ liệu ảnh UAV đa phổ với các mô hình học máy cho phép

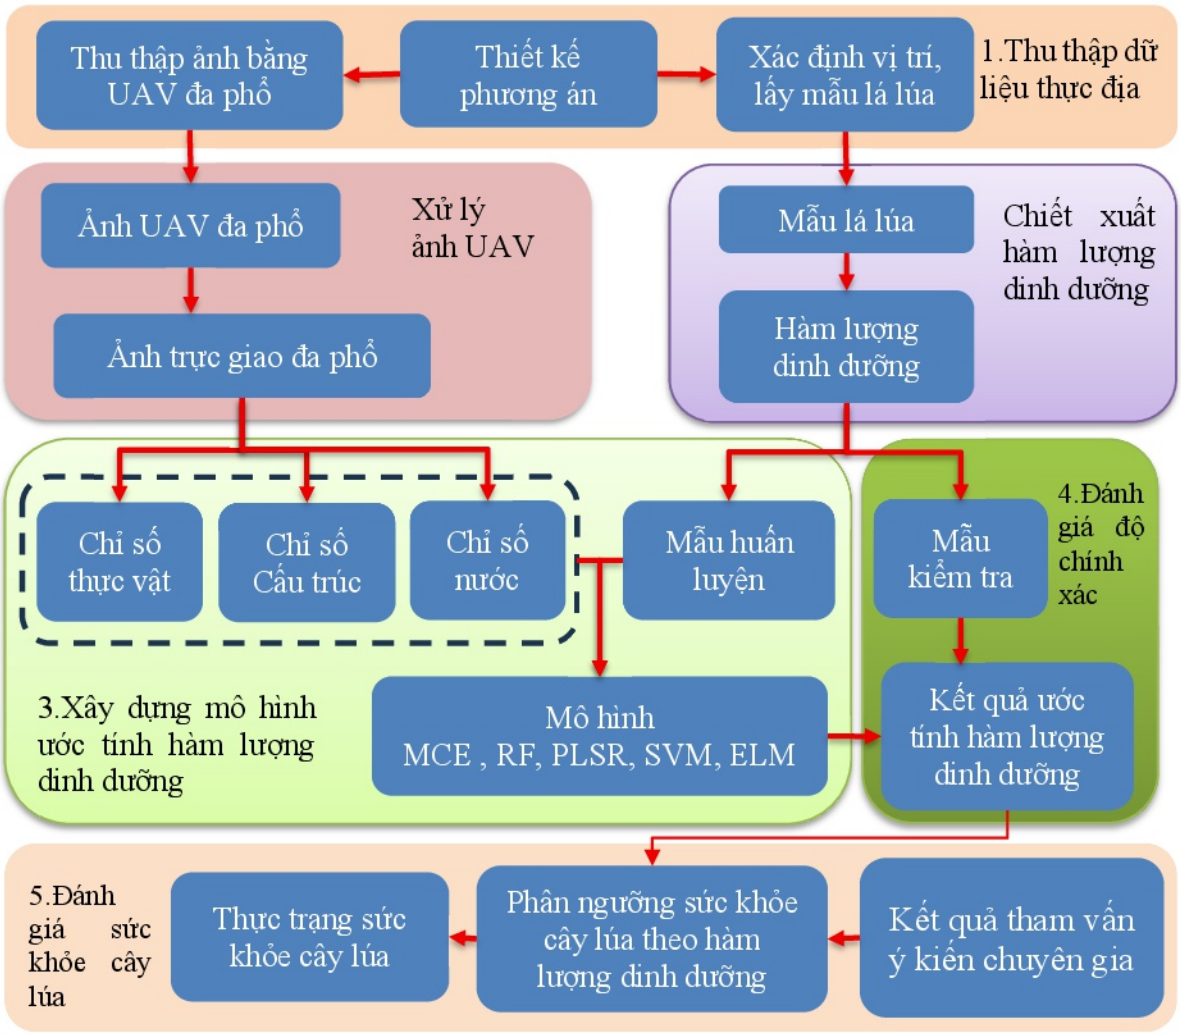
tự động hóa quá trình đánh giá sức khỏe cây lúa, nâng cao độ chính xác và giảm sự phụ thuộc vào đánh giá chủ quan của con người. Các mô hình học máy có khả năng tích hợp đồng thời nhiều chỉ số thực vật, đặc trưng phổ và thông tin không gian, từ đó phát hiện sớm các dấu hiệu bất thường như thiếu dinh dưỡng, stress nước hoặc nhiễm sâu bệnh ngay cả khi các biểu hiện này chưa rõ ràng trên thực địa. Điều này đặc biệt có ý nghĩa trong quản lý sản xuất lúa theo hướng nông nghiệp chính xác.

Mặc dù vậy, tại Việt Nam hiện nay việc ứng dụng đồng bộ dữ liệu UAV đa phổ và các mô hình học máy trong đánh giá sức khỏe cây lúa vẫn còn hạn chế, thiếu các quy trình chuẩn hóa từ khâu thu thập dữ liệu, xử lý ảnh, lựa chọn mô hình đến kiểm chứng kết quả phù hợp với điều kiện canh tác và sinh thái từng vùng. Do đó, việc nghiên cứu và đề xuất quy trình đánh giá sức khỏe cây lúa dựa trên sự kết hợp giữa ảnh UAV đa phổ và các mô hình học máy là hết sức cần thiết, góp phần nâng cao hiệu quả ứng dụng công nghệ số trong sản xuất lúa tại Việt Nam.

Xuất phát từ thực tiễn đó, đề tài "Đề xuất quy trình đánh giá sức khỏe cây lúa từ dữ liệu ảnh UAV đa phổ" có ý nghĩa khoa học và thực tiễn cao, góp phần xây dựng cơ sở khoa học cho việc ứng dụng công nghệ UAV trong nông nghiệp chính xác, hỗ trợ ra quyết định quản lý cây trồng hiệu quả, hướng tới phát triển sản xuất lúa bền vững và hiện đại.

2. Đề xuất quy trình nghiên cứu

Xuất phát từ mục tiêu nghiên cứu của đề tài, từ kết quả tổng quan tài liệu và luận giải vấn đề cần nghiên cứu. Quy trình đánh giá sức khỏe cây lúa từ dữ liệu ảnh UAV đa phổ được đề xuất trên **Error! Reference source not found.**. Quy trình gồm 05 bước chính: xuất phát từ thu thập dữ liệu thực địa, tiếp đến là xử lý dữ liệu, thành lập các mô hình, đánh giá độ chính xác kết quả đạt được và cuối cùng là sự kết hợp giữa ý kiến chuyên gia và bản đồ hàm lượng dinh dưỡng để đánh giá sức khỏe cây lúa.



Hình 1. Quy trình đánh giá sức khỏe cây lúa từ dữ liệu ảnh UAV đa phổ

Bước 1. Thu thập dữ liệu thực địa

Bao gồm công tác khảo sát lựa chọn khu vực thực nghiệm, lựa chọn giống lúa trồng thực nghiệm, xác định thời điểm thu thập dữ liệu phù hợp với các giai đoạn sinh trưởng (Đẻ nhánh, Trổ bông, Chín sữa) của cây lúa. Thiết kế phương án và bay chụp thu nhận ảnh bằng UAV đa phổ;

Thu thập điểm mẫu lá lúa trên thực địa làm dữ liệu huấn luyện và đánh giá độ chính xác mô hình. Tham khảo ý kiến chuyên gia, ý kiến người dân trên thực địa, xác định vị trí cây lúa ở các nhóm sức khỏe khác nhau làm cơ sở phân ngưỡng sức khỏe cây lúa trên ảnh hàm lượng dinh dưỡng.

Bước 2. Xử lý dữ liệu

Ảnh chụp bằng UAV được xử lý trên phần mềm chuyên dụng Agisoft Metashape Professional. Ảnh được hiệu chỉnh phổ phản xạ từ thông tin cảm biến mặt trời, sau đó được ghép bằng thuật toán SIFT, tái tạo ảnh bằng SFM và thành lập ảnh trực giao đa phổ;

Chiết xuất hàm lượng dinh dưỡng trên lá lúa tại các điểm mẫu sử dụng phương pháp ICP-OES. Kết quả hàm lượng tại các điểm mẫu được gán theo tọa độ điểm đã đo bằng công nghệ GNSS/RTK phục vụ chồng ghép, chiết xuất dữ liệu song trùng trên ảnh trực giao đa phổ thành lập từ dữ liệu ảnh UAV.

Bước 3. Thành lập mô hình

Tính 16 VIs, 08 TFs và 02 WIs từ dữ liệu ảnh trực giao đa phổ. Đánh giá tương quan (r) giữa các chỉ số VIs, TFs và WIs với hàm lượng dinh dưỡng tại các điểm mẫu tương ứng để lựa chọn các chỉ số tham gia mô hình ước tính hàm lượng. Dữ liệu đầu vào để xây dựng mô hình ước tính hàm lượng dinh dưỡng cây lúa là các chỉ số được chọn và các điểm mẫu đã chiết xuất hàm lượng dinh dưỡng trên lá.

Thành lập mô hình MCE và các mô hình học máy RF, PLSR, SVM, ELM: dữ liệu đầu vào là các chỉ số VIs, TFs và WIs đã được chọn. Sự kết hợp giữa các chỉ số trong các mô hình được thiết kế để đánh giá được sự đóng góp của chỉ số WIs trong tối ưu hóa các mô hình. Tỷ lệ chia dữ liệu mẫu huấn luyện và kiểm tra cho mô hình được đồng nhất 70%/30% cho mô hình MCE và các mô hình học máy. Các mô hình học máy sử dụng phương pháp K -Fold Cross Validation để huấn luyện, lựa chọn tham số và đánh giá độ ổn định mô hình.

Bước 4. Đánh giá độ chính xác mô hình

Kết quả ước tính hàm lượng dinh dưỡng của các mô hình được đánh giá trên tập dữ liệu kiểm tra. Sử dụng R^2 (R Square) và sai số trung phương (RMSE -Root Mean Square Error) đánh giá độ chính xác mô hình. Mô hình có R^2 lớn nhất và RMSE nhỏ nhất được sử dụng để ước tính và thành lập bản đồ hàm lượng dinh dưỡng của cây lúa;

Đánh giá kết quả ước tính trên toàn khu vực nghiên cứu thông qua sai số trung phương tương đối (rRMSE -Relative Root Mean Square Error), đánh giá sự thay đổi hàm lượng dinh dưỡng cây lúa qua ba giai đoạn đẻ nhánh, trổ bông và chín sữa.

Bước 5. Đánh giá sức khỏe cây lúa

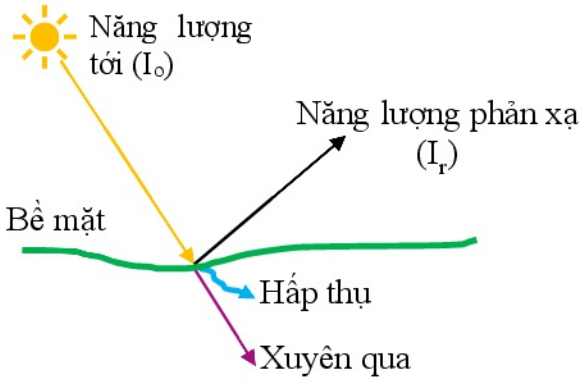
Chồng ghép vị trí khảo sát sức khỏe của cây lúa theo ý kiến chuyên gia và người nông dân trên thực địa với dữ liệu phân bố không gian hàm lượng dinh dưỡng cây lúa đã thành lập từ kết quả ước tính bởi mô hình được chọn. Phân ngưỡng sức khỏe cây lúa theo hàm lượng dinh dưỡng trên toàn khu vực.

Thành lập dữ liệu hiện trạng sức khỏe cây lúa từ giá trị phân ngưỡng và phân bố hàm lượng dinh dưỡng đã ước tính. Đánh giá sức khỏe cây lúa và đề xuất ứng dụng kết quả trong chăm sóc cây lúa theo định hướng nông nghiệp chính xác.

3. Quan hệ giữa phổ phản xạ và đặc trưng sinh học cây lúa

3.1 Phổ phản xạ

Phổ phản xạ là khái niệm chỉ sự phân bố năng lượng phản xạ của một vật thể trên các dải bước sóng khác nhau của ánh sáng. Khi ánh sáng chiếu lên bề mặt vật thể, một phần bị hấp thụ, xuyên qua, trong khi phần còn lại phản xạ trở lại môi trường (Hình 2). Mức độ phản xạ tại từng bước sóng được ghi nhận dưới dạng phần trăm, từ đó hình thành phổ phản xạ đặc trưng phản ánh các tính chất vật lý và hóa học của vật thể [2, 11]. Phân tích phổ phản xạ cung cấp nền tảng để xác định các thành phần cấu tạo và đặc trưng quang học của vật, đặc biệt hữu ích trong các lĩnh vực như nông nghiệp chính xác và viễn thám [25]. Đối tượng khác nhau sẽ có sự phản xạ ánh sáng khác nhau, năng lượng phản xạ khác nhau, phổ phản xạ thu được cũng không giống nhau. Mức độ phản xạ phổ của đối tượng được tính theo công thức (1).



Hình 2 Sơ đồ tương tác ánh mặt trời

$$R_{px} = \frac{I_r}{I_o}.100\% \qquad (1)$$

Trong đó: R_{px} – Phần trăm phản xạ phổ (%)

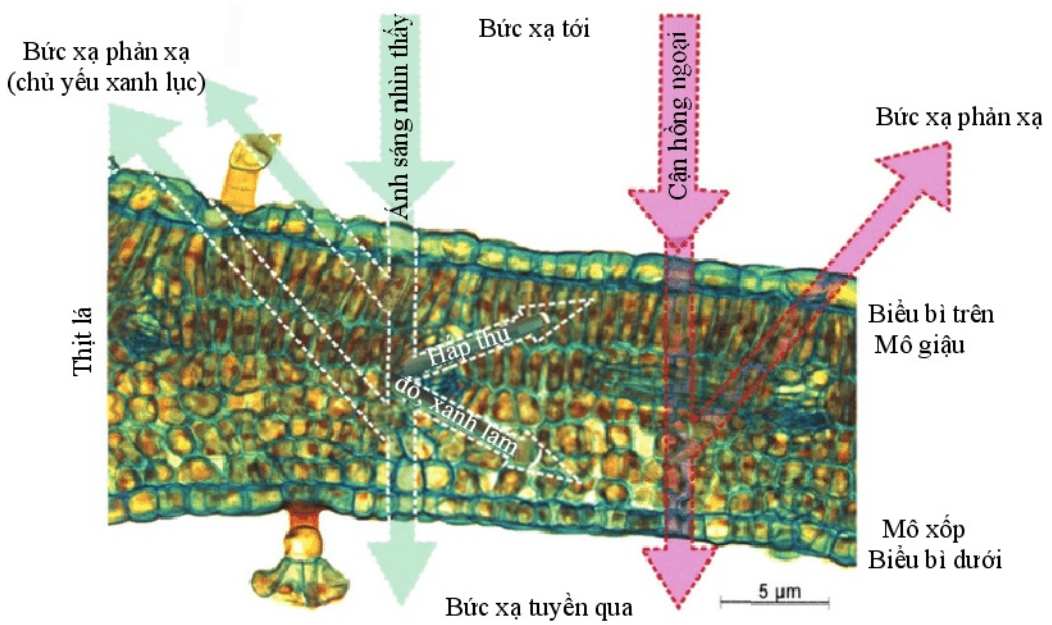
I_o- Năng lượng tới từ nguồn sáng (mặt trời)

I_r – Năng lượng phản xạ

Phổ phản xạ có thể được thu thập bằng nhiều phương pháp với các kỹ thuật và trang thiết bị khác nhau như: sử dụng thiết bị đo phổ phản xạ cầm tay, sử dụng cảm biến trên vệ tinh, và gần đây là cảm biến gắn trên thiết bị bay không người lái (UAV). Mỗi phương pháp này đều có những ưu nhược điểm riêng. Các cảm biến từ xa cho phép thu thập thông tin, không phá hủy mẫu, cung cấp dữ liệu phong phú, có thể tính toán định lượng, đánh giá sự phát triển và sức khỏe cây lúa theo từng giai đoạn khác nhau [5, 6]. Cảm biến gắn trên UAV cho phép thu thập dữ liệu trên diện rộng, thời gian ngắn và có độ phân giải cao [35].

3.2 Quan hệ giữa phổ phản xạ và đặc trưng sinh học của cây lúa

Phổ phản xạ của lá cây cung cấp thông tin quan trọng về đặc trưng sinh lý, phản ánh hàm lượng sắc tố, trạng thái sinh học của thực vật [9, 49, 67]. Ngoài ra, từ đặc điểm phản xạ phổ ở các bước sóng khác nhau cho phép xác định được trạng thái sức khỏe và loại hình sinh thái của thực vật. Đánh giá tình trạng dinh dưỡng, stress môi trường của cây trồng [61, 76]. Do vậy, thông qua phân tích dữ liệu phổ phản xạ, có thể phát hiện các dấu hiệu liên quan đến sự thay đổi trong cấu trúc và hàm lượng chất dinh dưỡng trên lá cây trồng.

