

**BỘ GIÁO DỤC
VÀ ĐÀO TẠO**

**VIỆN HÀN LÂM KHOA HỌC
VÀ CÔNG NGHỆ VIỆT NAM**

HỌC VIỆN KHOA HỌC VÀ CÔNG NGHỆ



NGUYỄN THỊ DUYÊN

**NGHIÊN CỨU GIẢI PHÁP ĐIỀU HƯỚNG CHO ROBOT DI
ĐỘNG PHỤC VỤ GIÁM SÁT MÔI TRƯỜNG VÀ SỰ PHÁT
TRIỂN CỦA CÂY TRỒNG TRONG NÔNG NGHIỆP**

LUẬN ÁN TIẾN SĨ KỸ THUẬT ĐIỆN, ĐIỆN TỬ VÀ VIỄN THÔNG

Hà Nội - 2026

BỘ GIÁO DỤC
VÀ ĐÀO TẠO

VIỆN HÀN LÂM KHOA HỌC
VÀ CÔNG NGHỆ VIỆT NAM

HỌC VIỆN KHOA HỌC VÀ CÔNG NGHỆ

NGUYỄN THỊ DUYÊN

**NGHIÊN CỨU GIẢI PHÁP ĐIỀU HƯỚNG CHO ROBOT DI
ĐỘNG PHỤC VỤ GIÁM SÁT MÔI TRƯỜNG VÀ SỰ PHÁT
TRIỂN CỦA CÂY TRỒNG TRONG NÔNG NGHIỆP**

LUẬN ÁN TIẾN SĨ KỸ THUẬT ĐIỆN, ĐIỆN TỬ VÀ VIỄN THÔNG

Ngành: Kỹ thuật điều khiển và tự động hóa

Mã số: 9 52 02 16

**Xác nhận của Học viện
Khoa học và Công nghệ**

Người hướng dẫn 1

Người hướng dẫn 2

TS. Ngô Mạnh Tiến

GS.TS. Phan Xuân Minh

Hà Nội - 2026

LỜI CAM ĐOAN

Tôi xin cam đoan luận án: "Nghiên cứu giải pháp điều hướng cho robot di động phục vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp" là công trình nghiên cứu của chính mình dưới sự hướng dẫn khoa học của tập thể hướng dẫn. Luận án sử dụng thông tin trích dẫn từ nhiều nguồn tham khảo khác nhau và các thông tin trích dẫn được ghi rõ nguồn gốc. Các kết quả nghiên cứu của tôi được công bố chung với các tác giả khác đã được sự nhất trí của đồng tác giả khi đưa vào luận án. Các số liệu, kết quả được trình bày trong luận án là hoàn toàn trung thực và chưa từng được công bố trong bất kỳ một công trình nào khác ngoài các công trình công bố của tác giả. Luận án được hoàn thành trong thời gian tôi làm nghiên cứu sinh tại Học viện Khoa học và Công nghệ, Viện Hàn lâm Khoa học và Công nghệ Việt Nam.

Hà Nội, ngày tháng năm 2026

Tác giả luận án
(Ký và ghi rõ họ tên)

NCS. Nguyễn Thị Duyên

LỜI CẢM ƠN

Luận án tiến sĩ được hoàn thiện bởi sự cố gắng của chính bản thân cùng với sự giúp đỡ tận tình của Thầy và Cô hướng dẫn khoa học, một số chuyên gia, đồng nghiệp, bạn bè và người thân trong gia đình.

Trước tiên, em xin được bày tỏ lòng biết ơn chân thành đến Tập thể hướng dẫn khoa học: Cô GS. TS. Phan Xuân Minh và Thầy TS. Ngô Mạnh Tiến. Nghiên cứu sinh đã nhận được những định hướng khoa học, những bài học quý báu, sự hướng dẫn tận tình và kinh nghiệm nghiên cứu khoa học quý giá trong nghiên cứu từ Thầy và Cô.

Em xin chân thành cảm ơn tới các thầy, cô giáo và cán bộ của Viện Công nghệ thông tin, Học viện Khoa học và Công nghệ -Viện Hàn lâm Khoa học và Công nghệ Việt Nam đã tạo điều kiện thuận lợi trong suốt quá trình nghiên cứu và thực hiện luận án.

Em xin chân thành cảm ơn tới Ban Giám đốc Học viện Nông nghiệp Việt Nam, Ban chủ nhiệm và các đồng nghiệp Khoa Cơ Điện, đã quan tâm, giúp đỡ em hoàn thành nhiệm vụ.

