

TỔNG QUAN ỨNG DỤNG KỸ THUẬT HÌNH ẢNH VÀ HỌC MÁY TRONG DỰ BÁO SỚM STRESS NƯỚC TRÊN CÂY TRỒNG

A REVIEW OF THE APPLICATION OF IMAGING TECHNIQUES AND MACHINE LEARNING FOR EARLY PREDICTION OF WATER STRESS IN CROPS

Lưu Thị Quỳnh Trang¹, Hà Quang Hưng¹,
Vũ Minh Trung¹, Phạm Minh Triển^{1,*}

DOI: <https://doi.org/10.57001/huiv5804.2025.381>

TÓM TẮT

Nước là yếu tố nền tảng quyết định sự sống, sinh trưởng và năng suất của cây trồng. Tuy nhiên, hiện tượng stress nước (thiếu hoặc thừa nước trên cây trồng) sẽ làm suy giảm hiệu quả quang hợp giảm sinh trưởng sinh khối và trong nhiều trường hợp dẫn đến chết cây, ảnh hưởng đến năng suất và làm giảm chất lượng nông sản, đe dọa an ninh lương thực toàn cầu. Các phương pháp phát hiện truyền thống thường tốn kém thời gian, phá huỷ mẫu và phụ thuộc đánh giá chủ quan khiến kết quả không chính xác và chậm. Hiện nay, sự phát triển của các kỹ thuật hình ảnh bao gồm ảnh khả kiến, ảnh nhiệt, ảnh đa phổ, ảnh siêu phổ kết hợp cùng các thuật toán học máy, đặc biệt là các mạng nơ-ron tích chập đã giúp phát hiện sớm, phân loại tình trạng stress nước trên quy mô lớn với độ chính xác cao và tốc độ phân tích nhanh. Nghiên cứu này cung cấp một cái nhìn tổng quan về ứng dụng các kỹ thuật hình ảnh và học máy đã và đang được sử dụng trong chẩn đoán stress nước cùng phân tích các ưu điểm, hạn chế và khả năng ứng dụng trong bối cảnh sản xuất nông nghiệp. Đồng thời, bài báo nhấn mạnh vai trò quan trọng của hệ thống giám sát tích hợp dữ liệu cảm biến và học máy để hỗ trợ người nông dân đưa ra quyết định. Cuối cùng, nghiên cứu đề xuất các hướng phát triển công nghệ tiềm năng để hướng tới xây dựng hệ sinh thái nông nghiệp thông minh, tối ưu hóa hiệu quả sử dụng nước và nâng cao khả năng thích ứng với điều kiện khí hậu đang ngày một khắc nghiệt.

Từ khóa: Stress nước, kỹ thuật hình ảnh, sức khỏe cây trồng, học máy.

ABSTRACT

Water is a fundamental factor determining the survival, growth, and yield of crops. However, water stress significantly impairs photosynthetic efficiency and biomass accumulation, often leading to plant mortality. This compromises crop yield and quality, and threatens global food security. Traditional detection methods are often time-consuming, destructive, and reliant on subjective assessments, resulting in inaccurate and delayed findings. Currently, the advancement of imaging techniques such as visible imaging, thermal imaging, multispectral imaging, and hyperspectral imaging, combined with machine learning algorithms, particularly Convolutional Neural Networks (CNNs), has facilitated the early detection and large-scale classification of water stress with high accuracy and rapid processing speed. This review provides a comprehensive overview of the application of imaging techniques and machine learning in water stress diagnosis, analyzing their advantages, limitations, and applicability in agricultural production contexts. Furthermore, the paper highlights the critical role of monitoring systems that integrate sensor data and machine learning to support farmers in decision-making. Finally, the study proposes potential technological directions aimed at building a smart agriculture ecosystem to optimize water use efficiency and enhance adaptability to increasingly harsh climatic conditions.

Keywords: Water stress, imaging techniques, plant health, machine learning.

¹Trường Đại học Công nghệ, Đại học Quốc gia Hà Nội

*Email: trienpm@vnu.edu.vn


Ngày nhận bài: 15/8/2025

Ngày nhận bài sửa sau phản biện: 15/10/2025

Ngày chấp nhận đăng: 28/11/2025

1. GIỚI THIỆU

Hiện nay, sự cải thiện chất lượng cuộc sống, thực phẩm và công nghệ đã giúp tăng cường sức khỏe và tuổi thọ của con người. Một nghiên cứu được công bố năm 2024 đã dự báo dân số thế giới sẽ liên tục gia tăng và đạt con số 10 tỉ người vào năm 2060, kéo theo các nhu cầu cơ bản về lương thực, cơ sở hạ tầng... cần được cải thiện và bổ sung [1]. Sản lượng của cây trồng phụ thuộc vào rất nhiều yếu tố như: ánh sáng, nhiệt độ, độ ẩm, lượng mưa và dinh dưỡng. Trong đó, nước đóng vai trò quan trọng và ảnh hưởng trực tiếp đến chất lượng, hình thái, tham gia các quá trình sinh lý, vận chuyển chất dinh dưỡng và điều hòa nhiệt độ [2]. Một trong những chức năng quan trọng nhất của nước là tham gia vào quá trình quang hợp nhằm cung cấp oxy cho môi trường, đóng góp trực tiếp vào sự hình thành đường và các hợp chất cac-bon và đóng vai trò nền tảng trong chuỗi dinh dưỡng của cây [3]. Ngoài ra, nước còn tham gia vận chuyển dinh dưỡng, truyền tín hiệu hooc-môn và bảo vệ tế bào khỏi stress oxy hóa [3]. Mặc dù vậy, cây có thể đối mặt với tình trạng bị stress nước, làm giảm khả năng hấp thu các vi chất dinh dưỡng thiết yếu và ảnh hưởng nghiêm trọng đến quá trình tổng hợp protein, carbohydrate và các hợp chất hữu cơ khác trong cây. Khi đó, cây sẽ kích hoạt các cơ chế thích nghi như đóng khí khổng và ức chế sinh trưởng lá để giảm thiểu mất nước (xem hình 1) [4]. Ngược lại, thừa nước cũng ảnh hưởng lớn đến sự sinh trưởng và năng suất của các loại cây trồng nhạy cảm với lũ lụt [5]. Thừa nước dẫn đến tình trạng thiếu oxy do tốc độ khuếch tán chậm trong nước và quá trình tiêu thụ oxy của vi sinh vật cũng như rễ cây.