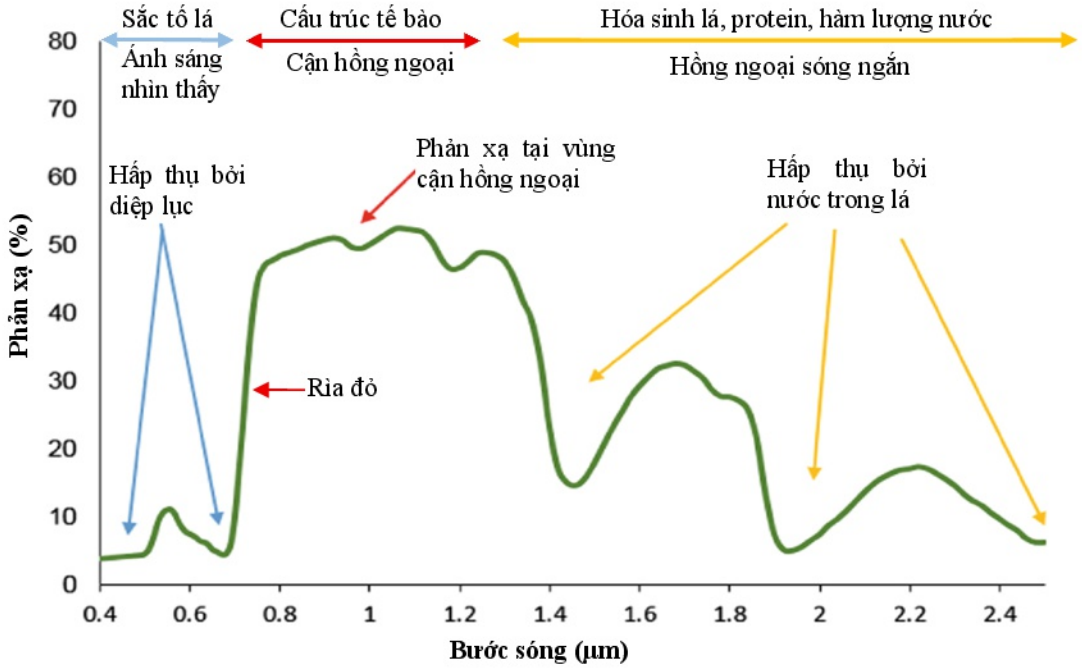


Hình 3 Cấu trúc tế bào của lá cây và sự tương tác với bức xạ điện từ [56]

Hình 3 thể hiện nguyên lý phản ứng với sóng điện từ của lá cây khỏe mạnh nằm trong phạm vi ánh sáng nhìn thấy và cận hồng ngoại. Lá cây khỏe mạnh hấp thụ 70–90% ánh sáng tới, đặc biệt là ở bước sóng xanh lam và đỏ (tập trung lần lượt ở 450 nm và 670 nm), và phản xạ hầu hết ánh sáng xanh lục (tập trung ở 533 nm), đó là lý do tại sao lá cây có màu xanh lục đối với mắt người. Ánh sáng xanh lục được phản xạ trở lại bởi sắc tố diệp lục trong lục lạp của tế bào diệp lục. Ánh sáng xanh lam và đỏ được sắc tố diệp lục trong tế bào diệp lục hấp thụ và sử dụng trong quá trình quang hợp. Tuy nhiên, các bước sóng trong vùng cận hồng ngoại (NIR) chủ yếu bị phản xạ và truyền qua lá, bị tán xạ bởi các giao diện tế bào trong mô trung mô (Hình 3). Đặc điểm này giúp phân biệt các loại cây cối và đánh giá sức khỏe của thảm thực vật từ dữ liệu viễn thám.

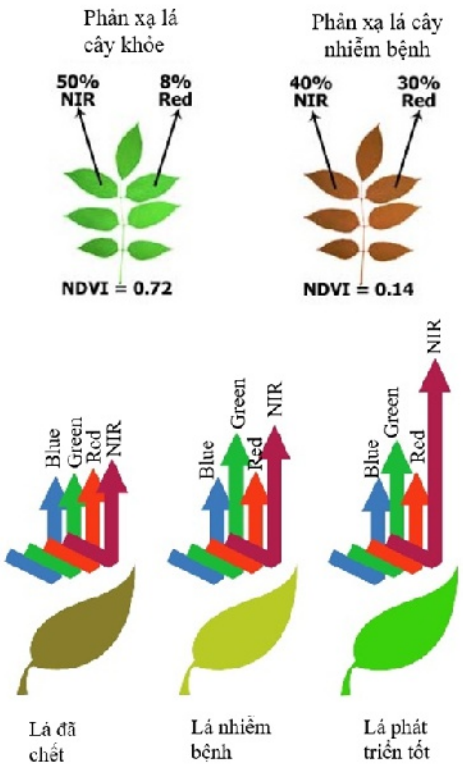
Thiết bị đo phổ hay chụp ảnh quang phổ thu nhận hình ảnh kỹ thuật số của thực vật ở các bước sóng ánh sáng mà tán cây phản xạ được. Biểu đồ phổ phản xạ thực vật Hình 4 có thể cho phép xác định sự thay đổi sinh lý thực vật ở các khoảng phổ phản xạ

khác nhau. Vùng ánh sáng nhìn thấy hữu ích khi phân tích sắc tố lá và hàm lượng chất diệp lục. Bên cạnh đó, phổ phản xạ vùng cận hồng ngoại phù hợp cho đánh giá sự thay đổi của cấu trúc tế bào bên trong lá. Ngoài ra, mức độ thay đổi của hàm lượng protein, hàm lượng nước trong lá lại phù hợp với khoảng sóng vùng hồng ngoại sóng ngắn.



Hình 4 Sơ đồ phổ phản xạ của thực vật [30]

Sự thiếu hụt chất dinh dưỡng đa lượng ảnh hưởng trực tiếp đến hàm lượng chất diệp lục, khả năng hấp thu dưỡng chất, tổng hợp protein,... gián tiếp làm thay đổi tính chất phổ phản xạ của thực vật, đặc biệt vùng ánh sáng nhìn thấy và cận hồng ngoại [4]. Cụ thể, cây lúa thiếu kali, phốt pho giảm khả năng quang hợp, cân bằng nước, chuyển hóa dinh dưỡng và tổng hợp protein. Do đó, cây lúa còi cọc lá hẹp giảm diện tích quang hợp, thân mềm, lá màu xanh sẫm, cháy mép lá [48]. Phân tích sự tương quan với phổ phản xạ khi lá cây cây khỏe mạnh (Hình 3 và Hình 4) cho thấy rằng, thiếu P, K cây lúa giảm khả năng quang hợp dẫn đến lượng diệp lục giảm đi. Do vậy, lá cây phản xạ với ánh sáng màu xanh lục sẽ giảm, kết quả lá có màu xanh tối, do hấp thụ ánh sáng xanh lam và đỏ giảm đi. Ngoài ra, cấu trúc tế bào của lá cây thay đổi, các mô lá không phát triển dẫn đến thân cây mềm, lá hẹp. Mất cân bằng nước trong lá do thiếu dinh dưỡng dẫn đến lá lúa cháy mép, héo. Sự thay đổi sinh lý như vậy của cây lúa dẫn đến thay đổi giá trị phản xạ trên biểu đổ phản xạ phổ.



Hình 5 Thay đổi phản xạ phổ của lá cây

(sửa từ nguồn : https://agristry.com/about/field-mapping/)

Hình 5 thể hiện thông tin phản xạ lá cây ở ba trạng thái: phát triển tốt, nhiễm bệnh, và lá đã chết. Qua đó, có thể nhận thấy rằng lá cây phát triển tốt có sự khác biệt lớn nhất giữa phản xạ trong vùng nhìn thấy và cận hồng ngoại. Khi lá cây nhiễm bệnh, sự cách biệt về phản xạ phổ được thu hẹp và đến khi lá cây chết, gần như phản xạ ở các kênh phổ là như nhau. Dựa vào sự thay đổi trên, chỉ số thực vật khác biệt chuẩn hóa (NDVI) đã được ứng dụng rộng rãi để theo dõi sức khỏe cây trồng. Lá cây khỏe mạnh, mức độ phản xạ với ánh sáng trong khoảng cận hồng ngoại và khoảng sáng màu đỏ có sự khác biệt rất lớn, phần trăm phản xạ tương ứng là 50% và 8%. Tỷ lệ này thay đổi rất lớn khi lá cây bệnh hoặc thiếu chất dinh dưỡng, sự cách biệt chỉ còn 10% (trong đó NIR 40%; red 30%) (Hình 5). Ví dụ này cho thấy rằng khi lá cây khỏe mạnh sự khác biệt giữa phản xạ phổ ở kênh NIR và Re lớn, đồng nghĩa với chỉ số NDVI cao. Ngược lại, khi lá cây nhiễm bệnh, thiếu chất dinh dưỡng làm cho khả năng hấp thụ chất diệp lục của lá cây giảm, kết quả là phổ phản xạ trong kênh NIR giảm và tăng độ phản xạ trong kênh màu đỏ dẫn đến chỉ số NDVI thấp.

Từ phân tích sự thay đổi sinh lý thực vật và mối quan hệ với phổ phản xạ có thể thấy được. Hoàn toàn có thể xác định được sự thay đổi của thực vật thông qua phổ phản xạ trên ảnh viễn thám. Mỗi vùng ánh sáng đặc trưng cho đặc tính riêng của sinh lý thực vật. Trong khoảng ánh sáng nhìn thấy đánh giá được sự thay đổi về hàm lượng diệp lục,

sắc tố lá và chỉ số VIs đã được sử dụng hiệu quả trong trường hợp này (Hình 5 là một ví dụ điển hình). Tính chất thay đổi phổ vùng cận hồng ngoại, hồng ngoại sóng ngắn do sự thay tổi về cấu trúc tế bào bên trong lá cây, độ cứng, độ rộng lá, mức độ xốp, độ ẩm lá cây là cơ sở sử dụng các chỉ số TFs và chỉ WIs.

4. Phương pháp thu thập dữ liệu ảnh UAV đa phổ

4.1 Phương pháp bay chụp ảnh

4.1.1 Thành lập điểm khống chế ảnh mặt đất

Việc đánh giá sức khỏe cây lúa được tiến hành tại nhiều giai đoạn sinh trưởng khác nhau, do đó dữ liệu ảnh UAV cần được thu thập ở các thời điểm tương ứng. Để đảm bảo khả năng chồng ghép ảnh phục vụ cho phân tích và đánh giá, dữ liệu ảnh UAV phải được thu thập trong cùng một hệ tọa độ không gian. Đồng thời, dữ liệu ảnh UAV cần được tích hợp chính xác với các điểm mẫu mặt đất nhằm trích xuất thông tin đồng bộ. Vì vậy, ảnh UAV và vị trí các điểm mẫu cần được đo đạc trong cùng một hệ tọa độ tham chiếu. Để đáp ứng yêu cầu này, các điểm khống chế ảnh mặt đất (GCPs - Ground Control Points) sẽ được thiết lập và đo nối với hệ thống mốc tọa độ cơ sở, đảm bảo tính nhất quán về không gian trong toàn bộ các đợt thu thập dữ liệu.

Điểm khống chế ảnh được bố trị ở các vị trí sao cho đảm bảo độ chính xác cần thiết cho mô hình số bề mặt (DSM-Digital Surface Model) và ảnh trực giao (Orthomosaic), các điểm này nên được sắp xếp hợp lý xung quanh ranh giới khu vực khảo sát, hoặc được phân bố đều khắp khu vực theo cả phương nằm ngang (mặt bằng) và phương thẳng đứng (độ cao) để kiểm soát tốt sai số hình học trong toàn bộ khu đo [43].

Các điểm GCPs được đánh dấu trên mặt đất bằng các tiêu khống chế ảnh. Để các tiêu này nhìn rõ trên ảnh bay chụp, ngoài chất liệu làm tiêu kích thước tiêu thì vị trí đặt tiêu rất quan trọng. Tiêu nên đặt tại vị trí thông thoáng, mặt địa hình bằng phẳng, vị trí an toàn để không bị mất trong suốt quá trình bay, không đặt dưới đường dây điện, không đặt tại nơi có bóng đổ, nơi có độ phản xạ mạnh hoặc cùng màu với chất liệu làm tiêu (làm lóa tiêu, không thấy tiêu).

4.1.2 Lập kế hoạch và chụp ảnh thực địa

Kế hoạch bay chụp ảnh UAV có thể được thực thiết kế trên số phần mềm như: DJI Ground Staion Pro (GS-Pro), DJI Terra, DJI Pilot, Pix4Dcapture, Pix4Dfields... Mặc dù các phần mềm đến từ nhiều hãng khác nhau nhưng đều có chung nguyên lý thiết kế, các thông số cần thiết cần tính toán để thiết lập bao gồm: chiều cao bay chụp, độ phủ trùm ảnh, phương pháp chụp ảnh; ngoài ra các thông số như: điều kiện thời tiết, số lượng dải bay, số ảnh chụp cần thiết, các phần mềm sẽ tính toán từ thông số chính nêu trên.

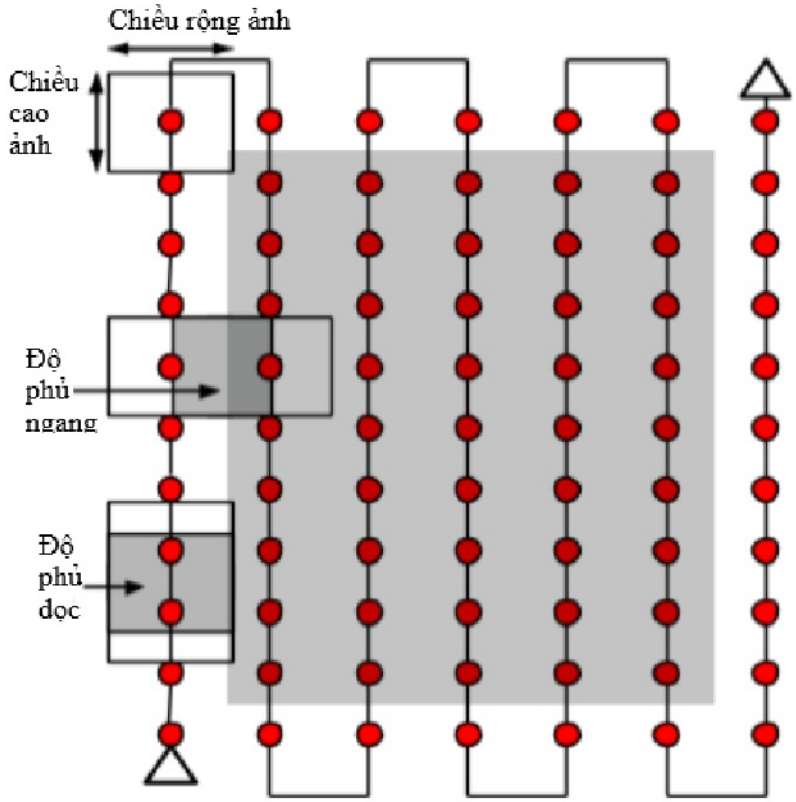
Chiều cao bay chụp của máy bay được tính là khoảng cách từ điểm máy bay cất cánh đến vị trí máy bay bay chụp ảnh theo dải bay đã thiết kế. Để đảm bảo an toàn cho thiết bị bay, chiều cao bay chụp cần được thiết kế cao hơn điểm cao nhất của địa hình tối thiểu 15m [1].

Chiều cao bay chụp tối đa được tính toán từ thông số máy ảnh và độ phân giải ảnh mặt đất, được tính toán theo công thức (2).

$$h_{bc} = \frac{W_{im}.GSD.\ell_f}{W_S.100} \qquad (2)$$

trong đó: W_{im}- độ rộng tấm ảnh (pixel); GSD – độ phân giải ảnh mặt đất cần đạt được (cm); ℓ_f- Chiều dài tiêu cự máy ảnh (mm) và W_S- độ rộng cảm biến máy ảnh. W_{im}, ℓ_f và W_S được lấy từ thông số kỹ thuật máy ảnh sử dụng trên UAV.

Giá trị phủ dọc và phủ ngang tốt nhất phù hợp với đa số địa hình bay chụp là 75%x75% [1]. Độ phủ trùm 75% cho phép độ phủ đủ để toàn bộ đường bay không bị bỏ sót mà không làm ảnh hưởng đến dữ liệu, nhưng không quá cao đến mức dữ liệu thu thập được bị bão hòa và bắt đầu xuất hiện nhiễu.