Cuối cùng, em xin bày tỏ lòng biết ơn tới gia đình, sự khuyến khích động viên của gia đình là động lực để em hoàn thành luận án này.

Hà Nội, ngày tháng năm 2026

Tác giả luận án

NCS. Nguyễn Thị Duyên

MỤC LỤC

MỞ ĐẦU	1
1. Tính cấp thiết của luận án	1
2. Mục tiêu nghiên cứu của luận án	2
3. Ý nghĩa khoa học và thực tiễn của luận án	2
4. Đóng góp mới của luận án	2
5. Bố cục của luận án	3
Chương 1. TỔNG QUAN VỀ ROBOT DI ĐỘNG TRONG NHÀ KÍNH NÔNG NGHIỆP	4
1.1 Cấu trúc hệ thống điều khiển robot di động	4
1.2 Tình hình nghiên cứu trong và ngoài nước	5
1.2.1 Tình hình nghiên cứu trong nước	6
1.2.2 Tình hình nghiên cứu ngoài nước	7
1.3 Robot di động giám sát môi trường và sự phát triển của cây trồng trong nhà kính nông nghiệp thông minh	15
1.3.1 Robot di động thu thập thông số môi trường canh tác nhà kính nông nghiệp	19
1.3.2 Robot di động thu thập, xử lý dữ liệu và nhận diện hình ảnh cây trồng	22
1.3.3 Quá trình điều hướng cho robot di động hoạt động trong môi trường nông nghiệp	29
1.4 Kết luận chương 1	32
Chương 2. GIẢI PHÁP ĐIỀU HƯỚNG CHO ROBOT DI ĐỘNG THU THẬP DỮ LIỆU GIÁM SÁT TRONG NÔNG NGHIỆP	34
2.1 Mạng cảm biến không dây trong nhà kính sản xuất nông nghiệp	34
2.1.1 Giới thiệu về mạng cảm biến không dây	34
2.1.2 Mô hình mạng cảm biến không dây trong nhà kính nông nghiệp	35
2.1.3 Giả thiết mô hình mạng cảm biến không dây và yêu cầu thu thập dữ liệu	38
2.2. Xác định số lượng nút cảm biến đầu cụm	39
2.3 Điều hướng robot di động thu thập dữ liệu trong mạng cảm biến	42
2.4 Đề xuất thuật toán điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây	46
2.4.1 Mục tiêu và các ràng buộc của bài toán	46
2.4.2 Thuật toán điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây	47
2.5. Mô phỏng và đánh giá hiệu quả của thuật toán MRNA	50
2.5.1 Đánh giá kết quả mô phỏng thuật toán MRNA	51

2.5.2 So sánh hiệu suất của thuật toán MRNA với một số thuật toán tương tự khác ảnh hưởng đến tuổi thọ của mạng cảm biến không dây.....	53
2.6 Kết luận chương 2	55
Chương 3. NÂNG CAO CHẤT LƯỢNG PHÁT HIỆN SÂU BỆNH CÂY TRỒNG TRÊN CƠ SỞ TRÍ TUỆ NHÂN TẠO.....	57
3.1 Đặt vấn đề	57
3.2 Khử nhiễu ảnh cây trồng do robot di động thu thập từ cảm biến hình ảnh tại một số nút cảm biến	59
3.2.1 Nhiễu trong ảnh cây trồng trong nhà kính nông nghiệp	59
3.2.2 Phương pháp khử nhiễu ảnh dựa trên biến đổi Wavelet	61
3.2.3 Mô phỏng và đánh giá kết quả	66
3.3 Nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp trên cơ sở trí tuệ nhân tạo.....	73
3.3.1 Các phương pháp phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp	73
3.3.2 Mô hình AI sử dụng trong phát hiện sâu bệnh trên cây trồng	73
3.3.3 Mô hình YOLO trong phát hiện sâu bệnh cây trồng.....	76
3.3.4 Cải tiến mô hình YOLO nhằm nâng cao chất lượng phát hiện sâu bệnh cây trồng	77
3.3.5 Mô phỏng mô hình đề xuất	83
3.3.6 Kết quả mô phỏng và đánh giá hiệu suất của mô hình	88
3.4 Kết luận chương 3	94
DANH MỤC CÔNG TRÌNH KHOA HỌC ĐÃ ĐƯỢC CÔNG BỐ CỦA TÁC GIẢ.....	97
TÀI LIỆU THAM KHẢO	98