Hình 1. Sơ đồ minh họa phản ứng của thực vật đối với căng thẳng do stress nước [7]

Nước ngọt đang dần trở thành một nguồn tài nguyên khan hiếm ở nhiều khu vực trên thế giới [6]. Tại Việt Nam,

tình trạng cạn kiệt và ô nhiễm nguồn nước ngày càng nghiêm trọng. Chỉ khoảng 1% tổng lượng nước trên Trái đất có thể sử dụng trực tiếp cho nông nghiệp và sinh hoạt [7]. Trước áp lực gia tăng dân số, đô thị hóa và biến đổi khí hậu, việc phát triển phương pháp quản lý nước hiệu quả là vô cùng cấp thiết. Hiện nay, các công nghệ hình ảnh tiên tiến đang được ứng dụng rộng rãi trong giám sát stress nước ở cây trồng, giúp phát hiện sớm dấu hiệu stress nước và tối ưu hóa việc sử dụng nước. Các kỹ thuật phổ biến bao gồm hình ảnh nhiệt để đo sự thay đổi nhiệt độ tán lá do giảm thoát hơi nước; hình ảnh đa phổ và siêu phổ để phân tích chỉ số thực vật như NDVI (Normalized Difference Vegetation Index), SAVI (Soil Adjusted Vegetation Index); và hình ảnh khả kiến để đánh giá mức độ xanh và cấu trúc tán cây [7]. Kết hợp với các loại cảm biến như cảm biến độ ẩm đất, pH, độ dẫn điện và trí tuệ nhân tạo, các kỹ thuật này không chỉ nâng cao hiệu quả sản xuất mà còn hướng tới một nền nông nghiệp bền vững, thích ứng với biến đổi khí hậu. Mặc dù vậy, hiện nay chưa có một nghiên cứu nào tập trung vào việc tổng hợp ứng dụng cũng như so sánh, đánh giá hiệu quả của các kỹ thuật hình ảnh trong nhận biết sớm stress nước trên cây trồng. Nghiên cứu này không chỉ tổng hợp tình hình phát triển công nghệ, đặc biệt là các kỹ thuật xử lý ảnh và ứng dụng học sâu trong nông nghiệp, còn chỉ ra các nhu cầu thực tiễn, đề xuất những định hướng nghiên cứu cho tương lai.

2. PHƯƠNG PHÁP NGHIÊN CỨU

Nghiên cứu này thực hiện một tổng quan hệ thống để phân tích các kỹ thuật hình ảnh và mô hình học sâu ứng dụng trong giám sát stress nước ở cây trồng. Quy trình được thực hiện thông qua ba bước chính: (1) Xác định các câu hỏi nghiên cứu trọng tâm về loại kỹ thuật hình ảnh, lợi ích - hạn chế và hiệu quả của học sâu; (2) Thu thập tài liệu từ các cơ sở dữ liệu uy tín (Web of Science, Scopus, IEEE Xplore) trong giai đoạn 2015 đến nay, sử dụng hệ thống từ khóa chuyên ngành; (3) Sàng lọc tài liệu theo tiêu chí và trích xuất dữ liệu theo các chủ đề được mã hóa. Bài nghiên cứu tổng quan được cấu trúc thành các phần: tổng quan lý thuyết về stress nước, mô tả chi tiết các kỹ thuật cảm biến hình ảnh (nhiệt, siêu phổ, đa phổ, RGB) và ứng dụng học máy, cùng với đánh giá toàn diện dựa trên độ chính xác, tính ứng dụng và chi phí. Phần kết luận tập trung phân tích thách thức và đề xuất định hướng phát triển cho các hệ thống nông nghiệp thông minh.

3. KỸ THUẬT HÌNH ẢNH TRONG THU THẬP DỮ LIỆU STRESS NƯỚC

Tình trạng nước là một trong những yếu tố quan trọng ảnh hưởng đến sinh trưởng và phát triển của cây trồng.

Nước đóng vai trò thiết yếu trong các quá trình sinh lý của thực vật như quang hợp, vận chuyển dinh dưỡng và điều hòa nhiệt độ. Khi cây bị thiếu nước, sự cân bằng nội môi bị xáo trộn, dẫn đến giảm hiệu suất quang hợp, rối loạn trao đổi chất và thậm chí làm chết cây trong điều kiện nghiêm trọng [4]. Tình trạng ngập úng ngắn hạn ở cây cải xoăn có thể làm thay đổi nồng độ glucosinolate - hợp chất dinh dưỡng quan trọng góp phần tạo nên giá trị dinh dưỡng của loại rau này [8]. Các nhà nghiên cứu đã phát triển nhiều phương pháp để đánh giá stress nước, bao gồm phân tích kiểu hình thực vật dựa trên kỹ thuật hình ảnh nhiệt, ảnh siêu phổ và các công nghệ cảm biến khác [7]. Ảnh khả kiến phân tích màu sắc trong ảnh khả kiến giúp nhận biết sự thay đổi về sắc thái của lá do stress nước, thể hiện qua việc chuyển từ màu xanh đậm sang vàng hoặc nâu. Tuy nhiên, kỹ thuật này thường chỉ phát hiện được khi stress đã ở mức nghiêm trọng [9]. Ảnh siêu phổ cung cấp thông tin chi tiết về phản xạ ánh sáng ở hàng nghìn dải bước sóng, cho phép phát hiện những thay đổi nhỏ nhất trong cấu trúc và thành phần hóa học của lá, giúp nhận biết stress nước ở giai đoạn rất sớm [10]. Ảnh nhiệt đo lường nhiệt độ bề mặt lá bằng ảnh nhiệt giúp xác định mức độ thoát hơi nước của cây. Khi cây bị stress nước, khả năng thoát hơi nước thay đổi, dẫn đến biến đổi nhiệt độ lá, từ đó có thể phát hiện dấu hiệu stress [11]. Ảnh đa phổ sử dụng các dải bước sóng khác nhau để tính toán các chỉ số thực vật như NDVI, giúp phát hiện sự thay đổi trong quang hợp và trạng thái nước của lá ở giai đoạn đầu. Việc kết hợp các kỹ thuật này với học máy giúp phát hiện sớm căng thẳng nước và hỗ trợ quản lý nông nghiệp bền vững [12]. Nhờ đó, các nghiên cứu này không chỉ giúp cải thiện hiệu quả sử dụng nước mà còn hỗ trợ xây dựng chiến lược quản lý nông nghiệp bền vững.

Ứng dụng các kỹ thuật hình ảnh trong thu thập thông tin cây trồng

Hình ảnh RGB thu nhận trong dải ánh sáng khả kiến (xanh lam, xanh lục, đỏ) là công cụ phổ biến để đánh giá sức khỏe thực vật. Dựa trên các chỉ số thực vật như chỉ số diện tích lá (Leaf Area Index, LAI), chỉ số xanh lá (Green Leaf Index, GLI), hình ảnh RGB có thể cung cấp thông tin quan trọng về sự thay đổi sắc tố và sinh khối của cây trồng dưới điều kiện stress nước [13]. Mặc dù có chi phí thấp, ảnh RGB bị hạn chế độ chính xác do phụ thuộc vào điều kiện ánh sáng và góc chụp. Ngược lại, ảnh nhiệt cung cấp đánh giá hiệu quả trạng thái nước thông qua cơ chế nhiệt: khi thiếu nước, khí khổng đóng lại làm tăng nhiệt độ bề mặt lá, cho phép theo dõi khả năng chịu hạn và tối ưu hóa tưới tiêu. Bên cạnh đó, các kỹ thuật ảnh phổ (đa phổ và siêu phổ) phát hiện stress nước thông qua sự thay đổi

phản xạ ánh sáng, đặc biệt là sự gia tăng phản xạ ở dải cận hồng ngoại (800 - 2500nm) do giảm hàm lượng nước trong mô. Việc kết hợp dữ liệu ảnh phổ với mô hình học máy cho phép dự đoán chính xác mức độ stress nước theo thời gian thực.