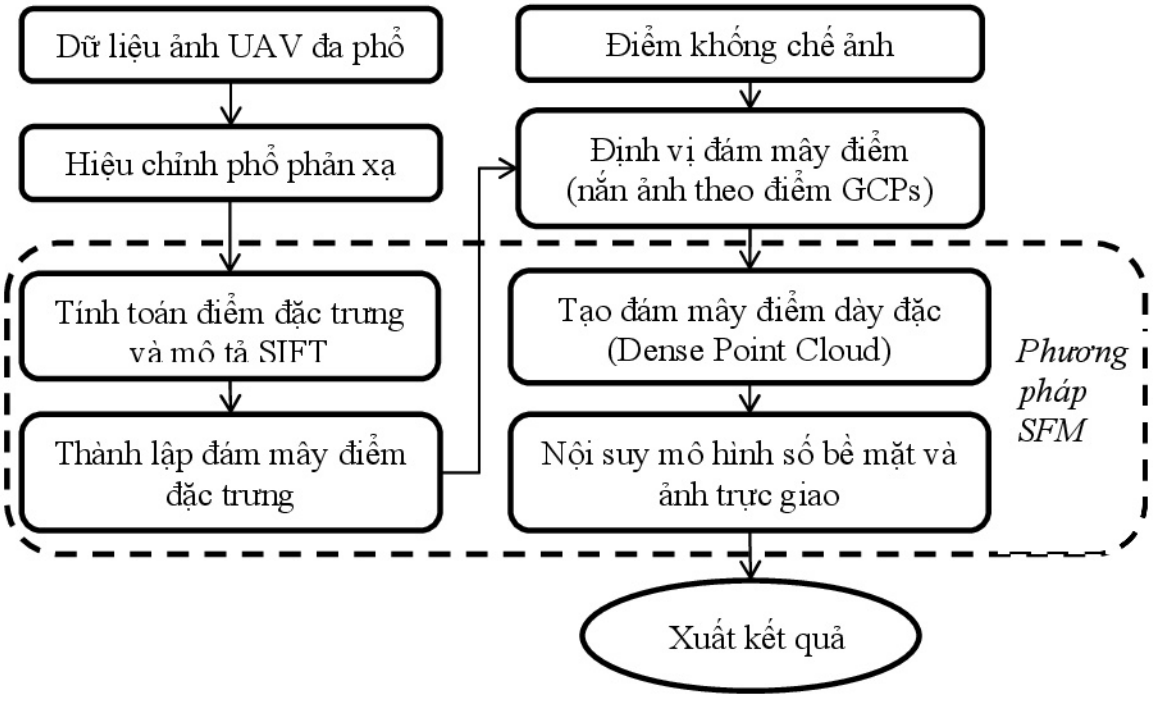


Hình 6 Độ phủ trùm của ảnh bay chụp UAV [1]

4.1.3 Phương pháp xử lý ảnh thành lập ảnh trực giao đa phổ

Dữ liệu ảnh UAV được đánh giá chất lượng, loại bỏ các ảnh lỗi. Các ảnh đảm bảo chất lượng sẽ được xử lý theo quy trình Hình 7 để thành lập ảnh trực giao đa phổ. Theo quy trình này, ảnh UAV được hiệu chỉnh phổ phản xạ, tiếp đến, hai giải thuật được ứng dụng rộng rãi trong các phần mềm xử lý ảnh UAV hiện nay là biến đổi đối tượng phi tỷ lệ (SIFT - Scale-Invariant Feature Transform) và tái tạo hình ảnh dựa vào chuyển động (SFM -Structure-from-Motion) [47] được sử dụng để xây dựng đám mây điểm, mô hình số bề mặt và ảnh trực giao đa phổ.

Hiệu chỉnh phổ phản xạ ảnh chụp: Cảm biến máy ảnh UAV đa phổ ghi nhận được bức xạ mặt trời phản xạ từ các đối tượng ở định dạng số (DNR-Digital Number Reflectance) Hình 8. Do vậy, hiệu chuẩn bức xạ là chuyển đổi các giá trị bức xạ DNR tại cảm biến thành giá trị phản xạ bề mặt tuyệt đối, tính đến sự thay đổi do sự khác biệt về ánh sáng môi trường do thời tiết và mặt trời, và giữa các loại và đơn vị cảm biến. Mối quan hệ giữa giá trị DNR của ảnh và độ phản xạ bề mặt được thiết lập từ giá trị tham chiếu là giá trị phản xạ của tấm chuẩn trắng (Reflectance Standard) hoặc thiết bị đo bức xạ mặt trời (sunlight sensor) (Hình 8).



Hình 7. Quy trình xử lý ảnh UAV đa phổ

Giá trị phổ phản xạ được tính theo công thức (3).

$$R_C^x = \frac{R_{im}^x . \Delta_{im}^x}{R_{hc}^x . \Delta_{hc}^x} \qquad (3)$$

Trong đó:

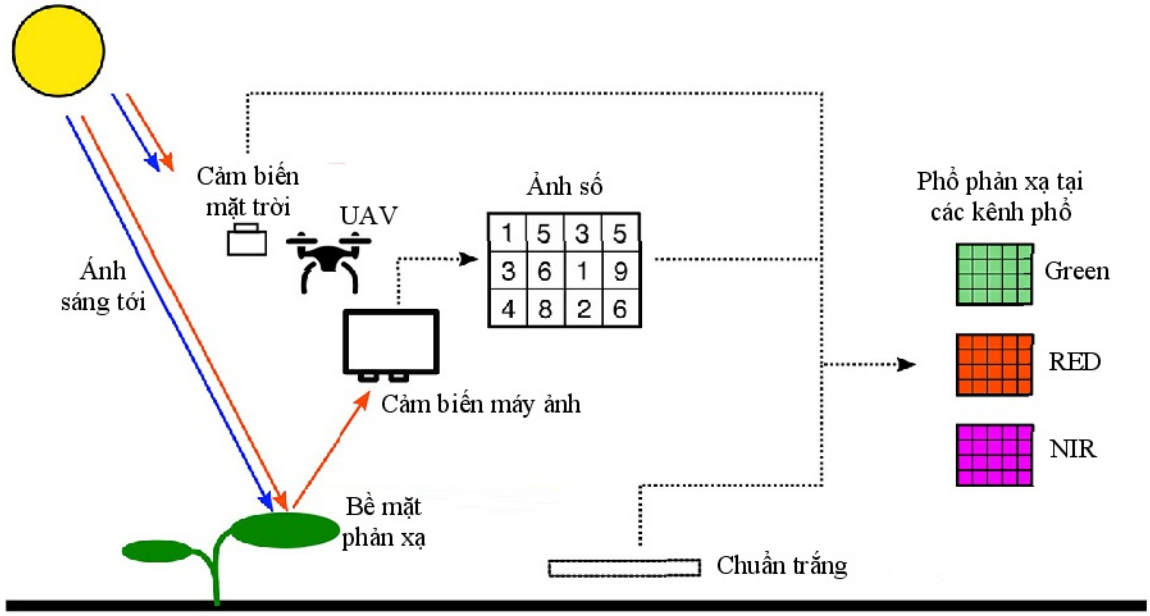
R_C^x – Giá trị phổ phản xạ kênh x sau hiệu chỉnh

R_{im}^x – Giá trị phổ kênh x trên ảnh đa phổ

R_{hc}^x – Giá trị phổ kênh x từ cảm biến mặt trời hoặc chuẩn trắng hiệu chỉnh phổ phản xạ.

Δ_{im}^x – Giá trị hiệu chuẩn phổ phản xạ trên ảnh ở kênh phổ x

Δ_{hc}^x – Giá trị hiệu chuẩn phổ phản xạ của thiết bị tham chiếu kênh x

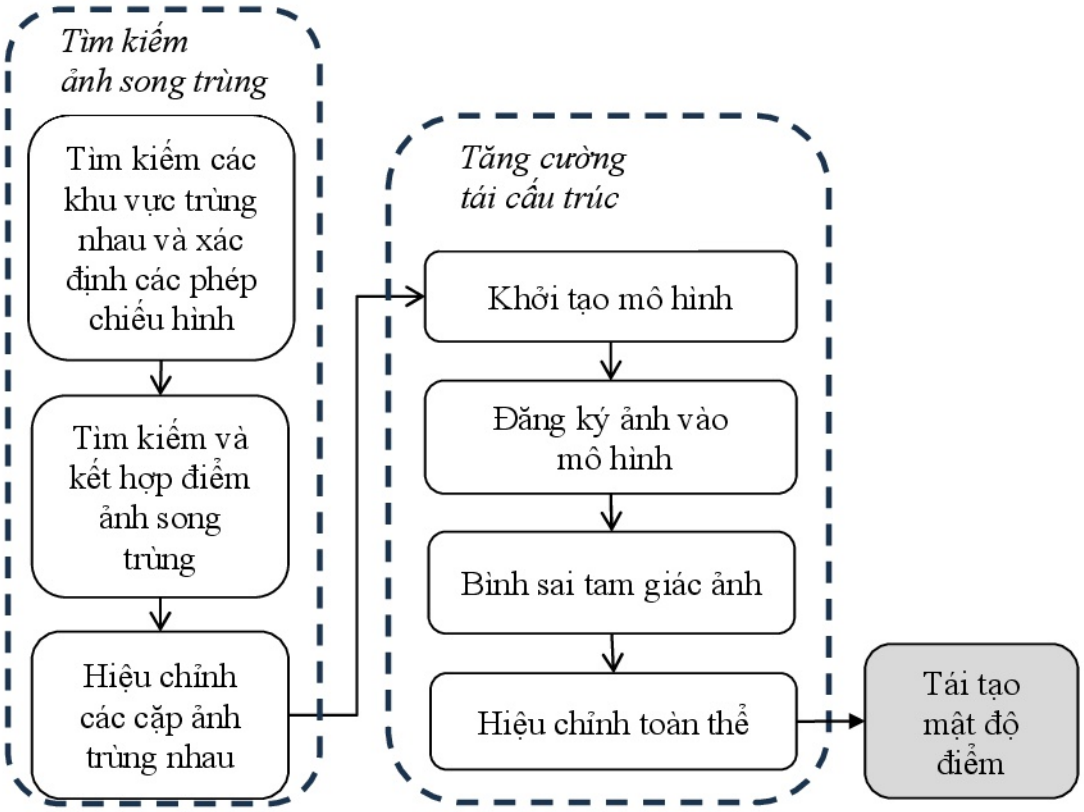


Hình 8 Sơ đồ thu nhận và hiệu chỉnh phổ ảnh UAV đa phổ [3]

Thuật toán SIFT, trích xuất các điểm đặc trưng theo phương pháp lọc theo sơ đồ các bước thực hiện trên Hình 9. Các nội dung cơ bản được đúc rút từ nghiên cứu của Nguyễn Đại Đồng và Cộng sự (2020) bao gồm: (1) sử dụng hàm Different – of Gaussiian để tìm các điểm đặc trưng. (2) sau đó dùng phép lọc Gauss để thay đổi tỷ lệ và chia nhóm các điểm đặc trưng xây dựng hệ không gian ảnh. (3) các điểm cực trị trong không gian ảnh được xác định là giá trị lớn nhất hoặc nhỏ nhất khi so sánh điểm song trùng, với 08 điểm liền kề cùng tỷ lệ và 09 điểm liền kề ở các tỷ khác. (4) các điểm đặc trưng được đánh giá về khả năng ổn định ảnh, nếu làm nhiễu hoặc xoay ảnh thì sẽ bị loại. (5) dựa vào phương pháp hướng dốc cục bộ ([40]) các điểm đặc trưng được định hướng. (6) Cuối cùng toàn bộ điểm đặc trưng của ảnh, mô tả về vị trí, hướng hay véc tơ biểu diễn cho các điểm đặc trưng sẽ được trích xuất phục vụ cho các bước tiếp theo của quá trình xử lý ảnh.



Hình 9 Các bước thực hiện chính trong thuật toán SIFT



Hình 10 Nguyên lý giải thuật SFM [47]

Giải thuật SIFT cho phép xử lý từng bức ảnh đơn lẻ để tìm kiếm các điểm

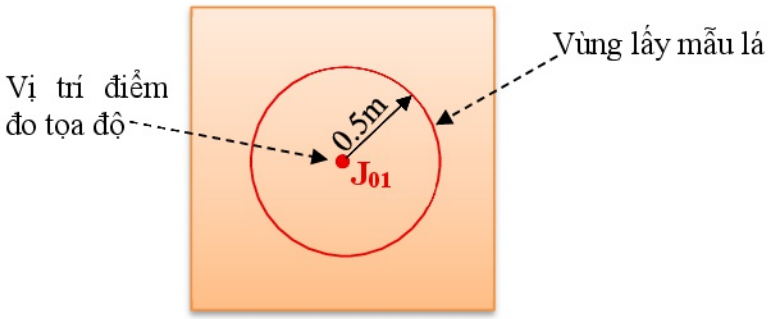
đặc trưng và xây dựng các vector đặc trưng cho từng tấm ảnh riêng biệt. Nhiệm vụ tiếp theo trong chu trình của SfM là đối sánh các điểm đặc trưng sử dụng các thông tin từ các vector đặc trưng xác định trên các ảnh chồng phủ để xây dựng đám mây điểm đặc trưng. Nội dung chính giải thuật SfM được tổng hợp theo sơ đồ các bước thực hiện trên Hình 10. Đám mây điểm 3D Ploint Cloud sẽ được thành lập, là cơ sở để xây dựng mô hình số bề mặt và ảnh trực giao.

4.2 Thu thập mẫu lá lúa

4.2.1 Phương pháp thu thập mẫu

Mẫu lá lúa được thu thập trên thực địa ngay sau khi kết thúc bay chụp ảnh UAV. Mẫu lá được sử dụng cho mục đích làm dữ liệu huấn luyện và kiểm tra độ chính xác mô hình. Trên mỗi ô ruộng lấy mẫu tại ba vị trí, bao gồm hai điểm ở góc và một điểm ở trung tâm để đảm bảo tính đại diện cho toàn bộ ô ruộng.

Chiết xuất giá trị phổ trên ảnh tại các vị trí song trùng với điểm lấy mẫu lá cần được thực hiện khi lựa chọn các chỉ số, huấn luyện các mô hình và đánh giá độ chính xác kết quả ước tính hàm lượng dinh dưỡng. Do vậy, các vị trí lấy mẫu lá trên thực địa sẽ được đo tọa độ bằng công nghệ GNSS động, trong cùng hệ tọa độ với các điểm khống chế ảnh. Tại mỗi điểm đo GNSS, mẫu lá được lấy 10g, đủ số lượng phục vụ công tác chiết xuất hàm lượng dinh dưỡng. Lá lúa ở phía trên, nằm trong bán kính 0.5m quanh điểm đo tọa độ GNSS sẽ được lấy làm mẫu (Hình 11). Mẫu lá lúa được đựng trong túi chuyên dụng, dán mã tương ứng với điểm đo tọa độ GNSS.



Hình 11. Khu vực lấy mẫu lá tại một điểm mẫu

4.2.2 Phương pháp chiết xuất hàm lượng dinh dưỡng trên lá lúa

Hàm lượng dinh dưỡng trên lá lúa tại các điểm mẫu được chiết xuất từ mẫu lá đã được sấy khô bằng thiết bị quang phổ phát xạ quang học Plasma cảm ứng cao tần (ICP-OES - Inductively Coupled Plasma Optical Emission Spectrometry). Cụ thể, 10g lá được sấy ở nhiệt độ 200°C và nghiền mịn đến kích thước hạt nhỏ hơn 200 nm. Một phần 0,2 gam bột thu được được trộn với 9 ml HNO_3 và 1 ml H_2O_2, sau đó được đun nóng ở

200°C trong 1 giờ cho đến khi dung dịch trong suốt, pha với dung dịch nước cất đạt 100ml. Dung dịch này sau đó được chia thành mười phần, mỗi phần 10 ml, và các dung dịch chuẩn tham chiếu với nồng độ phốt pho hoặc kali 40, 50, 60, 70 và 90 ppm được chuẩn bị. Hàm lượng phốt pho hoặc kali (mg/kg) trong các mẫu lá tươi được xác định bằng ICP-OES thông qua việc phân tích cả mẫu và các dung dịch chuẩn (4).

$$Hàm\ lượng\ \left(\frac{mg}{kg}\right) = \frac{C.V}{m} \quad (4)$$

Trong đó: C – nồng độ LPC hoặc LKC đo được (mg/L)

V - Thể tích pha loãng (L)

m – Khối lượng mẫu phân tích (kg)

Hàm lượng dinh dưỡng được tính theo đơn vị (%): 1% = 10 000mg/kg

5. Phương pháp tính và lựa chọn các chỉ số từ dữ liệu ảnh UAV đa phổ

5.1 Chỉ số thực vật

Chỉ số thực vật rất đa dạng, được sử dụng rộng rãi trong lĩnh vực nông – lâm nghiệp với mục đích theo dõi sinh trưởng và phát triển cây trồng. Trên 100 VIs khác nhau đã được đề xuất, một số chỉ số thực vật đã được phát triển qua nhiều nghiên cứu thực nghiệm và được chứng minh có vai trò quan trọng trong việc định lượng các chỉ số sinh hóa của thực vật [71, 74], điển hình như ước tính hàm lượng dinh dưỡng cây nho [51], cây khoai tây [41], cây lúa mỳ [75].