DANH MỤC CÁC KÝ HIỆU, CHỮ VIẾT TẮT

1. Danh mục các ký hiệu

Ký hiệu	Ý nghĩa	Đơn vị
E_{XT}	Năng lượng tiêu hao để truyền dữ liệu của nút cảm biến	J
E_{elec}	Năng lượng điện tử tiêu hao	J
$E_{amp}(\gamma, d)$	Năng lượng mạch khuếch đại vô tuyến	J
d	Khoảng cách truyền	m
γ	Số bit dữ liệu truyền đến nút thu	bit
$E_k(t)$	Năng lượng tiêu hao tổng của nút k trong vòng lặp t	J
E_0	Năng lượng ban đầu của nút cảm biến	J
N	Số nút cảm biến trong mạng cảm biến	nút
R_w	Bán kính bánh xe	mm
ω_i	Vận tốc góc của của bánh xe i	rad/s
v_x, v_y	Vận tốc tịnh tiến của tâm Robot	m/s
ω_z	Vận tốc góc quanh tâm của robot	rad/s
$V_r = [v_x, v_y, \omega_z]$	Véc tơ vận tốc của Robot	
PV_k	Giá trị ưu tiên của nút thứ k	
M	Số nút cảm biến đầu cụm trong mạng cảm biến đang xét	cụm
R	Tốc độ truyền dữ liệu	Kb/s
l_{max}	Khoảng cách lớn nhất giữa trung tâm điều khiển và một nút cảm biến trong mạng cảm biến	m
ξ_0	Thời gian báo cáo quy định trước	s
t_{tr0}	Tổng thời gian robot di động sử dụng cho việc di chuyển	s
t_{colo}	Thời gian thu thập dữ liệu từ nút cảm biến đầu cụm xa nhất	s
l_f	Bán kính trung bình của hình quạt tròn	m
H_f	Diện tích của hình quạt tròn	m ²
φ_f	Góc hình quạt	radian
ρ	Mật độ nút cảm biến trong mạng cảm biến	nút/m ²
ξ_{ij}	Chi phí để truyền dữ liệu và MR di chuyển từ nút i đến nút j	s
N_f	Số nút cảm biến trong vùng cảm biến đang xét	nút
$\Re(t)$	Tổng chiều dài quỹ đạo di chuyển của robot MR _f trong khu vực nhiệm vụ của nó tại vòng lặp thứ t	m
$\hat{g}$	Biểu thị ảnh quan sát được	

Ký hiệu	Ý nghĩa	Đơn vị
$g_{i,j}$	Biểu thị ma trận của ảnh gốc	
w	Nhiều trắng Gaussian cộng	
$\eta_{i,j}$	Biểu thị hàm nhiễu	
w_{ij}	Hệ số wavelet gốc	
$\hat{w}_{i,j}$	Hệ số sau khi áp dụng hàm ngưỡng	
λ	Giá trị ngưỡng	
$\hat{\sigma}_w$	Tham số ước lượng	
β	Tham số tỉ lệ	
$\alpha_k(z_k)$	Hàm sigmoid	
α	Hệ số tỷ lệ	
mAP	Giá trị trung bình của độ chính xác trung bình	

2. Danh mục các chữ viết tắt

Chữ viết tắt	Ý nghĩa tiếng Anh	Ý nghĩa tiếng Việt
NCS		Nghiên cứu sinh
ROS	Robot-Operating-System	Hệ điều hành điều khiển robot
MR	Mobile Robot	Robot di động
SLAM	Simultaneous Localization and Mapping	Định vị và xây dựng bản đồ đồng thời
TEB	Timed Elastic Band	Dải đàn hồi có ràng buộc thời gian
CO ₂	Carbon dioxide	Khí cac-bô-níc
WSNs	Wireless Sensor Networks	Mạng cảm biến không dây
CH	Cluster Head	Nút cảm biến đầu cụm
NCC	Network Control Center	Trung tâm điều khiển mạng
MRNA	Monitoring Robot Navigation Algorithm	Thuật toán điều hướng robot di động giám sát
OMS	Optimal Movement Strategy	Chiến lược chuyển động tối ưu
MES	Mean Square Error	Sai số bình phương trung bình
DWT	Discrete Wavelet Transform	Biến đổi Wavelet Rời rạc
DuTS	Dual-threshold shrinkage	Phép co rút ngưỡng kép
AWGN	Additive White Gaussian Noise	Nhiều Gaussian trắng cộng
AI	Artificial Intelligence	Trí tuệ nhân tạo
IoT	Internet of Things	Internet vạn vật