Ứng dụng ảnh khả kiến

Hình ảnh khả kiến đã được sử dụng rộng rãi trong khoa học thực vật nhờ chi phí thấp và dễ vận hành, bảo trì. Ứng dụng bao gồm phân tích sinh khối, đặc điểm năng suất, hình thái lá và sức sống cây con. Theo nghiên cứu của Fevgas và cộng sự [14], chuyển đổi ảnh RGB sang không gian màu HSV để tách nền và phân tích vùng lá, giúp phát hiện biến đổi cấu trúc tán lá do thiếu nước. Kỹ thuật hợp nhất ảnh RGB và nhiệt (Thermal InfraRed, TIR) làm tăng độ chính xác của mô hình phát hiện sớm căng thẳng nước và tiết kiệm chi phí giám sát [15]. Trong một nghiên cứu đã sử dụng một bộ phân loại tuyến tính đơn giản được sử dụng để tách phần lá xanh của cây khỏi nền ảnh. Sau khi phân đoạn màu, 14 đặc trưng về màu sắc và kết cấu được rút trích cho mỗi ảnh, tương ứng với ba mức tưới (tưới đủ, tưới hạn chế, thiếu nước nghiêm trọng). Mô hình phát hiện hai giai đoạn, huấn luyện với các tập hợp đặc trưng khác nhau, nhằm đánh giá chính xác mức độ stress nước. Mô hình áp dụng thuật toán học có giám sát Gradient Boosting Decision Tree cho kết quả khả quan: độ chính xác phân loại ba mức tưới đạt 80,95% và độ chính xác dự báo stress nước đạt 90,39% [16], chứng minh hiệu quả trong đánh giá điều kiện tưới tiêu trên đồng ruộng.

Ứng dụng ảnh siêu phổ

Kỹ thuật ảnh siêu phổ (Hyperspectral Image, HSI) là một công cụ tiên tiến trong lĩnh vực viễn thám và phân tích hình ảnh, cho phép thu thập thông tin phổ chi tiết trên nhiều dải bước sóng liên tục. Trong việc giám sát stress nước của cây trồng, HSI mang lại ưu thế vượt trội nhờ khả năng phân biệt sự thay đổi sinh lý của cây dựa trên phản xạ phổ. Nghiên cứu trên khoai tây sử dụng camera 710-VP Surface Optics Corporation với 128 dải phổ trong khoảng 400 - 1000nm, trong khi nghiên cứu trên rau diếp sử dụng hệ thống PlantScreen™ (Photon System Instruments, Czechia) với dải phổ 350 - 950nm [17]. Cả hai nghiên cứu đều sử dụng tấm Spectralon để chuẩn hóa dữ liệu phản xạ, cùng các chỉ số thực vật như NDVI, SAVI,... để tách tán lá và phân tích stress nước. Khi kết hợp HSI với thuật toán máy học, các mô hình Random Forest (RF), Extreme Gradient Boosting trong nghiên cứu trên khoai tây cho thấy khả năng phát hiện stress nước chính xác cao nhất khi sử dụng phương pháp majority voting, với các băng tần quan trọng như ~400nm (violet),

~700nm (red edge), ~750 - 1000nm (NIR) [18]. Trong nghiên cứu trên rau diếp, mạng nơ-ron đạt 89,8% chính xác với dữ liệu HSI, trong khi RF đạt 89,7% khi phân loại stress nước dựa trên chỉ số chlorophyll fluorescence, cho thấy hiệu quả của học máy trong trích xuất thông tin từ ảnh phổ. Cả hai nghiên cứu đều chứng minh rằng HSI có thể cung cấp dữ liệu phản xạ chi tiết về stress nước, giúp tối ưu hóa tưới tiêu và hỗ trợ chương trình lai tạo giống cây chịu hạn. Ứng dụng HSI trong nông nghiệp chính xác có thể giúp cải thiện giám sát cây trồng theo thời gian thực, giảm thiểu tổn thất do hạn hán và nâng cao hiệu quả sử dụng tài nguyên nước.


Ứng dụng ảnh nhiệt

Hình ảnh nhiệt ghi lại bức xạ hồng ngoại từ thực vật để chuyển thành hình ảnh nhiệt độ bề mặt, phản ánh trạng thái thoát hơi nước của cây [19]. Về cơ bản, chụp ảnh nhiệt ghi lại những thay đổi trong tương tác giữa bức xạ điện từ và thực vật. Trong số đó, bức xạ hồng ngoại bao gồm hồng ngoại gần (0,75 - 1,3 μ m), hồng ngoại sóng ngắn (1,3 - 3 μ m), hồng ngoại sóng trung (phạm vi từ 3 đến 8 μ m), hồng ngoại xa sóng dài (phạm vi từ 8 đến 14 μ m) và hồng ngoại cực đại (14 - 1000 μ m) [20]. Việc sử dụng hồng ngoại sóng dài, nhạy cảm hơn với nhiệt độ thấp (nhiệt độ trong nhà) có lợi hơn cho việc phân tích kiểu hình thực vật. Nghiên cứu cho cây nho, ứng dụng ảnh nhiệt có thể dự đoán tình trạng nước của cây nho với độ chính xác cao, đạt hệ số xác định R^2 lên tới 0,65 và sai số RMSE chỉ 0,184MPa, ngay cả khi không sử dụng nhiệt độ tham chiếu, cho thấy tiềm năng ứng dụng mạnh mẽ trong giám sát tưới tiêu chính xác và tự động [21]. Ảnh nhiệt hồng ngoại được sử dụng như một công cụ cảm biến từ xa không xâm lấn để ghi nhận nhiệt độ tán lá cây anh đào, từ đó trích xuất các chỉ số như chỉ số căng thẳng nước và chỉ số độ dẫn khí và khi kết hợp với mô hình học máy sử dụng mạng nơ-ron nhân tạo với ảnh chia nhỏ 10x10, mô hình đã dự đoán chính xác chỉ số Ψ_s và g_s với hệ số tương quan cao (R trong khoảng 0,83 đến 0,86), chứng minh tiềm năng lớn của phương pháp này trong giám sát và quản lý tưới tiêu chính xác cho cây trồng [22].

Ứng dụng ảnh đa phổ

Ảnh đa phổ (Multispectral Image, MSI) là một công nghệ viễn thám quan trọng giúp theo dõi stress nước ở cây trồng bằng cách phân tích phản xạ quang phổ trên một số dải bước sóng cụ thể. Không giống như ảnh siêu phổ, MSI chỉ thu thập dữ liệu từ một số lượng giới hạn dải phổ rộng (thường từ 3 - 10 băng tần), nhưng vẫn đủ để cung cấp thông tin quan trọng về tình trạng nước và sinh lý của cây trồng với chi phí thấp hơn [24]. Việc chuyển đổi từ ảnh siêu phổ sang ảnh màu được biết là một nhiệm vụ

đơn giản vì nó chỉ yêu cầu giảm bớt thông tin [24]. Tuy nhiên, quá trình chuyển ngược lại - từ ảnh màu sang ảnh siêu phổ hoặc ảnh đa phổ - không phải là một nhiệm vụ đơn giản (xem hình 2).



Hình 2. Sơ đồ tổng quát của việc chuyển đổi giữa ảnh khả kiến và ảnh siêu/đa phổ

Các nghiên cứu gần đây đã chỉ ra rằng MSI có thể được sử dụng để phát hiện stress nước thông qua các chỉ số thực vật như NDVI, RVI (Ratio Vegetation Index), GRI (Green-Red Index) và WBI. Trong một nghiên cứu về cỏ sân vườn, NDVI, WBI và GRI đã được sử dụng để ước tính hàm lượng nước trong đất và phản ứng của cây với hạn hán. Kết quả cho thấy WBI có mối tương quan mạnh nhất với hàm lượng nước trong đất ($r \geq 0,80$), trong khi NDVI chỉ có hiệu quả khi cây trồng đã bị stress nghiêm trọng [23]. Ưu điểm nổi bật của MSI là khả năng tích hợp trên UAV, cho phép giám sát diện rộng với chi phí thấp. Tuy nhiên, do giới hạn về số lượng dải phổ, MSI khó phân biệt căng thẳng nước với các stress khác như thiếu dinh dưỡng. Để nâng cao độ chính xác, nhiều nghiên cứu đề xuất kết hợp MSI với học máy hoặc cảm biến nhiệt. Bảng 1 đã tóm tắt các kỹ thuật hình ảnh trong giám sát và phát hiện sớm stress nước dựa trên các tiêu chí: chi phí, độ phổ biến, độ chính xác, giai đoạn phát hiện, điểm yếu và tình huống ứng dụng.