Nghiên cứu về cây lúa, các chỉ số đảm bảo tính đại diện cao trong phản ánh hàm lượng dinh dưỡng của cây lúa bao gồm: NDVI, GNDVI, NDRE, LCI, OSAVI, EVI, DVI, PRI, FCVI, RECI, MSAVI, MSR, SIPI, TVI, MCARI và RVI (**Error! Reference source not found.**). Các chỉ số này bao phủ cả vùng phổ xanh, đỏ, cận hồng ngoại và rìa đỏ, đại diện cho các nhóm đặc tính sinh lý chính như hàm lượng diệp lục (NDRE, LCI, RECI, MCARI), cấu trúc tán lá (NDVI, OSAVI, MSAVI), hoạt động quang hợp (PRI, SIPI) và ảnh hưởng của nền đất (MSR, OSAVI) [36, 68]. Các nghiên cứu gần đây đã xác nhận rằng các chỉ số này có khả năng phản ánh đáng tin cậy hàm lượng diệp lục và cấu trúc lá, những chỉ tiêu quan trọng trong đánh giá tình trạng dinh dưỡng của cây lúa [36, 66, 70]. Chẳng hạn, NDRE và LCI đã được chứng minh là có tương quan cao với hàm lượng protein hạt và diệp lục lá [36, 66], trong khi MCARI và RECI có độ nhạy cao ở giai đoạn sinh trưởng muộn [70]. Các chỉ số VIs nêu trên, có độ nhạy khác nhau với đặc tính sinh lý thực vật, và độ nhạy của cùng một chỉ số cũng không giống nhau ở các giai đoạn sinh trưởng cây lúa. Do vậy, việc khảo sát và lựa chọn tập hợp chỉ số này giúp chọn được các chỉ số tối ưu, giảm dư thừa thông tin, tăng tính bổ sung lẫn nhau

giữa các chỉ số và nâng cao hiệu quả mô hình hóa trong điều kiện canh tác lúa sử dụng ảnh UAV [68].

Bảng 1 Chỉ số thực vật

STT	Chỉ số thực vật VIs	Công thức tính	Tham khảo
1	Difference Vegetation Index (DVI)	$DVI = R_{NIR} - R_R$	[32]
2	Enhanced Vegetation Index (EVI)	$EVI = 2.5(R_{NIR} - R_R)/(\rho_{NIR} + 6R_R - 7.5R_B + 1)$	[29]
3	False Color Vegetation Index (FCVI)	$FCVI = 1.5(2R_{NIR} + R_B - 2R_G)/(2R_G + 2R_B - 2R_{NIR} + 127.5)$	[31]
4	Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = (R_{NIR} - R_G)/(R_{NIR} + R_G)$	[8]
5	Leaf Chlorophyll Index (LCI)	LCI $=(R_{NIR}/R_{RE})-1$	[26]
6	Modifid Chlorophyll Absorption In Reflectance Index (MCARI)	$MCARI = R_{RE} - R_R - 0.2(R_{RE} - \rho_G)R_{RE}/R_R$	[15]
7	Modified Soil Adjusted Vegetation Index (MSAVI)	$MSAVI = 0.5(2R_{NIR} + 1 - \sqrt{(2R_{NIR} + 1)^3 - 8(R_{NIR} - R_R)})$	[54]
8	Modified Simple Ratio (MSR)	$MSR = ((R_{NIR}/R_R) - 1)/((R_{NIR}/R_R) + 1)$	[12]
9	Normalized Difference Red Edge Index (NDRE)	NDRE$=(R_{NIR} - R_{RE})/(R_{NIR} + R_{RE})$	[22]
10	Normalized Difference Vegetable Index (NDVI)	NDVI $= (R_{NIR} - R_R)/(R_{NIR} + R_R)$	[58]
11	Optimized Soil Adjusted Vegetation Index (OSAVI)	$OSAVI = (R_{NIR} - R_R)/(R_{NIR} + R_R + 0.16)$	[57]
12	Photochemical Reflectance Index (PRI)	PRI$=(R_G - R_B)/(R_G + R_B)$	[21]
13	Red Edge Chlorophyll Index (RECI)	$RECI = (R_{NIR} - R_{RE})/R_{RE}$	[24]

14	Ratio Vegetation Index (RVI)	$RVI = R_{NIR}/R_R$	[32]
15	Transformed Vegetation Index (TVI)	$TVI = (R_G - R_R)/(R_G + R_R)$	[7]
16	Structure-Intensive Pigment Index (SIPI)	$SIPI = (R_{NIR} - R_B)/(R_{NIR} + R_B)$	[52]

Trong đó R_R, R_G, R_B, R_{RE} và R_{NIR} là phổ phản xạ trên ảnh tương ứng các kênh phổ Red, Green, Blue, Red -edge và Near Infrared.

VIs được lựa chọn ngoài chỉ tiêu có tính diện cao trong phản ánh hàm lượng dinh dưỡng của cây lúa nêu trên, cần phải đảm bảo được tính từ các kênh phổ (Red, Blue, Green, Re-edge và Nir) có thể thu nhận được trên cảm biến của máy ảnh trên UAV đa phổ sử dụng thu thập dữ liệu. Trong hầu hết các công thức tính VIs có sự xuất hiện của kênh Nir và Re (Bảng 1), kết quả này giải thích tại sao Nir và Re lại được xem là có độ nhạy cao với sự thay đổi sinh lý thực vật.

5.2 Chỉ số cấu trúc (TFs)

5.2.1 Chỉ số cấu trúc

Chỉ số cấu trúc (TFs - Texture Features) là yếu tố quan trọng trong hình ảnh, phản ánh sự phân bố không gian của độ sáng giữa các điểm ảnh lân cận và có thể giúp phát hiện sự thay đổi về tông màu thông qua phương sai cục bộ [28, 33]. Trong quá trình sinh trưởng của cây trồng, sự thay đổi về hàm lượng dinh dưỡng làm biến đổi màu sắc lá, hàm lượng diệp lục và độ ẩm, từ đó ảnh hưởng đến cấu trúc và phổ phản xạ của tán cây. Các chỉ số TFs thu được từ dữ liệu phổ có thể mô tả đặc điểm hình thái của tán cây và cải thiện khả năng phát hiện tín hiệu liên quan đến hàm lượng dinh dưỡng trên lá từ dữ liệu ảnh viễn thám [75]. Chỉ số TFs được tính từ ảnh trực giao đa phổ theo các công thức trên Bảng 2.

Bảng 2 Các chỉ số cấu trúc [75]

STT	Chỉ số	Ý nghĩa	Công thức tính
1	Contrast (CON)	Biểu thị sự biến đổi cục bộ của ma trận	$\sum_{i=1}^{n}\sum_{j=1}^{n}(i-j)^2 P_{i,j}$
2	Correlation (COR)	Phản ánh thước đo độ tuyến tính của hình ảnh giữa pixel	$\sum_{i=1}^{n}\sum_{j=1}^{n}\frac{(i-MEA_j)(j-MEA_j)P_{i,j}}{\sqrt{VAR_i}.\sqrt{VAR_j}}$

3	Dissimilarity (DIS)	Phản ánh sự khác biệt trong thang độ xám	$\sum_{i=1}^{n}\sum_{j=1}^{n}\lvert i-j\rvert P_{i,j}$
4	Entropy (ENT)	Biểu thị mức độ sự rối loạn trong ma trận	$-\sum_{i=1}^{n}\sum_{j=1}^{n}P_{i,j}\,logP_{i,j}$
5	Homogeneity (HOM)	Biểu thị sự biến đổi cục bộ của ma trận	$\sum_{i=1}^{n}\sum_{j=1}^{n}\frac{P_{i,j}}{1+(i-j)^2}$
6	Mean (MEA)	Phản ảnh độ xám trung bình của các pixel	$\sum_{i,j=1}^{n}iP_{i,j}$
7	Second moment (SEC)	Biểu thị mức độ đồng nhất của phân bố độ xám	$\sum_{i=1}^{n}\sum_{j=1}^{n}P_{i,j}^2$
8	Variance (VAR)	Mô tả sự phân tán của các giá trị xung quanh giá trị trung bình	$\sum_{i=1}^{n}\sum_{j=1}^{n}iP_{i,j}(i-MEA)^2$

Trong đó: i,j là giá trị độ xám của cặp pixcel liền kề (i,j), P(i,j) là tần suất xuất hiện của cặp giá trị độ xám (i,j).

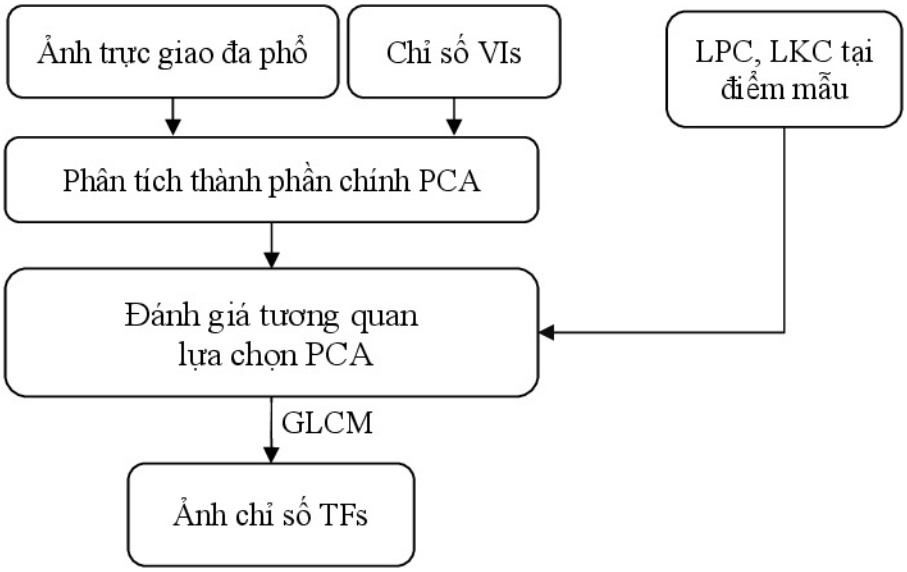
5.2.2 Phương pháp chiết xuất chỉ số cấu trúc

Quy trình chiết xuất và lựa chọn chỉ số TFs được tổng hợp trên Hình 12. Dữ liệu ảnh đầu vào chiết xuất chỉ số TFs bao gồm: ảnh trực giao có 5 kênh phổ và ảnh 16 chỉ số VIs đã được chiết xuất, tổng số 21 ảnh được sử dụng. Việc giảm chiều dữ liệu là cần thiết trước khi tính TFs. Do vậy, TFs được tính từ ảnh thành phần tính bởi Phương pháp phân tích thành phần chính (PCA-Principal Component Analysis). PCA là giải pháp được sử dụng phổ biến trong trường hợp này, với ưu điểm tổng hợp được các đặc trưng riêng của từng kênh phổ, đồng thời PCA cũng được chứng minh là giải pháp tránh được sự đa cộng tuyến giữa các kênh phổ.

Các chỉ số TFs được tính toán từ ảnh PCA có khả năng diễn giải hàm lượng dinh dưỡng trên 90%, cụ thể là kết quả của hai PCA đầu tiên. Kết quả PCA được đánh giá tương quan với hàm lượng dinh dưỡng tại các điểm mẫu, PCA có tương quan lớn nhất (r_{max}) sẽ được chọn để chiết xuất các chỉ số TFs.

TFs chiết xuất từ ảnh PCA (đã được chọn) thông qua ma trận đồng nhất cấp độ xám (GLCM - Gray-Level Co-occurrence Matrix). Đây là phương pháp sử dụng phổ biến trong phân tích cấu trúc trên ảnh. GLCM biểu diễn thống kê về tần suất đồng thời xuất hiện của các cặp mức xám tại hai điểm ảnh với mối quan hệ không gian xác định

trong một hình ảnh, và có khả năng phản ánh hiệu quả mối tương quan giữa các mức xám của cấu trúc [28, 38]. Cửa sổ GLCM kích thước 3x3 được sử dụng chiết xuất 8 chỉ số TFs theo công thức tính trên Bảng 2.



Hình 12 Sơ đồ quy trình chiết xuất chỉ số cấu trúc

5.3 Chỉ số nước

Trong nhóm chỉ số nước (WIs), NDWI và NSRI được sử dụng vì hai chỉ số này có thể tính toán từ các kênh phổ có trên ảnh thu nhận được từ UAV đa phổ. Trong khi, các chỉ số WIs khác không áp dụng được do yêu cầu các kênh phổ nằm ngoài dải bước sóng mà cảm biến của UAV đa phổ sử dụng thực nghiệm có thể thu nhận. Cụ thể, chỉ số NDWI được tính toán từ hai kênh phổ Green và Nir [44] được trình bày trong công thức (5). Bên cạnh đó, NSRI được định nghĩa là tỷ số giữa phản xạ phổ tại kênh Nir và Re [39], được tính theo công thức (6).

$$NDWI = \frac{R_G - R_{NIR}}{R_G + R_{NIR}} \quad (5)$$

$$NSRI = \frac{R_{NIR}}{R_{RE}} \quad (6)$$

Trong đó: R_{NIR}, R_{RE} và R_G - giá trị phổ phản xạ trên ảnh đa phổ của kênh cận hồng ngoại, rìa đỏ và xanh lá.

5.4 Phương pháp lựa chọn các chỉ số

Hệ số tương quan (Pearson Correlation Coefficients) ký hiệu là r, thể hiện mức độ gắn kết giữa các đối tượng. Khi phổ phản xạ thay đổi, phản ánh sự khác biệt về đặc tính của thực vật, từ đó làm thay đổi mức độ tương quan giữa các đối tượng, đồng thời ảnh hưởng đến phương sai trong dữ liệu [53]. Do vậy, r được sử dụng làm cơ sở lựa chọn

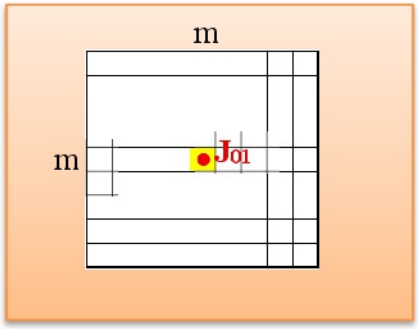
các chỉ số VIs, TFs và WIs phục vụ ước tính hàm lượng dinh dưỡng, r có giá trị nằm trong khoảng từ -1 đến 1 và được tính theo công thức (7).

$$r = \frac{\Sigma_1^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\Sigma_1^n (x_i - \bar{x})^2} . \sqrt{\Sigma_1^n (y_i - \bar{y})^2}} \quad (7)$$

Trong đó: x_i, y_i: giá trị thứ i của hai biến đánh giá tương quan x và y

$\bar{x}, \bar{y}$: giá trị trung bình của x_i, y_i

Áp dụng tính r giữa các chỉ số với hàm lượng dinh dưỡng tại các điểm mẫu, x sẽ là giá trị phổ trên ảnh và y là giá trị dinh dưỡng trên lá tại các điểm mẫu. Giá trị x được chiết xuất trên ảnh tương ứng của chỉ số đánh giá thuộc nhóm VIs, TFs và WIs.



J_{01} – Điểm lấy mẫu lá
m – số hàng, cột pixcel trong vùng thống kê quanh điểm mẫu J_{01}

Hình 13 Vùng thống kê giá trị phổ trên ảnh các chỉ số tại điểm mẫu J_{01}

Điểm mẫu lá lúa có tọa độ đo GNSS trên thực địa, được chuyển lên các ảnh chỉ số để chiết xuất giá trị song trùng. Tuy nhiên, giá trị đo là tọa độ là 01 điểm, để đủ 10g mẫu lá, lá lúa đã được lấy trong bán kính 0.5m quanh điểm đo này. Do vậy, để đảm bảo thu được giá trị khách quan, trên ảnh chỉ số, tạo vùng có diện tích S với kích thước 0.8mx0.8m và tâm là vị trí đo tọa độ GNSS (Hình 13). Giá trị phổ phản xạ của điểm mẫu trên ảnh chỉ số, là giá trị trung bình của các pixcel trong vùng diện tích S.

Mức độ tương quan giữa biến dự báo và biến mục tiêu được phân cấp theo nghiên cứu của Andy (2009) được thể hiện trên Bảng 3. Qua đó r có giá trị từ không tương quan, tương quan thuận và nghịch được chia làm 03 mức: thấp, trung bình và cao. Trong các mô hình, r đo lường độ mạnh và hướng của mối quan hệ tuyến tính giữa biến dự báo và biến mục tiêu, hệ số r càng cao thì khả năng suy diễn của mô hình càng tốt. Do vậy, các chỉ số VIs, TFs và WIs có hệ số tương quan cao ($r > \pm 0.5$) sẽ được chọn để tiếp tục đánh giá khả năng sử dụng trong các mô hình ước tính hàm lượng dinh dưỡng.