Chữ viết tắt	Ý nghĩa tiếng Anh	Ý nghĩa tiếng Việt
CNNs	Convolutional Neural Networks	Mạng nơ-ron tích chập
R-CNN	Fast Region-based Convolutional Network	Mạng nơ-ron tích chập dựa trên vùng nhanh
YOLO	You Only Look Once	
SiLU	Sigmoid Linear Unit	Khối tuyến tính kết hợp sigmoid
SSD	Single Shot Detector	Bộ phát hiện đối tượng một lần quét
RGB	Red Green Blue	Đỏ, Xanh Lam, Xanh Lục

DANH MỤC BẢNG

Bảng 1.1 Mô tả nhiệm vụ của robot di động trong nhà kính nông nghiệp [42].....	19
Bảng 2.1. So sánh các phương thức truyền tin trong mạng cảm biến không dây [63]	37
Bảng 2.2. Thiết lập các tham số mô phỏng.....	51
Bảng 2.3. Chiều dài quỹ đạo và thời gian thực hiện của robot di động.....	52
Bảng 2.4. Tuổi thọ mạng theo kích thước và mật độ mạng.....	53
Bảng 3.1. Các mô hình nhiễu và hàm mật độ xác suất (PDF) của chúng.....	61
Bảng 3.2 So sánh hiệu suất PSNR (dB) giữa các kỹ thuật ngưỡng wavelet khác nhau đối với các ảnh bị suy giảm bởi nhiễu Gaussian.....	71
Bảng 3.3: Tóm tắt các đặc điểm chính khi so sánh các hàm kích hoạt cơ bản.	82
Bảng 3.4: Phân tích hiệu suất của YOLOv11n với các giá trị α khác nhau trên bộ dữ liệu bệnh cà chua.....	88
Bảng 3.5: Phân tích hiệu suất của YOLOv11n với các giá trị α khác nhau trên bộ dữ liệu bệnh dưa chuột.....	89
Bảng 3.6: So sánh kết quả huấn luyện YOLO trên cùng bộ dữ liệu_Mô hình.....	90
Bảng 3.7: Đánh giá hiệu năng các kiến trúc YOLO trên bộ dữ liệu_bệnh cây dưa chuột.....	91
Bảng 3.8: Đánh giá hiệu năng các kiến trúc YOLO trên bộ dữ liệu_bệnh cây cà chua	91
Bảng 3.9: Đánh giá các hàm kích hoạt thay thế trên dữ liệu bệnh cây cà chua.....	92
Bảng 3.10: Đánh giá các hàm kích hoạt thay thế trên dữ liệu bệnh cây dưa chuột ..	92

DANH MỤC CÁC HÌNH VẼ, ĐỒ THỊ

Hình 1.1 Cấu trúc hệ thống điều khiển robot di động.....	4
Hình 1.2 Ví dụ về nhà kính nông nghiệp	5
Hình 1.3 Hệ thống đo lường và điều khiển môi trường nhà kính nông nghiệp [12] ..	8
Hình 1.4 Mạng cảm biến không dây tích hợp robot di động [20].....	10
Hình 1.5 Giám sát khu vực trong nhà kính bằng robot di động [23]	12
Hình 1.6 Hệ thống robot trong nhà kính trồng cà chua [32].....	13
Hình 1.7 Các hệ thống robot giám sát sâu bệnh trong nhà kính trồng cây cà chua ..	14
Hình 1.8 Nền tảng robot di động [37].....	14
Hình 1.9 Các yếu tố cần giám sát và điều khiển trong nhà kính ảnh hưởng đến sự phát triển của cây trồng	16
Hình 1.10 Mô hình nhà kính nông nghiệp diện tích vài hecta trồng cây cà chua.....	16
Hình 1.11 Cấu trúc của một nút cảm biến [40]	17
Hình 1.12 Sơ đồ hệ thống điều khiển giám sát sự phát triển của cây trồng [46]	23
Hình 1.13 Robot di động thu thập dữ liệu hình ảnh cây trồng từ camera cố định....	24
Hình 1.14 Sơ đồ quy trình triển khai sử dụng học sâu để phân loại và phát hiện sâu bệnh cây trồng [51]	26
Hình 1.15 Mô hình robot di động bốn bánh đa hướng [56].....	29
Hình 1.16 Phần cứng mô hình robot di động bốn bánh đa hướng	31
Hình 1.17 Cấu trúc hệ thống SLAM cho robot di động.....	31
Hình 1.18 Quá trình SLAM của robot và kết quả bản đồ hoá môi trường	31
Hình 1.19 Cấu trúc hệ thống điều hướng cho robot di động.....	31
Hình 1.20 Kết quả điều hướng robot di động dựa trên thuật toán A* và TEB	32
Hình 2.1 Cấu trúc cơ bản của WSNs	34
Hình 2.2 Kiến trúc mô hình giám sát sử dụng WSNs [61]	35
Hình 2.3 Mô hình mạng cảm biến không dây.....	36
Hình 2.4 Các loại cảm biến trong nhà kính nông nghiệp.....	37
Hình 2.5 Xác định số lượng nút cảm biến đầu cụm (CH).....	40
Hình 2.6. Phân vùng trong phương pháp heuristic	43
Hình 2.7. Cách ghép nối các điểm và đường mở	43
Hình 2.8 Đường đi của MR theo phương pháp heuristic	44
Hình 2.9 Lưu đồ thuật toán MRNA	49
Hình 2.10 Quỹ đạo của MR theo thuật toán MRNA	51
Hình 2.11 So sánh tuổi thọ của WSNs giữa các thuật toán OMS1, OMS2, Routing Algorithm và MRNA	55
Hình 3.1 Mô hình robot di động thu thập dữ liệu cảm biến và giám sát cây trồng ..	58