Bảng 1. Các kỹ thuật hình ảnh trong giám sát, phát hiện stress nước trên cây trồng

Kỹ thuật	Độ chính xác	Giai đoạn phát hiện	Điểm yếu	Tình huống ứng dụng
RGB	Trung bình	Khả sớm nếu có biến đổi màu hoặc hình thái rõ rệt	Độ chính xác của bị hạn chế do biến dạng kích thước giữa mặt phẳng 2D và cây; không thể xuyên qua tán cây trồng; không phù hợp với môi trường có ánh sáng thay đổi và nhiều vật che khuất [25]	- Phổ biến trong nghiên cứu và thực tiễn (nhà kính,...) - Chi phí rẻ, vận hành đơn giản - Là bước tiền xử lý (kết hợp với TIR)

TIR	Khá cao với stress nước, cần hiệu chỉnh môi trường	Tương đối sớm, dựa vào chênh lệch nhiệt độ lá khi cây thiếu nước	Chỉ thu các đặc điểm liên quan đến nhiệt độ bề mặt; độ phân giải không gian và khả năng lặp lại tương đối kém; khó triển khai hơn so với nhiệt kế hồng ngoại; hiệu quả rất hạn chế trong các chênh lệch nhiệt độ nhỏ [26], dễ bị nhiễu loạn đối với nhiệt độ đất, không khí và tán cây	- Giám sát diện rộng, đo nhanh, không xâm lấn - Tích hợp với UAV hoặc cầm tay để quản lý tưới - Phát hiện stress nước qua chênh lệch nhiệt độ lá
MSI	Tốt với các chỉ số thực vật (NDVI, WBI...), nhưng chi tiết phổ hạn chế	Khá sớm, tùy thuộc vào chỉ số sử dụng (NDVI, WBI...)	Độ phân giải phổ thấp, khó phân biệt stress nước với thiếu dinh dưỡng; phụ thuộc vào điều kiện ánh sáng [27]	- Thích hợp giám sát diện rộng với chi phí vừa phải - Phù hợp hệ thống UAV nông nghiệp chính xác - Phát hiện stress nước sớm, tối ưu tưới tiêu
HSI	Rất cao (ghi nhận hàng trăm băng tần, phân tích tinh vi biến đổi sinh lý)	Khá sớm (có thể sớm hơn MSI do phân giải quang phổ cao)	Trọng lượng nặng so với cảm biến RGB, kích thước dữ liệu lớn đòi hỏi sức mạnh tính toán, thời gian và tài nguyên lớn hơn; không phù hợp với các ứng dụng trực tuyến [28]	- Nghiên cứu học thuật, chọn giống, phân tích chuyên sâu - Dữ liệu phân giải cao, phát hiện biến đổi phổ tinh vi - Triển khai khi cần chính xác cao nhất hoặc có hạ tầng tính toán mạnh

4. CÁC KỸ THUẬT HỌC MÁY TRONG PHÂN TÍCH DỮ LIỆU STRESS NƯỚC

Học máy bao gồm các thuật toán cho phép máy tính tự động học từ dữ liệu để giải quyết các bài toán thực tế, đặc biệt hiệu quả trong xử lý ảnh và phân tích dữ liệu lớn [29]. Nhìn chung, học máy được phân thành ba loại chính (xem bảng 2):

1. Học có giám sát: là phương pháp trong đó mô hình học từ các cặp dữ liệu đầu vào và đầu ra tương ứng để từ đó dự đoán kết quả cho các dữ liệu đầu vào mới [30].
2. Học không giám sát: sử dụng các kỹ thuật phát hiện và phân loại các mẫu tiềm ẩn trong dữ liệu mà không có sẵn nhãn đầu ra.

3. Học tăng cường (Reinforcement Learning, RL): là một nhánh của học máy, trong đó các tác nhân học thông qua việc tương tác với môi trường nhằm tối ưu hóa phần thưởng tích lũy theo thời gian [31].

Đặc biệt trong lĩnh vực nông nghiệp, RL cho thấy tiềm năng lớn trong việc hỗ trợ ra quyết định theo thời gian thực và tự động hóa quy trình. Nhờ khả năng học hỏi liên tục từ môi trường, RL phù hợp với điều kiện nông nghiệp luôn biến động. Mặc dù hiện tại RL vẫn còn ít được áp dụng trong nghiên cứu về căng thẳng nước ở cây trồng [32], nhưng tiềm năng trong việc tối ưu hóa chiến lược tưới tiêu và cải thiện khả năng quản lý thích ứng là rất đáng chú ý và cần được khai thác thêm trong tương lai. Việc lựa chọn thuật toán học máy phù hợp phụ thuộc vào bản chất của vấn đề, số lượng và loại biến đầu vào, cũng như đặc điểm dữ liệu cụ thể. Trong các nghiên cứu gần đây, các thuật toán như máy vectơ hỗ trợ (Support Vector Machines, SVM) đã được ứng dụng hiệu quả trong việc phân tích dữ liệu cảm biến từ xa để đánh giá mức độ căng thẳng nước ở cây trồng.

4.1. Học máy có giám sát


4.1.1. Máy vectơ hỗ trợ

SVM hoạt động bằng cách tìm một siêu phẳng tối ưu để phân tách các lớp dữ liệu với việc sử dụng hàm hạt nhân như tuyến tính, đa thức, Gauss cho trường hợp phi tuyến tính [33]. Mô hình này dựa trên các vectơ hỗ trợ giúp đạt độ chính xác cao ngay cả khi số lượng dữ liệu huấn luyện còn hạn chế [34]. Một ưu điểm nổi bật khác của SVM là khả năng chống lại hiện tượng quá khớp (overfitting) nhờ vào việc duy trì sự cân bằng giữa hiệu quả trên tập huấn luyện và khả năng khái quát hóa sang dữ liệu mới [35]. Azimi và cộng sự [36] đã phát triển một phương pháp nhận dạng căng thẳng nước ở cây đậu gà, sử dụng hình ảnh RGB và các kỹ thuật trích xuất đặc trưng như SIFT (Biến đổi đặc trưng không phụ thuộc vào tỉ lệ) và HOG (Biểu đồ hướng gradient). Các mô hình học máy như KNN (K-Nearest Neighbors), cây quyết định, Naive Bayes và SVM được so sánh, trong đó SVM cho kết quả chính xác cao nhất đạt 73%. Mohite cùng nhóm nghiên cứu [37] áp dụng hình ảnh siêu phổ từ UAV để phát hiện căng thẳng nước ở cây ngô. Các dải bước sóng có ảnh hưởng được lựa chọn làm đầu vào, với hai mô hình SVM và RF được triển khai. SVM vượt trội trong phạm vi bước sóng 670 - 780nm. Sankararao và cộng sự [38] sử dụng dữ liệu siêu phổ từ UAV để phát hiện căng thẳng nước ở cây kê ngọc trai. Sau khi áp dụng các kỹ thuật lựa chọn đặc trưng, các mô hình SVM và RF được đánh giá, với SVM đạt độ chính xác cao tới 95,38% và 80,76% khi phát hiện căng

thắng ở giai đoạn sớm. Những kết quả này khẳng định SVM là một công cụ mạnh mẽ trong việc xử lý dữ liệu phi tuyến và chiều cao, đặc biệt phù hợp với đặc điểm phức tạp của ảnh RGB và ảnh siêu phổ. Khả năng mô hình hóa các mẫu tinh vi trên các dải bước sóng và kết hợp hiệu quả với các phương pháp chọn đặc trưng giúp SVM mang lại kết quả dự đoán vượt trội so với nhiều phương pháp truyền thống khác. Ngoài ra, SVM còn phát huy thế mạnh khi xử lý dữ liệu ở nhiều thang đo, chẳng hạn như trong các ứng dụng wavelet nhờ khả năng kết hợp linh hoạt giữa thông tin thời gian và tần số, cho phép trích xuất các mẫu trọng yếu từ dữ liệu cảm biến.