Bảng 3. Mức độ tương quan [20]

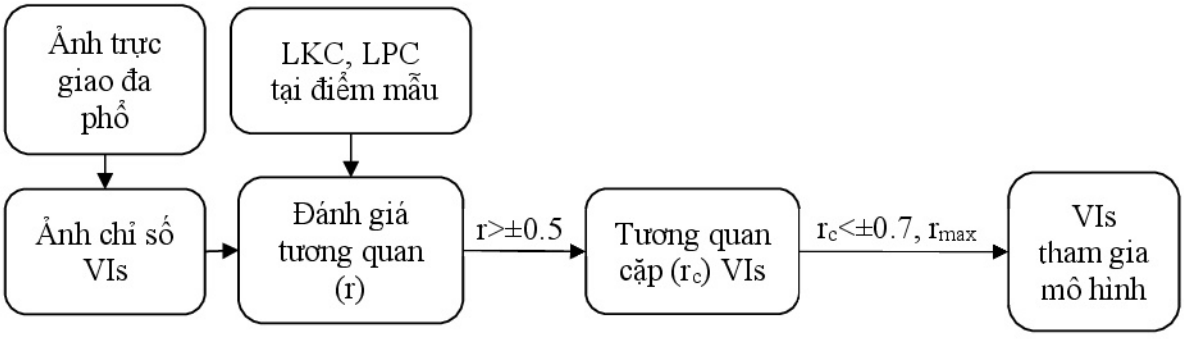
TT	Xu hướng	Mức độ tương quan	Tương quan (r)
1	Tương quan thuận	Cao	0.5 ÷ 1.0
2		Trung bình	0.3 ÷ 0.5
3		Thấp	0.0 ÷ 0.3

4	Không tương quan		0.0
5	Tương quan nghịch	Thấp	0.0 ÷ -0.3
6		Trung bình	-0.3 ÷ -0.5
7		Cao	-0.5 ÷ -1.0

Việc sử dụng đồng thời nhiều chỉ số phổ, đặc biệt khi không thực hiện bước chọn lọc ban đầu, có thể dẫn đến sự dư thừa và trùng lặp thông tin giữa các biến đầu vào, từ đó làm suy giảm hiệu suất của các mô hình phân loại và hồi quy [34]. Mặt khác, do các chỉ số thường được tính toán từ cùng một tập dữ liệu ảnh UAV đa phổ với số lượng kênh phổ hạn chế, hiện tượng đa cộng tuyến giữa các chỉ số là khó tránh khỏi, ảnh hưởng tiêu cực đến độ chính xác của mô hình ước tính. Nghiên cứu hồi quy đa biến cho thấy, việc lựa chọn các chỉ số VIs và TFs một cách có chọn lọc trước khi xây dựng mô hình sẽ mang lại kết quả ước tính hàm lượng dinh dưỡng cây trồng chính xác hơn [41]. Mức độ đa cộng tuyến được coi là cao khi hệ số tương quan giữa hai biến đạt $r_c > 0.7$ [37].

Khi xảy ra đa cộng tuyến giữa hai chỉ số, chỉ số có hệ số tương quan (r) cao hơn với biến mục tiêu thường được ưu tiên lựa chọn, do thể hiện mối liên hệ tuyến tính mạnh hơn với biến mục tiêu [64]. Bên cạnh đó, các chỉ số nhóm VIs, TFs và WIs được lựa chọn chỉ số riêng cho từng nhóm trước khi kết hợp trong mô hình. Cần xét đến xu hướng tương quan thuận ($0< r < 1$) và tương quan nghịch ($-1 < r < 0$) của các chỉ số. Vì mối quan hệ tuyến tính thuận – nghịch cũng có vai trò nền tảng trong xác định trọng số của hàm MCE và trong các mô hình học máy.

Chỉ số VIs được lựa chọn theo quy trình Hình 14. VIs được đánh giá tương quan với hàm lượng dinh dưỡng tại các điểm mẫu. Các chỉ số VIs có $r> \pm 0.5$ sẽ được lựa chọn và tiến hành đánh giá tương quan cặp (r_c). Cặp chỉ số VIs có $r_c<\pm 0.7$, được xem xét đánh giá tiếp theo. Trong một cặp chỉ số, giá trị tương quan cao với hàm lượng dinh dưỡng của chỉ số nào lớn hơn (r_{max}), chỉ số đó sẽ được lựa chọn tham gia mô hình ước tính hàm lượng dinh dưỡng.



Hình 14 Sơ đồ quy trình chiết xuất và lựa chọn chỉ số thực vật

Chỉ số TFs được chiết xuất được theo sơ đồ quy trình Hình 12, chỉ số WIs được chiết xuất từ ảnh trực giao đa phổ. Hai nhóm chỉ số này cũng được lựa chọn tương tự

phương pháp chọn chỉ số VIs.

5.5. Phương pháp kết hợp các chỉ số

Sự kết hợp giữa các nhóm chỉ số được tính toán dựa trên đặc điểm các chỉ số đã được lựa chọn tham gia mô hình ước tính LPC và LKC. Nguyên tắc kết hợp các chỉ số theo mục tiêu đánh giá được sự đóng góp của nhóm chỉ số nước trong các mô hình ước tính. Trong đó, kết hợp nhóm VIs và TFs đã được nghiên cứu cho thấy sự hiệu quả trong ước tính hàm lượng dinh dưỡng [19, 75]. Do vậy, tổ hợp 1 sẽ là sự kết hợp của các chỉ số trong nhóm này (Bảng 4). Nhóm WIs bao gồm hai chỉ số NSRI và NDWI có xu hướng tương quan trái ngược nhau với LPC và LKC. Do vậy, ở tổ hợp 2 và 3 sẽ sử dụng để đánh giá sự đóng góp riêng lẻ của từng chỉ số NSRI và NDWI trong mô hình ước tính LPC và LKC. Tổ hợp 4 sẽ đánh giá kết quả của kết hợp toàn bộ các chỉ số thuộc cả ba nhóm VIs, TFs và WIs.

Bảng 4 Phương án kết hợp các chỉ số

Tổ hợp	**Đặc điểm kết hợp các nhóm chỉ số**
1	VIs với TFs, không bao gồm WIs
2	VIs, TFs với NSRI (nhóm WIs)
3	VIs, TFs với NDWI (nhóm WIs)
4	Tổng hợp VIs, TFs và WIs

Các phương án trên Bảng 4 là cơ sở kết hợp các chỉ số đầu vào cho các mô hình ước tính hàm lượng dinh dưỡng. Mỗi tổ hợp sẽ được thực hiện trên từng mô hình, đánh giá độ chính xác đạt được và đánh giá mức độ đóng góp của các chỉ số nhóm WIs trong việc tối ưu hóa mô hình ước tính LKC và LPC.

6 Mô hình ước tính hàm lượng dinh dưỡng

6.1 Phương pháp đánh giá đa tiêu chí (MCE)

6.1.1 Đánh giá đa tiêu chí

Đánh giá đa tiêu chí (MCE) là phương pháp quyết định với các tình huống phức tạp có nhiều phương án khác nhau. Mỗi phương án được đánh giá trên nhiều tiêu chí khác nhau và có thể bị xung đột. Cơ sở toán học của MCE là một mô hình ra quyết định đa tiêu chí (MCDM -Multi-Criteria Decision Making). Trong đó, dữ liệu được biểu diễn thông qua mô hình ma trận và các hàm tổng hợp có trọng số nhằm đánh giá và xếp hạng các lựa chọn một cách hệ thống [23, 42]. Mỗi tiêu chí được gán một trọng số nhằm phản ánh mức độ quan trọng tương đối của nó trong toàn bộ quá trình đánh giá. Dữ liệu trong

ma trận sau đó được tổng hợp thông qua các hàm tổng hợp có trọng số, như mô hình tổng trọng số (WSM -Weighted Sum Model), phương pháp phân tích thứ bậc (AHP), hoặc kỹ thuật xếp hạng theo độ gần với giải pháp lý tưởng (TOPSIS), nhằm tạo ra một chỉ số tổng hợp cho mỗi phương án. Dựa trên các chỉ số này, các phương án được xếp hạng để hỗ trợ việc ra quyết định tối ưu [13, 63].

Hàm tổng hợp Y được xét đa tiêu chí theo công thức (8), với các biến số X là các chỉ số tốt nhất đã được chọn trong các nhóm chỉ số VIs, TFs và WIs.

$$Y = \sum_{i=1}^{n} P_i X_i \qquad (8)$$

Trong đó: Y – Hàm tổng hợp

P_i – Trọng số của biến i

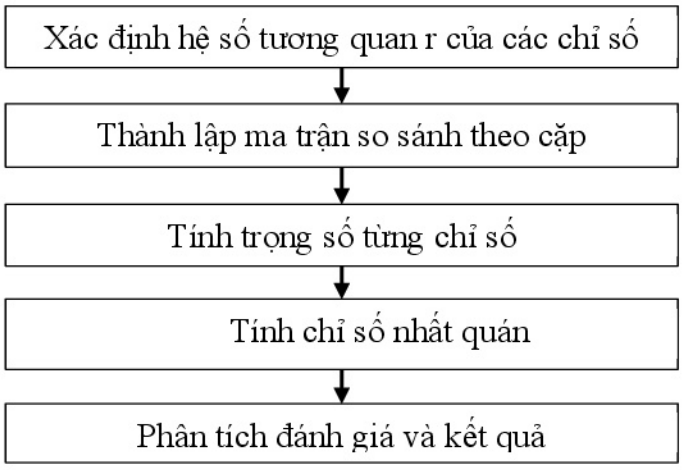
X_i - Giá trị của biến i

n – Số lượng biến số

Trong nghiên cứu này, trọng số P_i được tính theo phương pháp phân tích thứ bậc AHP. Trọng số được tính dựa trên mức độ tương quan với hàm lượng dinh dưỡng của các chỉ số đầu vào. Trong AHP, phương pháp cân bằng trọng số (các giá trị có trọng số như nhau) được sử dụng. Trọng số P_i cho tương quan cao nhất với hàm lượng dinh dưỡng được lựa chọn.

6.1.2 Tính trọng số theo phương pháp phân tích thứ bậc AHP

Quy trình tính trọng số cho hàm MCE theo phương pháp AHP với biến số đầu vào là các chỉ số VIs, TFs và WIs tham gia tính MCE (Hình 15).



Hình 15 Quy trình xác định trọng số theo AHP

+ *Xác định hệ số tương quan của các chỉ số:* Các chỉ số VIs, TFs và WIs được đánh giá tương quan (r) với hàm lượng dinh dưỡng. Các chỉ số được chọn tham gia mô hình MCE được đánh giá thông quan mức độ tương quan r. Hệ số tương quan r sẽ được

sử dụng làm cơ sở để tính trọng số theo AHP.

+ Thành lập ma trận so sánh cặp:

So sánh n chỉ số được ký hiệu A1, A2,… , An theo mức độ quan trọng và đánh giá theo cặp, tổng số cặp chỉ số được so sánh sẽ là n(n-1)/2 [10]. Ma trận kết quả A có kích thước n x m thể hiện mối quan hệ của các nhân tố với nhau, trong đó phần tử a_{ij} thể hiện mức độ quan trọng của chỉ số ở hàng i so với chỉ số ở cột j. Mối quan hệ giữa các nhân tố được đánh giá thông qua so sánh mức độ quan trọng với tiêu chí trên Bảng 5.

Bảng 5 Mức độ so sánh giữa các chỉ số [60]

Mức độ quan trọng	Định nghĩa	Giải nghĩa
1	Quan trọng như nhau	Hai chỉ số i và j đóng góp như nhau
3	Tầm quan trọng trung bình	Kinh nghiệm và phán đoán thiên về i hơn chỉ số j
5	Tầm quan trọng mạnh	Kinh nghiệm và phán đoán thiên hẳn i
7	Tầm quan trọng rất mạnh	Chỉ số i được ưu tiên rõ ràng và có sự vượt trội hơn j
9	Tầm quan trọng tuyệt đối	Bằng chứng cho thấy i vượt trội hơn j và ở mức cao nhất
2, 4, 6, 8	Mức trung gian giữa các mức liền kề	Sử dụng khi cần thỏa hiệp

Ma trận so sánh cặp được thành lập theo nguyên tắc mỗi phần tử đại diện cho một cặp so sánh, các phần tử phía trên và phía dưới đường chéo chính có giá trị nghịch đảo nhau như trên Bảng 6.

+ Tính trọng số cho từng chỉ số

Ma trận so sánh cặp trên Bảng 6 được chuẩn hóa. Giá trị thành phần được xác định trọng số bằng tỷ lệ của các thành phần ở các hàng trong cùng một cột chia cho giá trị tổng của cột, tính theo công thức (9).

$$P_{ij} = \frac{a_{ij}}{\sum_{i=1}^{n} a_{ij}} \qquad (9)$$

Bảng 6 Ma trận so sánh giữa các chỉ số [14]

	A_1	A_2	A_3	…	A_m
A_1	1	a_{12}	a_{13}	…	a_{1m}
A_2	$a_{21} = 1/a_{12}$	1	a	…	a_{2m}
A_3	$a_{31} = 1/a_{13}$	$a_{32} = 1/a_{23}$	1	…	a_{3m}
…	…	…	…	…	…

A_n	$a_{n1} = 1/a_{1n}$	$a_{n2} = 1/a_{2n}$	$a_{n3} = 1/a_{3n}$	…	1

Trọng số của các chỉ số được tính bằng trị trung bình của các trọng số thành phần trên cùng một hàng theo công thức (10):

$$P_i = \frac{\sum_j^m P_{ij}}{m} \qquad (10)$$

+ Tính chỉ số nhất quán

Tỷ số nhất quán CR được tính theo công thức (11) :

$$CR = \frac{CI}{RI} \qquad (11)$$

Trong đó : n- số lượng các chỉ số đầu vào

RI – chỉ số ngẫu nhiên

CI – chỉ số nhất quán

Chỉ số ngẫu nhiên RI phụ thuộc vào bậc của ma trận [59] (số lượng chỉ số đầu vào n), RI được xác định theo Bảng 7.

Chỉ số nhất quán CI được tính theo công thức (12)

$$CI = \frac{\lambda_{max} - n}{n-1} \qquad (12)$$

Trong đó : n – số lượng chỉ số tham gia

λ_{max}- hệ số riêng lớn nhất

Bảng 7 Chỉ số ngẫu nhiên RI [10]

n	RI	n	RI	n	RI
1	0	6	1.24	11	1.52
2	0	7	1.32	12	1.54
3	0.52	8	1.41	13	1.56
4	0.9	9	1.45	14	1.58
5	1.12	10	1.49	15	1.59

Hệ số riêng lớn nhất (λ_{max}), được tính theo công thức (13)

$$\lambda_{max} = \frac{\sum_i^n \lambda_i}{n} \qquad (13)$$

Các hệ số riêng thành phần λ_i được tính dựa trên dữ liệu ma trận trọng số P_i và ma trận hệ số A (Bảng 6) theo nguyên lý trên Bảng 8.

Bảng 8 Tính hệ số riêng

	A_1	A_2	A_3	…	A_m	*Hệ số riêng* λ_i
A_1	$\lambda_{11}=P_1/a_{11}$	$\lambda_{12}=P_2/a_{12}$	$\lambda_{13}=P_3/a_{13}$	…	$\lambda_{1m}=P_m/a_{1m}$	$\lambda_1 = P_1/\sum_{j=1}^m \lambda_{1j}$
A_2	$\lambda_{21}=P_1/a_{21}$	$\lambda_{22}=P_2/a_{22}$	$\lambda_{23}=P_3/a_{23}$	…	$\lambda_{2m}=P_m/a_{2m}$	$\lambda_2 = P_2/\sum_{j=1}^m \lambda_{1j}$

A_3	$\lambda_{31}=P_1/a_{31}$	$\lambda_{32}=P_2/a_{32}$	$\lambda_{33}=P_3/a_{33}$	...	$\lambda_{3m}=P_m/a_{3m}$	$\lambda_3 = P_3/\sum_{j=1}^{m}\lambda_{1j}$
...	...	...	...	...	...	
A_n	$\lambda_{n1}=P_1/a_{n1}$	$\lambda_{n2}=P_2/a_{n2}$	$\lambda_{n3}=P_3/a_{n3}$	...	$\lambda_{nm}=P_m/a_{nm}$	$\lambda_n = P_n/\sum_{j=1}^{m}\lambda_{1j}$

+ Đánh giá kết quả

Hệ số riêng (λ_{max}) luôn lớn hơn hoặc bằng số hàng n của ma trận A (tương ứng với số lượng chỉ số đầu vào). Giá trị nhất quán cao λ_{max} càng gần n và khi λ_{max} = n, các tham số đầu vào được đánh giá có sự nhất quán tuyệt đối.

Tỷ số nhất quán CR $\leq$ 0.1 được cho là đạt độ chính xác, tương ứng với sai số nằm trong khoảng $\leq$ 10%. Nếu kết quả có CR $\geq$ 0.1, cần thay đổi mức độ quan trọng giữa các cặp chỉ tiêu để có kết quả tốt hơn [10].

6.2 Mô hình học máy

6.2.1 Hồi quy bình phương tối thiểu (PLSR)

Hồi quy bình phương tối thiểu (PLSR-Partial Least Squares Regression) là một phương pháp thống kê được sử dụng để mô hình hóa mối quan hệ giữa một tập hợp các biến độc lập (biến dự báo) và các biến phụ thuộc (biến phản hồi) bằng cách chiếu cả hai vào một không gian mới [69].

Trong một số lĩnh vực như hóa phân tích, di truyền học và viễn thám. Mô hình PLSR cho kết quả tốt khi dự báo các biến với số lượng lớn và có mức tương quan cao. PLSR là một phương pháp sử dụng mô hình tuyến tính đa biến để liên kết dữ liệu giữa hai ma trận X và Y. Tuy nhiên, so với phương pháp hồi quy truyền thống, PLSR có tính ưu việt hơn, mô hình hóa cấu trúc bên trong của cả X và Y. PLSR phát huy hiệu quả trong việc phân tích các bộ dữ liệu có nhiều biến, chứa nhiễu, có mối tương quan cao (collinear), thậm chí bị thiếu dữ liệu ở cả X và Y.

PLSR dựa trên nguyên lý tìm ra hướng (các thành phần) giải thích được mối tương quan giữa biến dự báo X và biến phản hồi Y, từ đó tối đa hóa khả năng dự báo. Trong quá trình thực hiện, PLSR giảm số chiều của tập biến dự báo thành một tập hợp nhỏ hơn gồm các thành phần không tương quan (biến tiềm ẩn) và thực hiện hồi quy trên các thành phần này.