Hình 3.2 Cấu trúc hệ thống phát hiện, cảnh báo và phòng trừ sâu bệnh	58
Hình 3.3 Quá trình suy giảm chất lượng ảnh	60
Hình 3.4 Biến đổi Wavelet Rời rạc 2 chiều (2D-DWT) ba mức trên một ảnh	62
Hình 3.5 Quá trình phân rã ảnh theo thuật toán Mallat [70]	62
Hình 3.6 Quá trình tái tạo ảnh theo thuật toán Mallat.....	63
Hình 3.7 Các hàm ngưỡng được áp dụng cho các hệ số wavelet	65
Hình 3.8 Các ảnh thử nghiệm gốc (không nhiễu)	68
Hình 3.9 Các ảnh thử nghiệm với các mức nhiễu khác nhau: (a) $\sigma = 0.01$, (b) 0.02 , (c) 0.03 và (d) 0.04	69
Hình 3.10 Kết quả khử nhiễu trên các ảnh thử nghiệm với mức nhiễu $\sigma = 0.01$ bằng các phương pháp: (a) BS, (b) NS, (c) AI, (d) OP.	66
Hình 3.11 Kết quả khử nhiễu trên lá cà chua.....	71
Hình 3.12 Kiến trúc của CNN cơ bản [76].	70
Hình 3.13 Kiến trúc chính của các mô hình phát hiện đối tượng [77].....	75
Hình 3.14 Phát hiện vật thể bằng mô hình YOLO [78]	76
Hình 3.15 Lịch sử phát triển các phiên bản YOLO [79]	72
Hình 3.16 Kiến trúc tổng thể của mô hình YOLOv11 [99].	74
Hình 3.17 Chi tiết cấu trúc các lớp trong phần xương sống của mô hình YOLOv11 [91]	80
Hình 3.18 Lớp tích chập hoàn chỉnh với độ lệch b và hàm kích hoạt SiLU [100] ...	80
Hình 3.19 Mối quan hệ của α với hàm α SiLU (a) và đạo hàm của nó (b).....	82
Hình 3.20 Một số hình ảnh mẫu về bệnh trên cây cà chua	84
Hình 3.21 Tóm tắt số lượng hình ảnh và phân bố nhãn theo từng lớp bệnh cà chua trong các tập huấn luyện, xác thực và kiểm tra.....	85
Hình 3.22 Một số hình ảnh mẫu về bệnh trên cây dưa chuột	85
Hình 3.23 Tóm tắt số lượng hình ảnh và phân bố nhãn theo từng lớp bệnh dưa chuột trong các tập huấn luyện, xác thực và kiểm tra.....	81
Hình 3.24 Sơ đồ quá trình ghi nhãn đối tượng.....	87
Hình 3.25 Quá trình huấn luyện mô hình YOLO	87

MỞ ĐẦU

1. Tính cấp thiết của luận án

Sự phát triển của nông nghiệp công nghệ cao trong thời kỳ chuyển đổi số đòi hỏi việc ứng dụng mạnh mẽ các hệ thống cảm biến, robot di động và trí tuệ nhân tạo nhằm tự động hóa quá trình giám sát, thu thập và phân tích dữ liệu trong sản xuất nông nghiệp. Trong đó, nhà kính nông nghiệp là môi trường điển hình có điều kiện canh tác khép kín, cần được kiểm soát chặt chẽ các thông số môi trường như nhiệt độ, độ ẩm, ánh sáng và dinh dưỡng để đảm bảo sự sinh trưởng ổn định của cây trồng.