4.1.2. Mạng nơ-ron nhân tạo

Mạng nơ-ron nhân tạo (Artificial Neural Network, ANN) là một mô hình toán học được McCulloch và Pitts giới thiệu, lấy cảm hứng từ cấu trúc mạng nơ-ron sinh học, với các đơn vị nơ-ron được huấn luyện bằng cách tự điều chỉnh trọng số và độ lệch để ánh xạ các mẫu dữ liệu đầu vào với đầu ra tương ứng. Sau khi được huấn luyện đầy đủ từ dữ liệu lịch sử, ANN có khả năng thích ứng với những thay đổi theo chu kỳ và nhận diện các mẫu phức tạp ẩn trong dữ liệu. ANN với cấu trúc Perceptron đa lớp gồm lớp đầu vào, lớp ẩn và lớp đầu ra, sử dụng hàm kích hoạt để xử lý thông tin [39]. Hình 3 minh họa cấu trúc điển hình của một mạng ANN với các lớp và kết nối giữa các nơ-ron thể hiện quá trình truyền và xử lý thông tin. Nhờ vào khả năng học sâu từ dữ liệu, ANN được ứng dụng phổ biến trong các nhiệm vụ phân loại và nhận dạng, đặc biệt là khi xử lý dữ liệu từ ảnh đa phổ [40].




Hình 3. Cấu trúc mạng nơ-ron nhân tạo

Các mô hình ANN đã được sử dụng hiệu quả trong nhiều ứng dụng quan trọng như: ước tính lượng bốc thoát hơi nước [41] và đặc biệt là đánh giá mức độ căng thẳng nước của cây trồng. Với khả năng thích nghi linh hoạt và xử lý dữ liệu phi tuyến, đa biến phức tạp, ANN là một công cụ đầy tiềm năng trong việc hiện đại hóa nông nghiệp chính xác. Elsherbiny và cộng sự [14] ứng dụng kết hợp ánh sáng khả kiến và hình ảnh nhiệt để trích xuất các đặc điểm màu sắc, kết cấu và chỉ số nhiệt từ cây lúa,

sử dụng tổng cộng 21 đặc trưng đầu vào đạt độ chính xác 99,4%. Carrasco-Benavides và cộng sự [42] sử dụng ảnh nhiệt hồng ngoại để phân tích căng thẳng nước ở cây anh đào thông qua các đặc trưng như nhiệt độ tán cây và độ ẩm tương đối độ chính xác 83% đối với thể nước thân cây, 75% cho độ dẫn khí khổng và 81% tổng thể. Với khả năng học quan hệ phi tuyến, trích xuất đặc trưng tự động và quản lý đa biến, ANN khẳng định vị thế công cụ tối ưu cho hệ thống quản lý nước và hỗ trợ ra quyết định tưới tiêu trong nông nghiệp chính xác.

4.1.3. Mạng nơ-ron tích chập

Năm 1980, K. Fukushima giới thiệu mô hình neocognitron, được xem là tiền đề cho sự phát triển của mạng nơ-ron tích chập (Convolutional Neural Network, CNN) hiện đại [43]. CNN được xây dựng dựa trên ba lớp chính với các chức năng chuyên biệt. Đầu tiên, lớp tích chập sử dụng các bộ lọc để trích xuất đặc trưng cục bộ từ dữ liệu đầu vào. Tiếp theo, lớp gộp (pooling) có nhiệm vụ giảm kích thước dữ liệu, qua đó tăng khả năng khái quát hóa và giảm lượng tham số của mô hình. Cuối cùng, lớp kết nối đầy đủ (fully connected) tổng hợp toàn bộ thông tin đã qua xử lý để đưa ra dự đoán hoặc thực hiện phân loại. Kiến trúc phân tầng này cho phép CNN xử lý hiệu quả dữ liệu hình ảnh và nhận dạng các đặc trưng phức tạp theo cấp độ từ thấp đến cao. Hình 4 minh họa cấu trúc tổng quát của một mạng CNN, thể hiện rõ cách thức dữ liệu được truyền và trích xuất đặc trưng qua các lớp. Mạng CNN bắt đầu từ việc nhận dữ liệu ảnh đầu vào, sau đó lần lượt trải qua các lớp tích chập (kết hợp hàm kích hoạt phi tuyến), lớp gộp và lớp kết nối đầy đủ để đưa ra kết quả cuối cùng. Kiến trúc này cho phép CNN học các đặc trưng phức tạp và tự động từ dữ liệu, đặc biệt hiệu quả trong các tác vụ phân tích hình ảnh.



Hình 4. Cấu trúc cơ bản của mạng CNN

Một điểm mạnh quan trọng của CNN là khả năng tự động học các đặc trưng có ý nghĩa từ dữ liệu hình ảnh, thay vì phải thiết kế thủ công. Khi được huấn luyện với khối lượng dữ liệu lớn, CNN có thể học được các đặc trưng ở mức sâu hơn, từ đó phát hiện các mẫu phức tạp và ẩn trong hình ảnh. Trong lĩnh vực nông nghiệp, CNN đã được

ứng dụng vào nhiều tác vụ quan trọng như: xác định bệnh trên cây trồng, nhận dạng cây trồng... Các mô hình học sâu, đặc biệt là mạng nơ-ron tích chập đã được chứng minh là có hiệu suất vượt trội trong việc phát hiện tình trạng căng thẳng nước ở cây trồng nhờ khả năng học đặc trưng hình ảnh phức tạp và xử lý dữ liệu kiểu hình không xâm lấn. Chandel và cộng sự [44] đề xuất một hệ thống giám sát thời gian thực bằng thiết bị di động. Mô hình GoogLeNet được dùng để phân loại mức độ căng thẳng, đạt độ chính xác 97,9% cho ngô và 92,9% cho lúa mì, với thời gian xử lý chỉ 200 mili giây. Trong một nghiên cứu khác, Melo và cộng sự [45] sử dụng mô hình Inception-ResNet-v2 để phân tích ảnh nhiệt của cây mía, đạt độ chính xác 83%, 90% và 98% tương ứng với các mức 25%, 50% và 100% dung tích nước khả dụng. Những nghiên cứu này nhấn mạnh tính hiệu quả của CNN trong việc học các đặc điểm kiểu hình tinh vi để phát hiện căng thẳng nước mà không cần tiếp xúc vật lý với cây trồng.