Mô hình PLSR được biểu diễn theo công thức (14) và (15) như sau:

$$X = TP^2 + E \qquad (14)$$

$$Y = UT^2 + F \qquad (15)$$

Trong đó:

- X - là ma trận biến dự báo,
- Y - là ma trận biến phản hồi,

- T và U - là các ma trận điểm số (các biến tiềm ẩn),
- P và Q là các ma trận tải (loading),
- E và F là các ma trận sai số.

6.2.2 Rừng ngẫu nhiên (RF)

Phương pháp Rừng ngẫu nghiên (RF_Random Forest) được biết đến là một trong những thuật toán học máy điển hình trong bài toán phân loại và hồi quy. Mô hình RF được huấn luyện dựa trên sự phối hợp giữa luật kết hợp (Ensembling), tức là kết hợp nhiều mô hình yếu để tạo thành một mô hình mạnh hơn, và quá trình lấy mẫu tái lập (boostrapping). Đặc điểm nổi bật của RF là việc sử dụng nhiều cây quyết định và kết hợp chúng thành một "rừng" (forest). Mỗi cây quyết định được huấn luyện bởi các tập dữ liệu con khác nhau được lấy ngẫu nhiên từ tập dữ liệu huấn luyện. Quá trình này mang lại sự đa đạng cho mô hình cuối cùng bởi mỗi cây quyết định là một phần độc lập. Mỗi cây quyết định sẽ có một giá trị dự báo riêng và độc lập, kết quả cuối cùng của mô hình là giá trị bầu cử (voting) lớn nhất có được từ toàn bộ cây quyết định. Kết quả dự báo sẽ không bị chệch do được tổng hợp từ nhiều mô hình khác nhau, và so với một mô hình thì kết quả dự báo từ nhiều mô hình sẽ cho phương sai nhỏ hơn. Bằng việc áp dụng nguyên lý này mô hình RF đã khắc phục được hiện tượng quá khớp (overfitting).

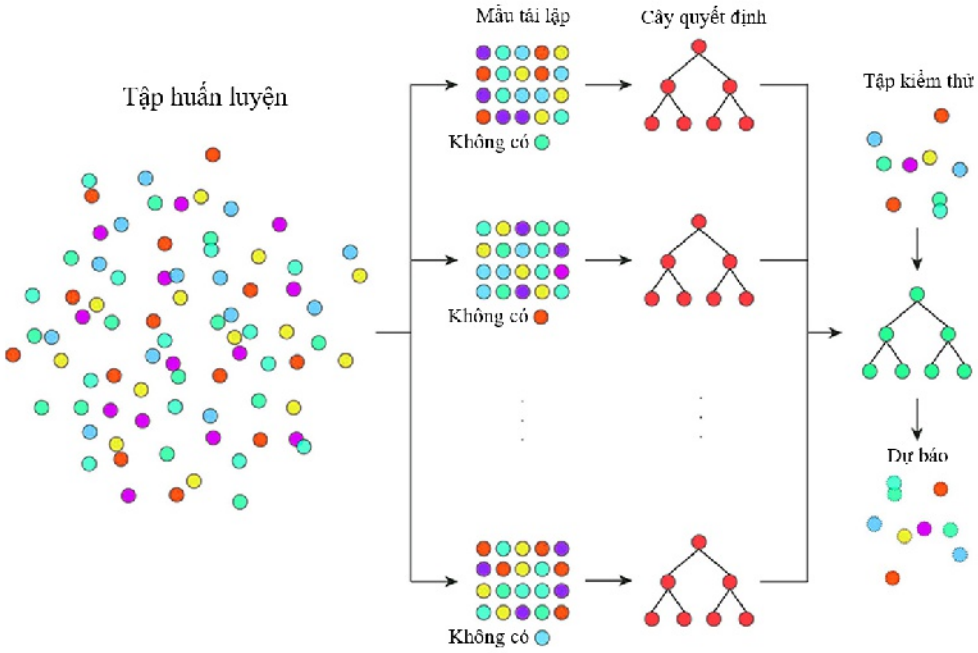
Theo nguyên lý của RF trên Hình 16 thuật toán RF được chia làm 03 phần chính.

Bước 1. Tạo tập dữ liệu huấn luyện ngẫu nhiêu theo dữ liệu đầu vào (mẫu boostrap), một phần dữ liệu sẽ được lựa chọn ngẫu nhiên và không tham gia vào quá trình huấn luyện mô hình. Các tệp dữ liệu này được gọi là Out - of - bag samples và được dùng làm tệp kiểm thử, sử dụng để đánh giá độ tin cậy và hiệu suất của mô hình sau khi được thành lập.

Bước 2. Sự dụng các tập con dữ liệu lấy ngẫu nhiên, xây dựng các cây quyết định

Bước 3. Kết hợp cây, nếu là bài toàn phân loại bình chọn theo số đông, với bài toán hồi quy lấy giá trị trung bình dự báo.

Trải qua quá trình kiểm thử và hiệu chỉnh mô hình, kết quả cuối cùng của RF là tạo ra được mô hình cây quyết định có độ tin cậy cao nhất, mô hình này được sử dụng để dự báo cho các tệp dữ liệu mới. Thử nghiệm với một số mô hình và đánh giá kết quả dự báo hàm lượng dinh dưỡng cây trồng tác giả Zhengchao và cộng sự đã cho khẳng định RF là mô hình cho kết quả tốt nhất [55].



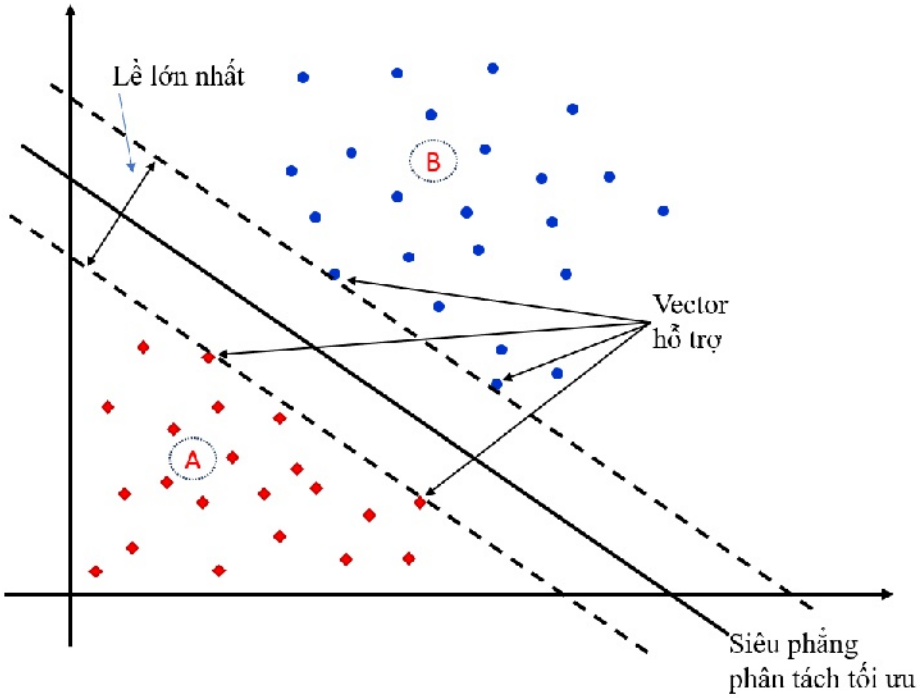
Hình 16 Thuật toán rừng ngẫu nhiên (sửa từ nguồn: https://learnetutorials.com)

6.2.3 Máy vector hỗ trợ (SVM)

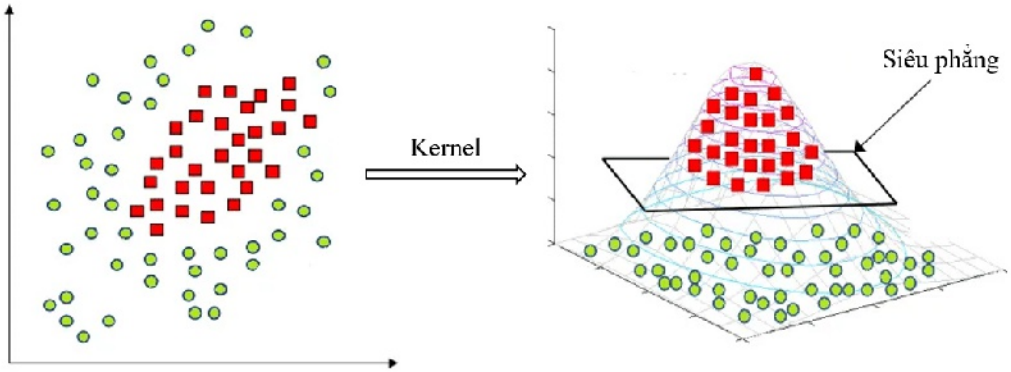
Máy vector hỗ trợ (SVM- Support Vector Machine) là thuật toán học có khả năng hoạt động hiệu quả với dữ liệu lớn, cấu trúc phức tạp và tồn tại trong không gian nhiều chiều (High Dimensional Spaces). Thuật toán này tiêu tốn ít bộ nhớ khi hoạt động do sử dụng các điểm trong tập dữ liệu hỗ trợ để đưa ra các dự báo ở hàm quết định, có thể tạo ra nhiều hàm quyết định từ các hàm kernal (biến đổi tập dữ liệu không phân biệt tuyến tính về phân biệt tuyến tính) khác nhau hoặc dùng để cải thiện thuật toán. Chính vì tính hiệu quả mà SVM thường được áp dụng nhiều trong các bài toán phân loại và dự báo.

Nguyên lý chính của SVM là tìm một ranh giới phân chia tốt nhất giữa các lớp dữ liệu (trong bài toán phân loại) hoặc tìm một ranh giới tối ưu để dự báo giá trị đầu ra (trong bài toán hồi quy). Các đường ranh giới được chọn sao cho khoảng cách từ ranh giới tới các điểm dữ liệu gần nó nhất là lớn nhất có thể, các điểm dữ liệu gần nhất này được gọi là "support vectors" (vector hỗ trợ).

SVM với mục tiêu xây dựng một siêu phẳng hoặc một tập hợp các siêu phẳng trong không gian đa chiều, thỏa mãn điều kiện khoảng cách từ các siêu phẳng tới các điểm dữ liệu ở tất cả các lớp (gọi là biên) càng xa càng tốt. Sai số tổng quát tỷ lệ nghịch với khoảng các từ điểm phân loại tới siêu phẳng, biên càng lớn thì sai số tổng quát trong bài toàn phân loại càng bé.



Hình 17 Siêu phẳng phân tách dữ liệu trong không gian hai chiều



Hình 18 Siêu phẳng phân tách dữ liệu trong không gian ba chiều

(sửa từ nguồn: https://trituenhantao.io)

Từ lớp dữ liệu đầu vào có thể tìm được nhiều mặt phẳng để phân nhóm đối tượng, nhưng SVM sẽ tìm siêu phẳng tối ưu để phân tách các đối tượng trong tập dữ liệu. Trong đó, các điểm trong không gian vector gọi và vector gốc, các điểm nằm trên biên hoặc gần nhất với lề của siêu phẳng gọi là các vector hỗ trợ, sau khi phân tách dữ liệu được chia thành hai nhóm có đặc điểm khác nhau. Hình 18 siêu phẳng chia dữ liệu thành hai nhóm riêng biệt (A) và (B), các vector hỗ trợ dùng để tối ưu hóa nền và quyết định đến vị trí, hướng của siêu phẳng.

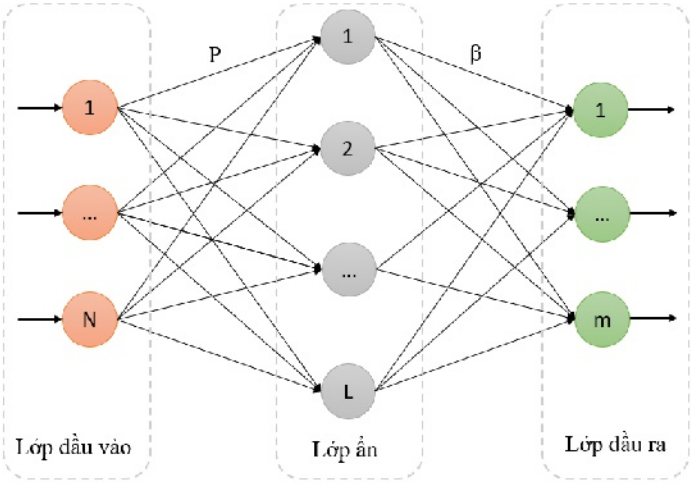
Khi dữ liệu không tuyến tính, Kernel với các hàm tuyến tính, đa thức, sigmoid được áp dụng như một hàm ánh xạ chuyển dữ liệu dữ liệu từ không gian ít chiều hơn sang không gian nhiều chiều hơn (Hình 18), từ đó ta tìm được siêu phẳng phân tách dữ liệu.

6.2.4 Máy học cực hạn (ELM)

Máy học cực hạn ELM (Extreme Learning Machine) là một phương pháp học máy dùng cho mạng nơ-ron truyền thẳng một lớp ẩn (SLFN - Single Layer Feedforward Neural Network), nổi bật với tốc độ huấn luyện rất nhanh vì trọng số của lớp ẩn được gán ngẫu nhiên và không cần điều chỉnh, chỉ cần tính toán trọng số đầu ra một cách tuyến tính [17]. Khác với mạng nơ-ron truyền thống, ELM tránh được bẫy cực tiểu cục bộ do không có huấn luyện trọng số đầu vào [50]. Lỗi này được khắc phục bằng cách thiết lập ngẫu nhiên trọng số giữa lớp đầu vào và lớp ẩn, đồng thời có khả năng xác định ngưỡng của các nơ-ron trong lớp ẩn một cách hiệu quả [27]. Khả năng tổng quát tốt và hiệu quả cao với nhiều loại bài toán (phân loại, hồi quy, phân cụm) [16]

Giả sử có N mẫu dữ liệu, ELM thực hiện theo nguyên lý cơ bản như Hình 19, dữ liệu đầu vào được x_i và tệp dữ liệu mục tiêu t_i

Với một lớp ẩn đơn trong ELM, giả sử nút ẩn thứ j, có P_j , b_j là tham số, hàm đầu ra tại nút ẩn sẽ được tính là: $h_j(x_i) = g(P_j, b_j, x_i)$. Hàm đầu ra của ELM cho mạng truyền thẳng ẩn đơn (SLFN) với L các nút ẩn được tính theo công thức (16) [16, 17]



Hình 19 Cấu trúc của ELM

$$f_L(x) = \sum_{j=1}^{L} \beta_i h_i(x) \qquad (16)$$

Trong đó β_i – trọng số đầu ra của nút ẩn thứ i

Trọng số được khởi tạo gán ngẫu nhiên P_i và độ lệch bias b_j cho mỗi nút ẩn j = 1, 2, …, L. Sử dụng hàm kích hoạt g(.) (sigmoid, ReLU, radial basis function). Với mỗi ẩn đầu vào x_i, tương ứng sẽ tính được giá trị ẩn thứ j theo công thức (17)

$$h_j(x_i) = g(P_j.x_i + b_j) \qquad (17)$$

Việc tính toán trên được lặp lại cho toàn bộ số lượng mẫu N và L nút ẩn được ma trận đầu ra của lớp ẩn (H) kích thước (NxL):

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} g(P_1.x_1 + b_1) & \dots & g(P_L.x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(P_1.x_N + b_1) & \dots & g(P_L.x_N + b_L) \end{bmatrix}$$

Ma trận mục tiêu: $T = \begin{bmatrix} t_1 \\ \vdots \\ t_N \end{bmatrix}$

Ma trận trọng số đầu ra (β) :

$$\beta = H^t T \qquad (18)$$

Trong đó : β - Trọng số đầu ra cần tìm

T - Ma trận đầu ra kỳ vọng

H^t- Ma trận nghịch đảo của H

Kết quả đầu ra dự báo được tính từ vector giá trị đầu ra của các nút ẩn h(x) và trọng số đầu ra β của mô hình.

$$\hat{y} = h(x).\beta \qquad (19)$$

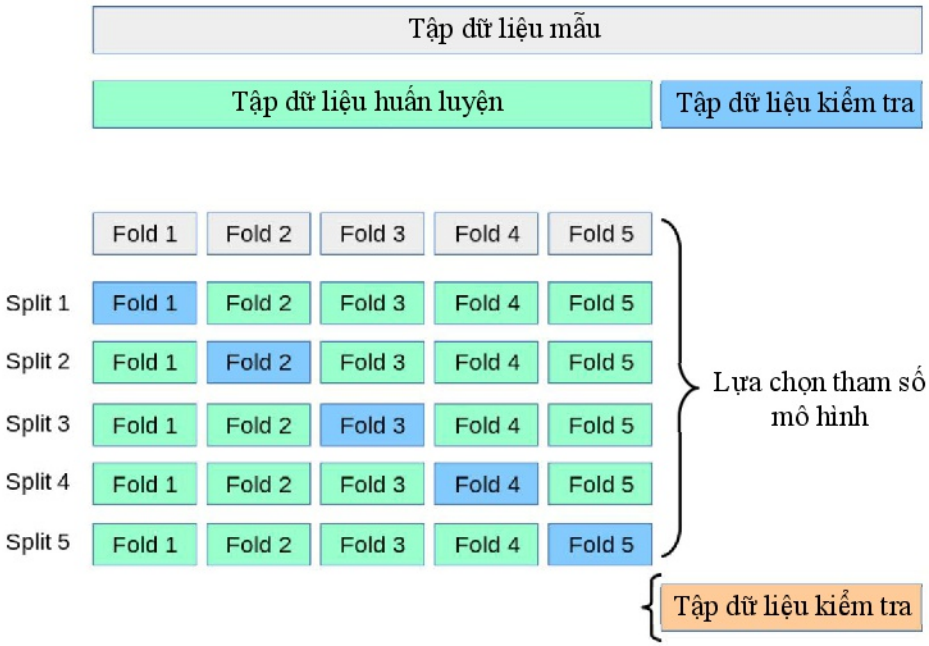
6.3 Phương pháp huấn luyện và hiệu chỉnh các mô hình học máy

Khả năng tổng quát hóa của các mô hình cần được đánh giá, đảm bảo rằng mô hình không những hoạt động tốt trên tập dữ liệu huấn luyện mà còn có thể áp dụng hiệu quả trên tập dữ liệu mới (dữ liệu đánh giá mô hình chưa tham gia vào quá trình huấn luyện mô hình). Thực hiện mục tiêu trên, phương pháp xác thực chéo (CV – Cross-Validation) là một kỹ thuật lấy mẫu lại (resampling) đã được nghiên cứu ứng dụng thành công trên các mô hình học máy [45, 62, 65], đặc biệt khi tập dữ liệu mẫu nhỏ cần tiết kệm và sử dụng hiệu quả. Việc áp dụng CV giúp đảm bảo rằng mô hình không chỉ hoạt động tốt trên dữ liệu huấn luyện mà còn có thể áp dụng hiệu quả vào dữ liệu mới chưa từng thấy.