Việc bố trí mạng cảm biến không dây trong nhà kính giúp theo dõi liên tục các thông số môi trường, nhưng đồng thời đặt ra thách thức về độ bao phủ thu thập dữ liệu, giới hạn năng lượng và tính ổn định truyền thông. Bên cạnh đó, việc giám sát sự phát triển và phát hiện sớm sâu bệnh của cây trồng vẫn chủ yếu dựa vào quan sát thủ công, tốn thời gian và dễ sai sót. Do đó, cần có một giải pháp tự động, hiệu quả và thông minh hơn nhằm hỗ trợ quá trình này.

Trong bối cảnh đó, robot di động được xem là phương tiện thích hợp để tích hợp vào hệ thống giám sát nông nghiệp. Với khả năng di chuyển linh hoạt trong nhà kính, robot di động có thể vừa thu thập dữ liệu môi trường từ các nút cảm biến đầu cụm, vừa tiếp cận và thu nhận hình ảnh cây trồng thông qua cảm biến hình ảnh đặt trong khu vực gần vị trí các cảm biến môi trường. Tuy nhiên, để hệ thống hoạt động hiệu quả, cần nghiên cứu giải pháp điều hướng giúp robot di chuyển hợp lý, đảm bảo thu thập dữ liệu đầy đủ trong thời gian cho phép và giảm mức tiêu thụ năng lượng của các nút cảm biến trong mạng cảm biến không dây.

Đồng thời, dữ liệu hình ảnh cây trồng thu được từ robot di động cần được xử lý và phân tích thông minh nhằm phục vụ giám sát sinh trưởng và phát hiện sớm sâu bệnh cây trồng. Việc nghiên cứu cải tiến mô hình trí tuệ nhân tạo trong nhận diện hình ảnh sẽ giúp nâng cao độ chính xác và hiệu quả của hệ thống giám sát tự động trong điều kiện thực tế nhà kính.

Từ những phân tích trên, đề tài “Nghiên cứu giải pháp điều hướng cho robot di động phục vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp” được lựa chọn nhằm nâng cao hiệu quả làm việc của robot di động hoạt động trong sản xuất nông nghiệp. Trong khuôn khổ của đề tài, nghiên cứu sinh tập trung vào nghiên cứu giải pháp điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây trong nhà kính nông nghiệp. Với bộ dữ liệu hình ảnh cây trồng do robot di động thu thập được, luận án nghiên cứu giải pháp nâng cao chất lượng giám sát cây trồng trên cơ sở trí tuệ nhân tạo, ưu tiên phát hiện sâu bệnh cây trồng.

Việc thực hiện đề tài không chỉ đóng góp vào hướng phát triển robot di động thông minh trong nông nghiệp chính xác, mà còn góp phần thúc đẩy ứng dụng công nghệ điều khiển, tự động hóa kết hợp trí tuệ nhân tạo trong quản lý, giám sát và tối ưu hóa quá trình sản xuất nông nghiệp hiện đại.

2. Mục tiêu nghiên cứu của luận án

- Điều hướng cho robot di động trong nhà kính nông nghiệp đảm bảo thu thập đầy đủ dữ liệu đo từ các nút cảm biến đầu cụm trong thời gian cho phép, ưu tiên giảm mức tiêu thụ năng lượng của các nút cảm biến trong mạng cảm biến không dây.

- Giám sát sự phát triển của cây trồng trong nông nghiệp trên cơ sở trí tuệ nhân tạo, nhằm phát hiện sớm và chính xác sâu bệnh để hỗ trợ kịp thời các biện pháp phòng trừ, góp phần nâng cao năng suất và hiệu quả canh tác.

3. Ý nghĩa khoa học và thực tiễn của luận án

- Ý nghĩa khoa học

Luận án đã nghiên cứu giải pháp điều hướng cho robot di động để đảm bảo robot di động thu thập đầy đủ dữ liệu từ các nút cảm biến trong thời gian cho phép, giảm thiểu mức tiêu thụ năng lượng tại các nút cảm biến. Nghiên cứu cải tiến mô hình trí tuệ nhân tạo nhằm nâng cao chất lượng giám sát cây trồng. Đây là đóng góp có giá trị khoa học, tạo tiền đề cho những nghiên cứu tiếp theo về robot nông nghiệp thông minh và công nghệ giám sát cây trồng.