4.2. Học máy không giám sát

Thuật toán phân cụm K-means là một phương pháp học không giám sát hiệu quả để phân nhóm dữ liệu dựa trên độ tương đồng nhằm chia tập dữ liệu thành k cụm sao cho tổng bình phương khoảng cách từ các điểm đến tâm cụm là nhỏ nhất [46]. Thuật toán thực hiện lặp đi lặp lại quá trình gán điểm vào cụm và cập nhật vị trí tâm cụm cho đến khi đạt trạng thái hội tụ. Trong nông nghiệp, K-means được sử dụng để phân loại các trạng thái sinh trưởng của cây - chẳng hạn như "không stress", "stress nhẹ" và "stress nghiêm trọng" - dựa trên các chỉ số sinh lý như tốc độ kéo dài lá, nhiệt độ bề mặt lá và hàm lượng nước trong đất [48]. Phương pháp này giúp xác định các ngưỡng stress động, thay vì dựa vào các mốc cố định như truyền thống, từ đó phản ánh chính xác hơn sự thích nghi sinh lý của cây theo thời gian (ví dụ do rễ cây phát triển sâu hơn, tiếp cận nước tốt hơn). Trong nghiên cứu của Owino L. cùng cộng sự, K-means Clustering đã được áp dụng để phân tích dữ liệu tiêu thụ nước hằng ngày của hộ dân, từ đó phát hiện ra 3 kiểu sử dụng nước khác nhau tương ứng với các mùa trong năm. Kết quả cho thấy thuật toán này cho độ hiệu quả phân cụm cao nhất so với các phương pháp khác, với chỉ số Silhouette đạt 0,6315 và Calinski-Harabasz Index đạt 305,92, phản ánh khả năng mô hình hóa tốt hành vi tiêu thụ nước để phục vụ quản lý tài nguyên [47]. Còn trong một nghiên cứu khác, K-means được dùng để phân loại mức độ stress ở cây ngô theo từng giai đoạn sinh trưởng (lá thứ 4 và thứ 5). Các cụm được xác định rõ ràng và mô hình hóa bằng hồi quy bậc nhất đến bậc ba, với độ chính xác R^2 từ 89% đến 98%, cho

thấy khả năng theo dõi diễn tiến ngưỡng stress theo thời gian. Đặc biệt, cụm "high stress" có ranh giới hoàn toàn tách biệt với các cụm khác, chứng minh tính khả thi của phương pháp trong thiết kế hệ thống điều khiển tưới tự động [48]. Tóm lại, K-means Clustering không chỉ là một công cụ học máy mạnh mẽ trong nhận diện water stress mà còn chứng minh hiệu quả thực tiễn thông qua độ chính xác cao, khả năng thích ứng theo thời gian và hỗ trợ ra quyết định trong quản lý nước bền vững.

4.3. Học tăng cường

Bảng 2. Các kỹ thuật học máy trong chẩn đoán stress nước

Kỹ thuật	Loại học máy	Dữ liệu đầu vào	Điểm mạnh	Điểm hạn chế, thách thức
SVM	Có giám sát	- Ảnh RGB, Siêu phổ. - Dữ liệu đặc trưng (SIFT, HOG).	- Hiệu quả với bộ dữ liệu ít. - Chống quá khớp	- Cần bước trích xuất đặc trưng thủ công trước khi đưa vào mô hình.
ANN	Có giám sát	- Ảnh đa phổ, ảnh nhiệt. - Chỉ số sinh lý (màu sắc, kết cấu).	- Thích ứng tốt với dữ liệu phi tuyến, đa biến phức tạp.	- Cần huấn luyện đầy đủ từ dữ liệu lịch sử. - Cấu trúc mạng phức tạp, phụ thuộc vào việc điều chỉnh trọng số/độ lệch.
CNN	Có giám sát	- Ảnh RGB, Ảnh nhiệt. - Dữ liệu hình ảnh thô.	- Tự động trích xuất đặc trưng (không cần làm thủ công).	- Yêu cầu khối lượng dữ liệu lớn để mô hình có thể học các đặc trưng.
K-Means	Không giám sát	- Chỉ số sinh lý (nhiệt độ lá, độ ẩm đất). - Dữ liệu tiêu thụ nước.	- Phân loại được các ngưỡng stress động.	- Không dự đoán nhãn cụ thể ngay lập tức mà chỉ gom nhóm. - Kết quả phụ thuộc vào quá trình lặp để đạt hội tụ.
RL	Học tăng cường	- Tương tác với môi trường (cơ chế thưởng phạt)	- Phù hợp với chiến lược dài hạn	- Ít được áp dụng thực tế hiện nay. - Phức tạp do vấn đề "phần thưởng trễ" (hành động bây giờ nhưng kết quả mới thấy ở cuối vụ).

Học tăng cường là một nhánh của học máy, trong đó một tác nhân học cách ra quyết định thông qua việc

tương tác với môi trường và nhận phản hồi dưới dạng phần thưởng hoặc hình phạt [49]. Thông qua quá trình thử - sai liên tục, tác nhân dần tối ưu hóa chiến lược hành động nhằm đạt được mục tiêu dài hạn trong điều kiện môi trường không chắc chắn và luôn thay đổi. Trong bối cảnh nguồn nước khan hiếm, RL trở thành công cụ tiềm năng để tối ưu hóa chiến lược tưới tiêu và giảm thiểu căng thẳng nước trong nông nghiệp. Hung và Yang đề xuất mô hình RL đa tác nhân mô phỏng hành vi điều chỉnh nhu cầu tưới tiêu, giúp hệ thống thích nghi tốt hơn với hạn hán và giảm nguy cơ cạn kiệt hồ chứa [50]. Ở một hướng tiếp cận khác, Alkaff và cộng sự sử dụng thuật toán Proximal Policy Optimization để phát triển hệ thống tưới tiêu thông minh cho cây ngô, tích hợp trong môi trường mô phỏng AquaCrop-OSPy. Mô hình RL được thiết kế để đối phó với tính chất hành động thưa (sparse action) và phần thưởng trễ (delayed reward) - hai đặc trưng phổ biến trong quản lý nông nghiệp. Cơ chế phần thưởng đặc biệt được xây dựng nhằm vừa phạt các lần tưới không cần thiết, vừa thưởng lớn cho năng suất cao - sử dụng công thức phần thưởng cuối mùa, khuyến khích tác nhân đưa ra quyết định hiệu quả cả ngắn và dài hạn. Kết quả thực nghiệm cho thấy phương pháp PPO giúp giảm 29% lượng nước tưới, nâng cao hiệu suất sử dụng nước lên 76,76kg/ha/mm (cao hơn 40% so với phương pháp tối ưu ngưỡng ẩm SMT), đồng thời tăng lợi nhuận lên 9% [51]. Những ứng dụng này chứng minh tiềm năng của RL trong quản lý tài nguyên nước bền vững cho nông nghiệp hiện đại. Tổng hợp các kỹ thuật học máy trong phân tích stress nước được thể hiện ở bảng 2.

4.4. Hệ thống giám sát stress nước tích hợp học máy

Một trong những ứng dụng quan trọng của học máy là khả năng tích hợp vào hệ thống giám sát tưới tiêu thông minh. Trong nghiên cứu của Gupta cùng cộng sự, nhóm tác giả đã xây dựng một quy trình bán thời gian thực bao gồm thu nhận ảnh CF, xử lý và phân đoạn ảnh, trích xuất chỉ số Fv/Fm và cuối cùng phân loại stress nước bằng mô hình RF. Hệ thống này có tiềm năng ứng dụng rộng rãi trong canh tác quy mô lớn nhờ khả năng tự động hóa cao [52]. Tương tự, việc sử dụng UAV tích hợp camera RGB hoặc TIR để thu thập ảnh từ trên cao giúp giám sát diện rộng và phát hiện kịp thời các khu vực có dấu hiệu stress, từ đó kích hoạt hệ thống tưới tự động chính xác [53]. Các xu hướng hiện nay còn hướng tới phát triển các mô hình học sâu nhẹ có thể triển khai trên thiết bị di động hoặc hệ thống nhúng, giúp tiết kiệm chi phí và nâng cao tính linh hoạt trong ứng dụng thực tế.