Nguyên lý cơ bản của CV là chia dữ liệu gốc thành hai phần, một là tập huấn luyện và phần còn lại là tập kiểm thử mô hình. Đầu tiên, tập huấn luyện được sử dụng để huấn luyện mô hình, sau đó tập kiểm thử được sử dụng để kiểm tra mô hình nhằm thu được độ chính xác làm chỉ số hiệu suất của mô hình. Các tham số tối ưu thu được từ CV có thể tránh hiệu quả tình trạng quá khớp (Overfiting) và thiếu khớp (underfiting), và cuối cùng đạt được độ chính xác dự đoán lý tưởng cho tập kiểm tra [72].

CV được thực hiện với một số phương pháp bao gồm Holdout, Leave-One-Out (LOOCV) và K-fold. Phương pháp Holdout dữ liệu được chia một lần theo tỷ lệ 70/30% hoặc 80/20% phục vụ huấn luyện (train) và kiểm tra (test) mô hình. LOOCV mô hình được huấn luyện trên toàn bộ bộ dữ liệu nhưng bỏ qua một điểm dữ liệu và lặp lại quá trình này cho từng điểm dữ liệu. Trong LOOCV, mô hình được huấn luyện trên n−1 mẫu và kiểm tra trên mẫu bị bỏ qua, lặp lại quá trình này cho mỗi điểm dữ liệu trong bộ dữ liệu. K-Fold, **t**ập dữ liệu được chia làm k phần bằng nhau, lặp lại n lần, mỗi lần chọn

1 phần làm tập kiểm tra và k-1 phần còn lại sử dụng huấn luyện mô hình, kết quả được tính là trung bình của K lần kiểm tra (Hình 20).

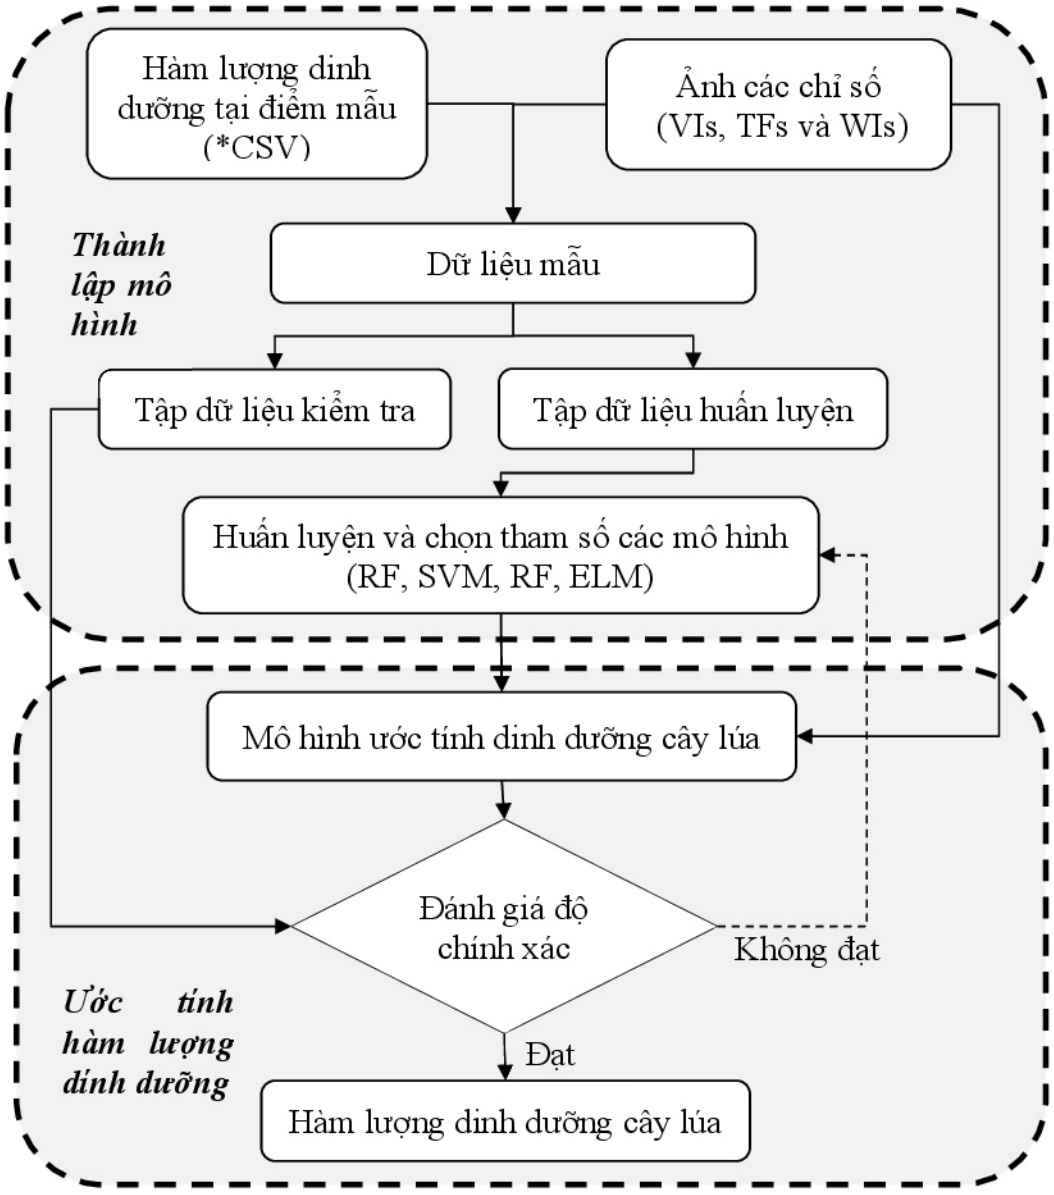


Hình 20 Nguyên lý K-Fold Cross-validation [46]

Holdout là một phương pháp đơn giản và nhanh do chỉ huấn luyện mô hình một lần, nhưng độ chính xác phụ thuộc nhiều vào cách chia dữ liệu ban đầu. Các thông tin quan trọng có thể nằm trong tệp dữ liệu kiểm tra mà ta bỏ qua khi huấn luyện mô hình, dẫn đến sai lệch lớn. LOOCV mô hình kiểm tra trên một điểm dữ liệu nên có thể độ sai lệch thấp nhưng phương sai cao, đặc biệt khi điểm kiểm tra lại là điểm ngoại lệ, không có thông tin trong tập huấn luyện. Trong khi, K-Fold toàn bộ dữ liệu đều được sử dụng cả cho huấn luyện và kiểm tra (trong các vòng lặp khác nhau), giúp khai thác tối đa thông tin từ tập dữ liệu, nhất là khi số lượng mẫu nhỏ. So với phương pháp chia Holdout, K-Fold giúp giảm độ lệch (bias) của ước lượng hiệu suất mô hình, vì kết quả được lấy trung bình từ nhiều lần kiểm tra. K-Fold dữ liệu huấn luyện và kiểm tra được chia ngẫu nhiên thành các tập riêng, đảm bảo mô hình không bị overfitting trong quá trình hiệu chỉnh cho các mô hình.

Với các phân tích nêu trên, áp dụng Cross-Validation với phương pháp K-Fold trong quá trình huấn luyện mô hình, đánh giá độ ổn định lựa chọn các siêu tham số cho các mô hình học máy (số lượng cây (n_estimatiors) trong RF, hệ số điều chỉnh độ phạt lỗi (c) của SVM, Số thành phần tiềm ẩn được giữ lại (n_components) của PLSR và số lượng lớp ẩn (hidden layer sizes) khi sử dụng mô hình ELM).

Hàm lượng dinh dưỡng cây lúa được ước tính bằng mô hình học máy với dữ liệu đầu vào là chỉ số VIs, TFs và WIs được thực hiện với hai công đoạn chính: Thành lập mô hình và ước tính hàm lượng, quy trình được thể hiện trên Hình 21.



Hình 21 Sơ đồ ước tính hàm lượng dinh dưỡng cây lúa bằng mô hình học máy

Bước 1. Tạo tập dữ liệu: Các điểm mẫu lá có tọa độ đo GNSS được chuyển lên ảnh chỉ số và chiết xuất giá trị các chỉ số trong vùng diện tích S =0.8mx0.8m. Giá trị chỉ số là giá trị trung bình trong vùng diện tích S. Được tập dữ liệu đầu vào là các điểm mẫu có tọa độ (X,Y,H), hàm lượng dinh dưỡng (LKC, LPC) và giá trị các chỉ số (VIs, TFs và WIs). Dữ liệu được sử dụng làm dữ liệu huấn luyện và dữ liệu kiểm tra kết quả ước tính mủa mô hình.

Bước 2.Thành lập mô hình: Sử dụng K -fold cross validation để huấn huyện và lựa chọn các tham số cho các mô hình học máy (RF, PLSR, SVM, ELM). Huấn luyện mô hình bằng K-1 tập và tập còn lại để kiểm tra độ chính xác mô hình. Độ chính xác mô hình trên tập huấn huyện được đánh giá thông qua R^2 và RMSE. Độ ổn định mô hình

được đánh giá bằng sự biến động của R^2 và RMSE, giá trị không quá 10% mô hình đạt yêu cầu độ chính xác.

Bước 3. Ước tính hàm lượng dinh dưỡng: Sử dụng mô hình đã được đánh giá và cho kết quả tối ưu, ước tính hàm lượng dinh dưỡng cho toàn khu vực dựa trên ảnh các chỉ số VIs, TFs và WIs. Kết quả ước tính được đánh giá độ chính xác trên tập dữ liệu kiểm tra, thông qua giá trị R^2 và sai số trung phương RMSE.

6.4 Phương pháp đánh giá độ chính xác

Mô hình được đánh giá độ chính xác thông qua sai số R^2(R – Square), sai số trung phương (RMSE- Root Mean Square Error) và sai số trung phương tương đối (rRMSE - Relative Root Mean Square Error). Xác định RMSE và R^2 dựa trên sự chênh lệch giữa giá trị hàm lượng tại các điểm mẫu và hàm lượng ước tính được từ mô hình theo công thức (20 và 21)

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(L_i - X_i)^2}{\sum_{i=1}^{n}(L_i - \bar{L})^2} \qquad (20)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(L_i - X_i)^2}{n}} \qquad (21)$$

Trong đó: L_i – Hàm lượng dinh dưỡng của mẫu i

X_i – Hàm lượng dinh dưỡng ước tính được tương ứng với mẫu i

$\bar{L}$ – Trị trung bình của L_i

n – số lượng mẫu

Trong đánh giá hàm lượng dinh dưỡng, $R^2 < 0$ mô hình có độ chính xác thấp nhất, mô hình được coi là có độ chính xác tốt khi có $R^2 > 0,5$ và mô hình tốt nhất khi $R^2 = 1$ (đạt độ chính xác 100%) [18].

rRMSE cho biết sai số của mô hình dự báo chiếm tỷ lệ bao nhiêu % so với giá trị trung bình của mô hình dự báo được. Phương pháp này cho phép đánh giá hiệu quả mô hình không ảnh hưởng bởi đơn vị đo [73]. RMSE cho phép đánh giá độ chính xác mô hình tại vị trí các điểm mẫu kiểm tra mô hình, rRMSE đánh giá được kết quả trên toàn khu vực ước tính, rRMSE được tính theo công thức (22).

$$rRMSE(\%) = \frac{RMSE}{x}.100\% \qquad (22)$$

Trong đó: RMSE – Sai số trung phương của mô hình

x – Trung bình hàm lượng dinh dưỡng (LKC hoặc LPC) trên toàn khu vực đo vẽ ước tính được từ mô hình.

Bảng 9 Tiêu chí đánh giá hiệu suất mô hình theo rRMSE [73]

STT	Sai số trung phương tương đối	Hiệu suất mô hình

1	rRMSE < 10%	Cao
2	10% ≤ rRMSE < 20%	Tốt
3	20% ≤ rRMSE < 30%	Chấp nhận được
4	rRMSE ≥ 30%	Không chính xác

Hiệu suất mô hình ước tính được đánh giá theo rRMSE bao gồm 04 tiêu chí được thể hiện trên Bảng 9. Trong đó kết quả được coi là chấp nhận được khi giá trị rRMSE nhỏ hơn 30%.

KẾT LUẬN

Từ kết quả nghiên cứu đã khẳng định rằng mục tiêu đề tài đã được chứng minh và có thể rút ra một số kết luận như sau:

1. Việc đề xuất một quy trình đánh giá sức khỏe cây lúa có cấu trúc chặt chẽ và mang tính hệ thống là yêu cầu mang tính nền tảng nhằm đảm bảo tính khoa học, tính nhất quán và khả năng tái lập của kết quả nghiên cứu. Quy trình được chuẩn hóa xuyên suốt từ khâu thu thập dữ liệu, tiền xử lý ảnh, trích xuất đặc trưng phổ, xây dựng và lựa chọn mô hình đến đánh giá và kiểm chứng kết quả không chỉ góp phần giảm thiểu sai số mà còn tạo điều kiện thuận lợi cho việc mở rộng và áp dụng trong các điều kiện canh tác khác nhau.

2. Dữ liệu ảnh UAV đa phổ đóng vai trò là nguồn thông tin đầu vào quan trọng trong đánh giá sức khỏe cây lúa nhờ khả năng cung cấp dữ liệu có độ phân giải không gian cao, tính linh hoạt và khả năng quan sát liên tục theo thời gian. Thông qua việc khai thác các đặc trưng phổ và chỉ số thực vật, dữ liệu UAV đa phổ cho phép phản ánh chi tiết trạng thái sinh trưởng và các biểu hiện stress sinh lý của cây lúa, từ đó nâng cao hiệu quả giám sát đồng ruộng và hỗ trợ quản lý cây trồng trên diện rộng.

3. Các mô hình học máy thể hiện vai trò then chốt trong việc phân tích và khai thác hiệu quả dữ liệu ảnh UAV đa phổ. Với khả năng xử lý dữ liệu đa chiều, mô hình hóa các mối quan hệ phi tuyến và tích hợp đồng thời nhiều đặc trưng đầu vào, các mô hình học máy góp phần nâng cao độ chính xác trong phân loại, đánh giá và dự báo sức khỏe cây lúa. Việc ứng dụng các mô hình này giúp giảm thiểu sự phụ thuộc vào đánh giá chủ quan, đồng thời tăng cường tính tự động hóa và hiệu quả của quá trình phân tích dữ liệu.

4. Sự kết hợp đồng bộ giữa quy trình đánh giá chặt chẽ, dữ liệu ảnh UAV đa phổ và các mô hình học máy đã chứng minh tính hiệu quả trong việc nâng cao chất lượng và độ tin cậy của kết quả đánh giá sức khỏe cây lúa. Cách tiếp cận tích hợp này không chỉ góp phần tối ưu hóa công tác giám sát và quản lý cây trồng mà còn tạo tiền đề cho việc ứng dụng rộng rãi công nghệ nông nghiệp chính xác, hướng tới phát triển sản xuất lúa bền vững và hiện đại.

TÀI LIỆU THAM KHẢO

[1]. Aerotas. *Mission Planning and Data Processing*. https://www.aerotas.com/choosing-flight-altitude 2020.

[2]. Al-Abbas, A.H., R. Barr, J.D. Hall, F.L. Crane, and M.F. Baumgardner, *Spectra of Normal and Nutrient-Deficient Maize Leaves.* Agronomy Journal, 1974. **66**: p. 16-20.

[3]. Assmann, J.J., J.T. Kerby, A.M. Cunliffe, and I.H. Myers-Smith, *Vegetation monitoring using multispectral sensors — best practices and lessons learned from high latitudes.* Journal of Unmanned Vehicle Systems, 2019. **7**(1): p. 54-75.