- Ý nghĩa thực tiễn

Luận án có ý nghĩa thực tiễn trong việc ứng dụng robot di động và công nghệ tự động hóa cho mô hình nhà kính nông nghiệp. Hệ thống robot di động vừa giám sát môi trường, vừa theo dõi sự phát triển của cây trồng và phát hiện sớm sâu bệnh. Giải pháp điều hướng giúp thu thập dữ liệu cảm biến đầy đủ, tiết kiệm năng lượng và nâng cao hiệu quả giám sát. Việc phát hiện sớm và chính xác sâu bệnh cây trồng hỗ trợ xử lý kịp thời, giảm sử dụng thuốc bảo vệ thực vật và hạn chế tác động xấu đến môi trường. Kết quả nghiên cứu góp phần nâng cao năng suất, chất lượng sản phẩm và thúc đẩy phát triển nông nghiệp sạch, bền vững.

4. Đóng góp mới của luận án

Các đóng góp mới của luận án:

- Đề xuất giải pháp điều hướng cho robot di động đảm bảo thu thập đầy đủ dữ liệu từ mạng cảm biến không dây trong thời gian cho phép phục vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp và tiết kiệm năng lượng tiêu thụ của các nút cảm biến.

- Đề xuất cải tiến mô hình YOLO nhằm nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp.

5. Bố cục của luận án

Luận án được trình bày bao gồm phần "Mở đầu" trình bày lý do lựa chọn đề tài, mục tiêu và ý nghĩa khoa học và thực tiễn của luận án, và ba chương chính với nội dung như sau:

Chương 1. Tổng quan về robot di động trong nhà kính nông nghiệp, nghiên cứu tổng quan về cấu trúc hệ thống điều khiển robot di động, tình hình nghiên cứu trong và ngoài nước về điều hướng cho robot di động giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp, phân tích các công bố liên quan đến đối tượng, nội dung và phạm vi nghiên cứu của luận án, từ đó đưa ra hướng nghiên cứu phù hợp cho luận án; sau đó nghiên cứu bài toán robot di động thu thập dữ liệu thông số môi trường canh tác nhà kính từ mạng cảm biến không dây và giám sát cây trồng trong nhà kính nông nghiệp, nghiên cứu mô hình trí tuệ nhân tạo trong phát hiện sâu bệnh cây trồng.

Chương 2. Giải pháp điều hướng cho robot di động thu thập dữ liệu giám sát trong nông nghiệp, nghiên cứu mô hình mạng cảm biến không dây trong nhà kính nông nghiệp, đề xuất lựa chọn số lượng nút cảm biến đầu cụm hợp lý với mục đích tiết kiệm năng lượng tiêu thụ của các nút cảm biến và đề xuất phương pháp điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây đảm bảo đầy đủ trong khoảng thời gian cho phép. Mô phỏng thuật toán trên phần mềm Matlab và so sánh với các phương pháp tương tự khác để kiểm chứng tính hiệu quả của của phương pháp đề xuất.

Chương 3. Nâng cao chất lượng phát hiện sâu bệnh cây trồng trên cơ sở trí tuệ nhân tạo, nghiên cứu và đề xuất thuật toán khử nhiễu ảnh cây trồng mà robot di động thu thập từ cảm biến hình ảnh trong hệ thống camera giám sát cây trồng trong nhà kính nhằm nâng cao chất lượng bộ dữ liệu đầu vào cho mô hình trí tuệ nhân tạo; nghiên cứu và đề xuất cải tiến mô hình YOLO nhằm nâng cao chất lượng phát hiện sâu bệnh trên cây trồng trong nhà kính nông nghiệp. Mô phỏng thuật toán đề xuất và mô hình cải tiến để kiểm chứng hiệu suất của chúng.


Phần Kết luận và Kiến nghị trình bày tóm tắt các đóng góp chính của luận án và hướng phát triển của luận án trong tương lai.

Chương 1. TỔNG QUAN VỀ ROBOT DI ĐỘNG TRONG NHÀ KÍNH NÔNG NGHIỆP

Mô hình nhà kính nông nghiệp nhằm cung cấp sản phẩm nông nghiệp sạch và an toàn đang được quan tâm nghiên cứu phát triển trên toàn thế giới. Tự động hóa nhà kính nông nghiệp dựa trên các robot di động đang thu hút sự quan tâm của các nhà khoa học. Trong chương này, luận án tổng quan về cấu trúc hệ thống điều khiển robot di động, các nghiên cứu trong và ngoài nước liên quan đến lĩnh vực này được đề cập tới. Nghiên cứu nhiệm vụ của robot di động giám sát môi trường và sự phát triển của cây trồng trong nhà kính nông nghiệp thông minh.