5. THÁCH THỨC VÀ TRIỂN VỌNG CỦA CÁC KỸ THUẬT HÌNH ẢNH VÀ CÔNG NGHỆ HỌC MÁY TRONG ĐÁNH GIÁ STRESS NƯỚC

Dù đạt nhiều tiến bộ, việc ứng dụng thực tế các kỹ thuật hình ảnh và AI để phát hiện stress nước vẫn đối mặt với những thách thức đáng kể. Tính không đồng nhất của môi trường ngoài thực địa (biến đổi ánh sáng, sự che khuất tán cây) gây khó khăn cho việc xây dựng các bộ dữ liệu chuẩn. Các mô hình học sâu, vốn đòi hỏi lượng dữ liệu lớn, thường bị sụt giảm hiệu năng khi chuyển từ điều kiện phòng thí nghiệm ra thực địa - đây chính là vấn đề tổng quát hóa. Hơn nữa, tính chất "hộp đen" của nhiều mô hình hạn chế khả năng diễn giải sinh học, làm giảm lòng tin của người sử dụng. Để vượt qua các rào cản này, các hướng nghiên cứu đang tập trung vào phát triển mô hình học nhẹ để triển khai trên thiết bị di động và UAV, kết hợp với học chuyển giao, học bán giám sát để thích ứng với dữ liệu thực tế. Triển vọng dài hạn hướng tới các hệ thống thông minh tích hợp học sâu với mô hình sinh lý cây trồng, cho phép không chỉ giám sát mà còn ra quyết định tưới tiêu thời gian thực, từ đó tạo nền tảng cho một nền nông nghiệp chính xác và bền vững.

6. KẾT LUẬN

Nghiên cứu này thực hiện một đánh giá toàn diện về các kỹ thuật hình ảnh tiên tiến - bao gồm ảnh khả kiến, nhiệt, đa phổ và siêu phổ, trong giám sát và phát hiện stress nước ở cây trồng. Kết quả chỉ ra tiềm năng lớn của việc kết hợp đồng bộ các công nghệ này để phát hiện sớm các dấu hiệu thiếu nước. Để áp dụng thành công, nghiên cứu nhấn mạnh yêu cầu hiểu biết sâu về đặc tính quang học của cây trồng, cùng với các công cụ phần mềm mạnh và quy trình xử lý dữ liệu chính xác. Trong đó, hiệu chuẩn cảm biến và tối ưu hóa quy trình xử lý là các bước then chốt đảm bảo độ tin cậy của kết quả, góp phần quan trọng vào sự phát triển của khoa học thực vật ứng dụng. Đặc biệt, sự kết hợp giữa các kỹ thuật hình ảnh và các chỉ số thực vật đã mang lại những tiến bộ rõ rệt trong việc giám sát stress nước ở các giai đoạn khác nhau của cây trồng, từ giai đoạn đầu khi cây chưa có dấu hiệu rõ rệt cho đến giai đoạn phát triển mạnh. Việc ứng dụng các mô hình học sâu như CNN cho phép tự động hóa và tối ưu hóa quy trình giám sát cây trồng, giảm sự can thiệp của con người. Các phương pháp này không chỉ giúp phát hiện sớm stress nước mà còn mở ra cơ hội phát triển các mô hình phân tích cây trồng tổng quát, có thể áp dụng cho nhiều loài và chủng loại thực vật khác nhau. Sự kết hợp giữa công nghệ chụp ảnh tiên tiến và kỹ thuật học sâu không chỉ giúp các nhà nghiên cứu khai thác tối đa

dữ liệu hình ảnh mà còn đóng góp vào việc tối ưu hóa quy trình sản xuất nông nghiệp. Hơn nữa, việc ứng dụng công nghệ này sẽ góp phần quan trọng trong việc bảo vệ môi trường và đa dạng sinh học, tạo ra những chiến lược canh tác thông minh, hiệu quả và bền vững hơn. Cuối cùng, nghiên cứu này chỉ ra rằng việc kết hợp các công nghệ hình ảnh tiên tiến với học sâu có tiềm năng lớn trong việc phát triển nông nghiệp thông minh và bền vững, mở ra một hướng đi mới cho ngành nông nghiệp toàn cầu.

TÀI LIỆU THAM KHẢO

- [1]. R. Hannah, et al., "Peak global population and other key findings from the 2024 UN World Population Prospects," *Our World in Data*, 2024.
- [2]. S. del Río, et al., "Preliminary Study on Taxonomic Review Using Histological Sections of Some Iberian Species from the Genus *L.* (Fagaceae)," *Am J Plant Sci*, 05, 18, 2773-2784, 2014.
- [3]. A. Singh, et al., "Machine Learning for High-Throughput Stress Phenotyping in Plants," *Trends Plant Sci*, 21, 2, 110-124, 2016.
- [4]. M. M. Chaves, et al., "Understanding plant responses to drought - from genes to the whole plant," *Functional Plant Biology*, 30, 3, 239-264, 2003.
- [5]. D. Schwarz, et al., "Grafting as a tool to improve tolerance of vegetables to abiotic stresses: Thermal stress, water stress and organic pollutants," *Sci Hortic*, 127, 2, 162-171, 2010.
- [6]. Y. Osakabe, et al., "Response of plants to water stress," *Front Plant Sci*, 5, no. MAR, 2014.
- [7]. H. G. Jones, "Application of Thermal Imaging and Infrared Sensing in Plant Physiology and Ecophysiology," *Advances in Botanical Research*, 41, 107-163, 2004.
- [8]. S. R. Brazel, et al., "Overwatering may be as detrimental as underwatering in container-grown kale (*Brassica oleracea* L. *acephala*)," *Sci Hortic*, 316, p. 111961, 2023.
- [9]. S. Mertens, et al., "Monitoring of drought stress and transpiration rate using proximal thermal and hyperspectral imaging in an indoor automated plant phenotyping platform," *Plant Methods*, 19, 1, 2023.
- [10]. D. M. Kim, et al., "Highly sensitive image-derived indices of water-stressed plants using hyperspectral imaging in SWIR and histogram analysis," *Sci Rep*, 5, 2015.
- [11]. M. Pineda, et al., "Thermal imaging for plant stress detection and phenotyping," *Remote Sens.*, 13(1), 68, 2021.
- [12]. A. Singh, et al., "Machine Learning for High-Throughput Stress Phenotyping in Plants," *Trends in Plant Science*, 21, 2, 2016.
- [13]. A. Kior, et al., "RGB Imaging as a Tool for Remote Sensing of Characteristics of Terrestrial Plants: A Review," *Plants*, 13(9), 1262, 2024.
- [14]. O. Elsherbiny, et al., "Integration of visible and thermal imagery with an artificial neural network approach for robust forecasting of canopy water content in rice," *Remote Sens (Basel)*, 13, 9, 2021.
- [15]. G. Fevgas, et al., "Integrating thermal infrared and RGB imaging for early detection of water stress in lettuces with comparative analysis of IoT sensors," *Smart Agricultural Technology*, 11, 2025.
- [16]. S. Zhuang, et al., "Early detection of water stress in maize based on digital images," *Comput Electron Agric*, 140, 461-468, 2017.
- [17]. P. Kumar, R. L. Eriksen, I. Simko, B. Mou, "Molecular Mapping of Water-Stress Responsive Genomic Loci in Lettuce (*Lactuca* spp.) Using Kinetics Chlorophyll Fluorescence, Hyperspectral Imaging and Machine Learning," *Front Genet*, 12, 2021.
- [18]. J. M. Duarte-Carvajalino, et al., "Estimation of water stress in potato plants using hyperspectral imagery and machine learning algorithms," *Horticulturae*, 7, 7, 2021.
- [19]. A. A. Gowen, et al., "Applications of thermal imaging in food quality and safety assessment," *Trends Food Sci Technol*, 21, 4, 190-200, 2010.
- [20]. G. ElMasry, et al., "Emerging thermal imaging techniques for seed quality evaluation: Principles and applications," *Food Research International*, 131, 109025, 2020.
- [21]. S. Gutiérrez, et al., "Vineyard water status assessment using on-the-go thermal imaging and machine learning," *PLoS One*, 13, 2, 2018.
- [22]. M. Carrasco-Benavides, et al., "Water status estimation of cherry trees using infrared thermal imagery coupled with supervised machine learning modeling," *Comput Electron Agric*, 200, p. 107256, 2022.
- [23]. M. J. Badzmierowski, et al., "Using hyperspectral and multispectral indices to detect water stress for an urban turfgrass system," *Agronomy*, 9, 8, 2019.
- [24]. I. Kasajima, "Measuring plant colors," *Plant Biotechnology*, 36, 2, 63-75, 2019.
- [25]. C. Zheng, et al., "Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming," *Remote Sens.*, 13(3), 531, 2021.
- [26]. L. C. Carvalho, et al., "Potential Phenotyping Methodologies to Assess Inter- and Intra-variety Variability and to Select Grapevine Genotypes Tolerant to Abiotic Stress," *Front. Plant Sci.*, 12:718202, 2021.
- [27]. M. J. Badzmierowski, et al., "Using hyperspectral and multispectral indices to detect water stress for an urban turfgrass system," *Agronomy*, 9, 8, 2019.
- [28]. I. T. Ayankojo, et al., "Advances in the Application of Small Unoccupied Aircraft Systems (sUAS) for High-Throughput Plant Phenotyping," *Remote Sens.*, 15(10), 2623, 2023.
- [29]. E. Horvitz, D. Mulligan, "Data, privacy, and the greater good," *Science* (1979), 349, 6245, 253-255, 2015.
- [30]. P. Cunningham, et al., "Supervised learning," in *Cognitive Technologies*, Springer Verlag, 21-49, 2008.