[4]. Ayala-Silva, T. and C.A. Beyl, *Changes in spectral reflectance of wheat leaves in response to specific macronutrient deficiency.* Advances in Space Research, 2005. **35**(2): p. 305-317.

[5]. Bouman, B., *Crop modelling and remote sensing for yield production.* Netherlands Journal of Agricultural Science 43: 143-161, 1995. **43**.

[6]. Bouvet, A., T. Le Toan, and N. Lam, *Monitoring of the rice cropping system in the Mekong Delta using ENVISAT/ASAR dual polarization data.* IEEE Transactions on Geoscience and Remote Sensing, 2009. **47**.

[7]. Broge, N.H. and E. Leblanc, *Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density.* Remote Sensing of Environment, 2001. **76**(2): p. 156-172.

[8]. Buschmann, C. and E. Nagel, *In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation.* International Journal of Remote Sensing, 1993. **14**(4): p. 711-722.

[9]. Buschmann, C. and E. Nagel, *Variation of reflectance signatures of a leaf as indication of physiological activity.* Proceedings of IGARSS '93 - IEEE International Geoscience and Remote Sensing Symposium, 1993: p. 522-524 vol.2.

[10]. Cabala, P., *Using the Analytic Hierarchy Process in Evaluating Decision Alternatives.* Operations Research and Decisions, 2010. **1**: p. 1-23.

[11]. Chappelle, E.W., M.S. Kim, and J.E. McMurtrey, *Ratio analysis of reflectance spectra (RARS): An algorithm for the remote estimation of the concentrations of chlorophyll A, chlorophyll B, and carotenoids in soybean leaves.* Remote Sensing of Environment, 1992. **39**: p. 239-247.

[12]. Chen, J.M., *Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications.* Canadian Journal of Remote Sensing, 1996. **22**(3): p. 229-242.

[13]. Choudhuri, P.K., *Application of Multi-Criteria Decision Making (MCDM) Technique for Gradation of Jute Fibres.* Journal of The Institution of Engineers (India): Series E, 2014. **95**: p. 63 - 68.

[14]. Đặng Tuyết Minh, *Nghiên cứu ứng dụng mô hình hoá không gian trong phân vùng nguy cơ phục vụ cảnh báo lũ lưu vực sông Lam*, in *Kỹ thuật Trắc địa - Bản đồ*. 2018, Đại học Mỏ - Địa chất.

[15]. Daughtry, C.S.T., C.L. Walthall, M.S. Kim, E.B. de Colstoun, and J.E. McMurtrey, *Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance*. Remote Sensing of Environment, 2000. **74**(2): p. 229-239.
[16]. Deng, B., X. Zhang, W. Gong, and D. Shang, *An Overview of Extreme Learning Machine*. 2019 4th International Conference on Control, Robotics and Cybernetics (CRC), 2019: p. 189-195.
[17]. Ding, S., H. Zhao, Y. Zhang, X. Xu, and R. Nie, *Extreme learning machine: algorithm, theory and applications*. Artificial Intelligence Review, 2013. **44**: p. 103 - 115.
[18]. Ennaji, O., L. Vergütz, and A. El Allali, *Machine learning in nutrient management: A review*. Artificial Intelligence in Agriculture, 2023. **9**: p. 1-11.
[19]. Fan, Y., H. Feng, J. Yue, X. Jin, Y. Liu, R. Chen, M. Bian, Y. Ma, X. Song, and G. Yang, *Using an optimized texture index to monitor the nitrogen content of potato plants over multiple growth stages*. Computers and Electronics in Agriculture, 2023. **212**: p. 108147.
[20]. Field, A., *Discovering Statistics Using SPSS* 2009, University of Sussex, UK.
[21]. Gamon, J.A., L. Serrano, and J.S. Surfus, *The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels*. Oecologia, 1997. **112**(4): p. 492-501.
[22]. Gamon, J.A. and J.S. Surfus, *Assessing leaf pigment content and activity with a reflectometer*. New Phytologist, 1999. **143**(1): p. 105-117.
[23]. Ghorabaee, M.K., M. Amiri, E.K. Zavadskas, Z. Turskis, and J. Antuchevičienė, *Simultaneous Evaluation of Criteria and Alternatives (SECA) for Multi-Criteria Decision-Making*. Informatica, 2018. **29**: p. 265-280.
[24]. Gitelson, A. and M.N. Merzlyak, *Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves*. Journal of Photochemistry and Photobiology B: Biology, 1994. **22**(3): p. 247-252.
[25]. Gitelson, A.A., C. Buschmann, and H.K. Lichtenthaler, *Leaf chlorophyll fluorescence corrected for re-absorption by means of absorption and reflectance measurements*. Journal of Plant Physiology, 1998. **152**: p. 283-296.
[26]. Gitelson, A.A., Y. Gritz †, and M.N. Merzlyak, *Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves*. Journal of Plant Physiology, 2003. **160**(3): p. 271-282.
[27]. Guo, L., P. Fu, T. Shi, Y. Chen, H. Zhang, R. Meng, and S. Wang, *Mapping field-scale soil organic carbon with unmanned aircraft system-acquired time series multispectral images*. Soil and Tillage Research, 2020. **196**: p. 104477.
[28]. Haralick, R.M., K. Shanmugam, and I. Dinstein, *Textural Features for Image Classification*. IEEE Transactions on Systems, Man, and Cybernetics, 1973. **SMC-3**(6): p. 610-621.
[29]. Huete, A., K. Didan, T. Miura, E.P. Rodriguez, X. Gao, and L.G. Ferreira, *Overview of the radiometric and biophysical performance of the MODIS vegetation indices*. Remote Sensing of Environment, 2002. **83**(1): p. 195-213.
[30]. Janse, P.V., R.R. Deshmukh, J.N. Kayte, and P.U. Randive, *Estimation of Crop Chlorophyll Content by Spectral Indices Using Hyperspectral Non-imaging Data*. 2019. **1037**: p. 363-371.
[31]. Jiang, J., W. Cai, H. Zheng, T. Cheng, Y. Tian, Y. Zhu, R. Ehsani, Y. Hu, Q. Niu,

L. Gui, and X. Yao, *Using Digital Cameras on an Unmanned Aerial Vehicle to Derive Optimum Color Vegetation Indices for Leaf Nitrogen Concentration Monitoring in Winter Wheat*. Remote Sensing, 2019. **11**(22): p. 2667.
[32]. Jordan, C.F., *Derivation of Leaf-Area Index from Quality of Light on the Forest Floor*. Ecology, 1969. **50**(4): p. 663-666.
[33]. Kavdır, İ. and D.E. Guyer, *Comparison of Artificial Neural Networks and Statistical Classifiers in Apple Sorting using Textural Features*. Biosystems Engineering, 2004. **89**(3): p. 331-344.
[34]. Kiala, Z., O. Mutanga, J. Odindi, and K.Y. Peerbhay, *Feature Selection on Sentinel-2 Multispectral Imagery for Mapping a Landscape Infested by Parthenium Weed*. Remote. Sens., 2019. **11**: p. 1892.
[35]. Kuenzer, C. and K. and Knauer, *Remote sensing of rice crop areas*. International Journal of Remote Sensing, 2013. **34**(6): p. 2101-2139.
[36]. Li, W., W. Wu, M. Yu, H. Tao, X. Yao, T. Cheng, Y. Zhu, W. Cao, and Y. Tian, *Monitoring rice grain protein accumulation dynamics based on UAV multispectral data*. Field Crops Research, 2023. **294**: p. 108858.
[37]. Liu, C., Z. Zhang, and J.W. Balay, *Posterior assessment of reference gages for water resources management using instantaneous flow measurements*. Sci Total Environ, 2018. **634**: p. 12-19.
[38]. Liu, J., Y. Zhu, L. Song, X. Su, J. Li, J. Zheng, X. Zhu, L. Ren, W. Wang, and X. Li, *Optimizing window size and directional parameters of GLCM texture features for estimating rice AGB based on UAVs multispectral imagery*. Frontiers in Plant Science, 2023. **14**.
[39]. Liu, L.-y., W.-j. Huang, R.-L. Pu, and J.-h. Wang, *Detection of internal leaf structure deterioration using a new spectral ratio index in the near-infrared shoulder region*. Journal of Integrative Agriculture, 2014. **13**(4): p. 760-769.
[40]. Lowe, D.G., *Distinctive Image Features from Scale-Invariant Keypoints*. International Journal of Computer Vision, 2004. **60**(2): p. 91-110.
[41]. Ma, Y., Z. Chen, F. Yiguang, M. Bian, Y. Guijun, R. Chen, and H. Feng, *Estimating potassium in potato plants based on multispectral images acquired from unmanned aerial vehicles*. Frontiers in Plant Science, 2023. **14**.
[42]. Maghrabie, H.F.A., *Multi-Criteria Decision Making under Uncertain Evaluations*. 2018, Concordia University. p. 120.
[43]. Martínez-Carricondo, P., F. Agüera-Vega, F. Carvajal-Ramírez, F.-J. Mesas-Carrascosa, A. García-Ferrer, and F.-J. Pérez-Porras, *Assessment of UAV-photogrammetric mapping accuracy based on variation of ground control points*. International Journal of Applied Earth Observation and Geoinformation, 2018. **72**: p. 1-10.
[44]. McFeeters, S., *Using the Normalized Difference Water Index (NDWI) within a Geographic Information System to Detect Swimming Pools for Mosquito Abatement: A Practical Approach*. Remote Sensing, 2013. **5**(7): p. 3544-3561.
[45]. Mushagalusa, C.A., A.B. Fandohan, and R. Glèlè Kakaï, *Random forest and spatial cross-validation performance in predicting species abundance distributions*. Environmental Systems Research, 2024. **13**(1).
[46]. Nguyễn Chiến Thắng. *K-Fold cross validation, đánh giá model hiệu quả hơn khi có ít dữ liệu*. https://miai.vn/ 2021.
[47]. Nguyễn Đại Đồng and Bùi Ngọc Quý, *Cơ sở khoa học phương pháp đo ảnh chụp*

từ thiết bị bay không người lái UAV. Tạp chí khoa học Đo đạc và bản đồ, 2020. **46**: p. 19-27.
[48]. Nguyễn Xuân Kỳ, *Tuyển chọn giống lúa ngắn ngày và xác định các biện pháp kỹ thuật canh tác phù hợp ở tỉnh Quảng Bình*. 2017, Đại học Nông lâm, Đại học Huế.
[49]. Nikolaev, S., E. Urbanovich, V.R. Shayapov, E.A. Orlova, and D.A. Afonnikov, *A Method Of Evaluating The Absorption Spectrum Of Wheat Leaf By The Spectrum Of Diffuse Reflection*. Siberian Herald of Agricultural Science, 2019.
[50]. Patil, H.A. and K. Sharma, *Extreme Learning Machine: A Comprehensive Survey of Theories & Algorithms*. 2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES), 2023: p. 749-756.
[51]. Peng Xuelian, Chen Dianyu, Zhou Zhenjiang, Zhang Zhitao, Xu Can, Zha Qing, Wang Fang, and Hu Xiaotao, *Prediction of the Nitrogen, Phosphorus and Potassium Contents in Grape Leaves at Different Growth Stages Based on UAV Multispectral Remote Sensing*. Remote Sensing, 2022. **14**(11): p. 2659.
[52]. Peñuelas, J., J.A. Gamon, A.L. Fredeen, J. Merino, and C.B. Field, *Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves*. Remote Sensing of Environment, 1994. **48**(2): p. 135-146.
[53]. Pohl, C. and J.L. and Van Genderen, *Review article Multisensor image fusion in remote sensing: Concepts, methods and applications*. International Journal of Remote Sensing, 1998. **19**(5): p. 823-854.
[54]. Qi, J., A. Chehbouni, A.R. Huete, Y.H. Kerr, and S. Sorooshian, *A modified soil adjusted vegetation index*. Remote Sensing of Environment, 1994. **48**(2): p. 119-126.
[55]. Qiu, Z., F. Ma, Z. Li, X. Xu, H. Ge, and C. Du, *Estimation of nitrogen nutrition index in rice from UAV RGB images coupled with machine learning algorithms*. Computers and Electronics in Agriculture, 2021. **189**: p. 106421.
[56]. Roman, A. and T. Ursu, *Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks*. 2016. p. 141-152.
[57]. Rondeaux, G., M. Steven, and F. Baret, *Optimization of soil-adjusted vegetation indices*. Remote Sensing of Environment, 1996. **55**(2): p. 95-107.
[58]. Rouse, J.W., R.H. Haas, J.A. Schell, and D.W. Deering, *Monitoring Vegetation Systems in the Great Plains with ERTS (Earth Resources Technology Satellite)*, in *Proceedings of 3rd Earth Resources Technology Satellite Symposium*. 1973, NASA: Greenbelt. p. 309-317.
[59]. Saaty, T., *Decision making with the Analytic Hierarchy Process*. Int. J. Services Sciences Int. J. Services Sciences, 2008. **1**: p. 83-98.
[60]. Saaty, T.L., *How to make a decision: the Analytic Hierarchy Process*. European Journal of Operational, 1990. **48**: p. 9-26.
[61]. Tomimatsu, H. and S. Itano, *Differences in spectrum reflectance and physiological indices among three typical semi-natural grasslands in Japan*. Grassland Science, 2009. **55**: p. 221-224.
[62]. Verak, N., P. Ehkan, R. Ngadiran, S. Jungjit, S. Sitthisarn, M.N. Mohd Warip, M.Z. Ilyas, and F.F. Zakaria, *Comparative Analysis of ELM-Based Blind Image Quality Assessment with K-Fold Cross-Validation*. Journal of Advanced Research in Applied Sciences and Engineering Technology, 2025. **64**(4): p. 213-222.
[63]. Wang, C.-N., H.-T. Tsai, T.P. Ho, V.T. Nguyen, and Y.-F. Huang, *Multi-Criteria*

Decision Making (MCDM) Model for Supplier Evaluation and Selection for Oil Production Projects in Vietnam. Processes, 2020.
[64]. Wang, J., Q. Zhou, J. Shang, C. Liu, T. Zhuang, J. Ding, Y. Xian, L. Zhao, W. Wang, G. Zhou, C. Tan, and Z. Huo, *UAV- and Machine Learning-Based Retrieval of Wheat SPAD Values at the Overwintering Stage for Variety Screening.* Remote Sensing, 2021. **13**(24): p. 5166.
[65]. Wang, J.E. and J.Z. Qiao, *Parameter Selection of SVR Based on Improved K-Fold Cross Validation.* Applied Mechanics and Materials, 2014. **462-463**: p. 182-186.
[66]. Wang, Y., S. Tan, X. Jia, L. Qi, S. Liu, H. Lu, C. Wang, W. Liu, X. Zhao, L. He, J. Chen, C. Yang, X. Wang, J. Chen, Y. Qin, J. Yu, and X. Ma, *Estimating Relative Chlorophyll Content in Rice Leaves Using Unmanned Aerial Vehicle Multi-Spectral Images and Spectral–Textural Analysis.* Agronomy, 2023. **13**(6): p. 1541.
[67]. White, P.A., H.A. Frye, M.F. Christensen, A.E. Gelfand, and J.A. Silander, *Spatial functional data modeling of plant reflectances.* The Annals of Applied Statistics, 2021.
[68]. Wijayanto, A.K., A. Junaedi, A.A. Sujaswara, M.B.R. Khamid, L.B. Prasetyo, C. Hongo, and H. Kuze, *Machine Learning for Precise Rice Variety Classification in Tropical Environments Using UAV-Based Multispectral Sensing.* AgriEngineering, 2023. **5**(4): p. 2000-2019.
[69]. Wold, S., M. Sjöström, and L. Eriksson, *PLS-regression: a basic tool of chemometrics.* Chemometrics and Intelligent Laboratory Systems, 2001. **58**(2): p. 109-130.
[70]. Xu, S., X. Xu, Q. Zhu, Y. Meng, G. Yang, H. Feng, M. Yang, Q. Zhu, H. Xue, and B. Wang, *Monitoring leaf nitrogen content in rice based on information fusion of multi-sensor imagery from UAV.* Precision Agriculture, 2023. **24**(6): p. 2327-2349.
[71]. Xue, J. and B. Su, *Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications.* Journal of Sensors, 2017. **2017**: p. 1-17.
[72]. Xuemei Yao, *Application of Optimized SVM in Sample Classification.* International Journal of Advanced Computer Science and Applications, 2022. **13**(06): p. 540-547.
[73]. Yalçın, G., S. Bayram, and H. Citakoglu, *Evaluation of Earned Value Management-Based Cost Estimation via Machine Learning.* Buildings, 2024. **14**: p. 3772.
[74]. Yu, Y., H. Yu, X. Li, L. Zhang, and Y. Sui, *Prediction of Potassium Content in Rice Leaves Based on Spectral Features and Random Forests.* Agronomy, 2023. **13**(9): p. 2337.
[75]. Zhang, J., T. Cheng, L. Shi, W. Wang, Z. Niu, W. Guo, and X. Ma, *Combining spectral and texture features of UAV hyperspectral images for leaf nitrogen content monitoring in winter wheat.* International Journal of Remote Sensing, 2022. **43**(7): p. 2335-2356.
[76]. Zhong, X., *Application of Spectral Reflectance on Research of Plant Eco-Physiology.* Plant Physiology, 2011.