- [31]. L. Pack Kaelbling, et al., "Reinforcement Learning: A Survey," *Journal of Artificial Intelligence Research*, 4, 237-285, 1996.
- [32]. Y. Chen, et al., "A Decision-Making System for Cotton Irrigation Based on Reinforcement Learning Strategy," *Agronomy*, 14, 1, 2024.
- [33]. C. Cortes, V. Vapnik, "Support-vector networks," *Mach Learn*, 20, 3, 273-297, 1995.
- [34]. B. Zheng, et al., "A support vector machine to identify irrigated crop types using time-series Landsat NDVI data," *International Journal of Applied Earth Observation and Geoinformation*, 34, 1, 103-112, 2015.
- [35]. G. Mountrakis, et al., "Support vector machines in remote sensing: A review," *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 3, 247-259, 2011.
- [36]. S. Azimi, T. K. Gandhi, "Water Stress Identification in Chickpea Images using Machine Learning," in *IEEE Region 10 Humanitarian Technology Conference, R10-HTC*, Institute of Electrical and Electronics Engineers Inc., 2020.
- [37]. J. Mohite, et al., "Detection Of Crop Water Stress In Maize Using Drone Based Hyperspectral Imaging," in *International Geoscience and Remote Sensing Symposium (IGARSS)*, Institute of Electrical and Electronics Engineers Inc., 5957-5960, 2022.
- [38]. A. U. G. Sankararao, et al., "Water Stress Detection in Pearl Millet Canopy with Selected Wavebands using UAV Based Hyperspectral Imaging and Machine Learning," in *2022 IEEE Sensors Applications Symposium, SAS 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022.
- [39]. S. Palani, et al., "An ANN application for water quality forecasting," *Mar Pollut Bull*, 56, 9, 1586-1597, 2008.
- [40]. J. Q. Zhang, et al., "Prediction of Soybean Growth and Development Using Artificial Neural Network and Statistical Models," *Acta Agronomica Sinica*, 35, 2, 341-347, 2009.
- [41]. T. Poblete, et al., "Artificial neural network to predict vine water status spatial variability using multispectral information obtained from an unmanned aerial vehicle (UAV)," *Sensors (Switzerland)*, 17, 11, 2017.
- [42]. M. Carrasco-Benavides, et al., "Water status estimation of cherry trees using infrared thermal imagery coupled with supervised machine learning modeling," *Comput Electron Agric*, 200, 107256, 2022.
- [43]. H. Tomimori, et al., "A Convolutional Neural Network with Incremental Learning," *Journal of Signal Processing*, 21, 4, 155-158, 2017.
- [44]. N. S. Chandel, et al., "State-of-the-art AI-enabled mobile device for real-time water stress detection of field crops," *Eng Appl Artif Intell*, 131, 107863, 2024.
- [45]. L. L. de Melo, et al., "Deep learning for identification of water deficits in sugarcane based on thermal images," *Agric Water Manag*, 272, 107820, 2022.
- [46]. T. M. Kodinariya, et al., "Review on determining number of Cluster in K-Means Clustering," *International Journal of Advance Research in Computer Science and Management Studies*, 1, 6, 2013.
- [47]. L. Owino, et al., "Dynamic Water Stress Threshold Determination for Precision Deficit Irrigation Control using Progressive Clustering Approach," in *IFAC-PapersOnLine*, Elsevier B.V., 5287-5292, 2023.
- [48]. H. Guo, et al., "Identifying daily water consumption patterns based on K-means Clustering, Agglomerative Hierarchical Clustering, and Spectral Clustering algorithms," *Aqua Water Infrastructure, Ecosystems and Society*, 73, 5, 870-887, 2024.
- [49]. R. S. Sutton, et al., *Reinforcement Learning: An Introduction Second edition, in progress*, Second edition. The MIT Press Cambridge, Massachusetts London, England, 2015.
- [50]. F. Hung, et al., "Assessing Adaptive Irrigation Impacts on Water Scarcity in Nonstationary Environments - A Multi-Agent Reinforcement Learning Approach," *Water Resour Res*, 57, 9, 2021.
- [51]. M. Alkaff, et al., "Optimizing Water Use in Maize Irrigation with Reinforcement Learning," *Mathematics*, 13, 4, 2025.
- [52]. A. Gupta, et al., "Drought stress detection technique for wheat crop using machine learning," *PeerJ Comput Sci*, 9, 2023.
- [53]. S. S. Virnodkar, et al., "Remote sensing and machine learning for crop water stress determination in various crops: a critical review," *Precision Agric*, 21, 1121-1155 2020.

AUTHORS INFORMATION

Luu Thi Quynh Trang, Ha Quang Hung, Vu Minh Trung, Pham Minh Trien

VNU University of Engineering and Technology, Hanoi, Vietnam