1.1 Cấu trúc hệ thống điều khiển robot di động

Cấu trúc của hệ thống điều khiển robot di động chia thành 4 khối chính (Hình 1.1): (1) Khối giao tiếp: Bao gồm các bảng điều khiển với nút bấm, giao diện người-máy (HMI), mạng cảm biến không dây và các module truyền thông phục vụ trao đổi dữ liệu. (2) Khối cảm biến: Tập hợp các cảm biến tiệm cận để phát hiện va chạm, camera 3D để thu nhận thông tin môi trường và hệ thống Lidar dùng cho quét - thu thập dữ liệu bản đồ, sau đó truyền các tín hiệu này về bộ xử lý trung tâm. (3) Khối xử lý trung tâm: Là máy tính nhúng chạy hệ điều hành ROS, thực hiện các chức năng như xây dựng bản đồ, lập kế hoạch quỹ đạo, điều hướng và xử lý các tác vụ truyền thông trong hệ thống. (4) Khối điều khiển bám quỹ đạo: triển khai các thuật toán điều khiển giúp robot bám theo quỹ đạo được gửi từ khối xử lý trung tâm; yêu cầu đảm bảo độ chính xác cao, sai lệch nhỏ và đồng thời cung cấp phản hồi vị trí trở lại cho bộ điều khiển trung tâm.



Hình 1.1 Cấu trúc hệ thống điều khiển robot di động

Hệ thống điều khiển robot di động có thể chia thành 3 giai đoạn: Giai đoạn bản đồ hóa môi trường và định vị vị trí của robot (Simultaneous Localization and Mapping - SLAM), giai đoạn lập kế hoạch đường đi (Path Planning) và giai đoạn điều khiển bám quỹ đạo.

- *Giai đoạn bản đồ hóa môi trường và định vị vị trí của robot*: giai đoạn này cung cấp nhận thức không gian chính xác trong thời gian thực. SLAM cho phép robot đồng thời ước lượng vị trí và tư thế của chính nó trong môi trường, đồng thời xây dựng hoặc cập nhật bản đồ môi trường chưa biết thông qua dữ liệu cảm biến như Lidar, camera và IMU [1], [2]. Nhờ khả năng định vị liên tục và mô hình hóa môi trường nhất quán, SLAM tạo ra nền tảng thông tin đáng tin cậy cho các giai đoạn lập kế hoạch quỹ đạo, điều hướng và tránh vật cản. Việc tích hợp SLAM giúp robot hoạt động tự chủ trong các môi trường phức tạp, không có hệ thống định vị ngoài, đảm bảo độ chính xác và an toàn trong quá trình thực thi nhiệm vụ.

- *Giai đoạn lập kế hoạch đường đi*: là giai đoạn thiết kế một đường đi an toàn, không va chạm với khoảng cách ngắn nhất và ít tốn thời gian nhất từ điểm xuất phát đến điểm đích bởi một robot di động một cách tự động [3]. Lập kế hoạch đường đi được phân loại thành lập kế hoạch đường đi toàn cục và lập kế hoạch đường đi cục bộ dựa trên thông tin môi trường được bản đồ hóa trong giai đoạn SLAM.

- *Giai đoạn điều khiển bám quỹ đạo*: Dựa trên quỹ đạo đã được xác định ở giai đoạn trước, robot sẽ được điều khiển để di chuyển bám sát quỹ đạo này với sai lệch tối thiểu, đồng thời bảo đảm các ràng buộc về vận tốc và gia tốc theo thời gian đều được đáp ứng [4].

1.2 Tình hình nghiên cứu trong và ngoài nước

Nhà kính/nhà màng và nhà lưới nông nghiệp là một hệ thống mô hình canh tác quan trọng trong sản xuất nông nghiệp. Cấu trúc nhà kính nông nghiệp có thể được bao phủ bằng màng kính hoặc màng nhựa, vật liệu trong suốt và mờ (Hình 1.2).



Hình 1.2 Ví dụ về nhà kính nông nghiệp

Công nghệ sử dụng nhà kính để trồng cây này có tầm quan trọng đáng kể, đặc biệt là ở những khu vực có điều kiện khí hậu khắc nghiệt và ô nhiễm. Nhà kính nông nghiệp sẽ tạo ra một môi trường sống thuận lợi cho cây trồng, giúp người trồng cây có thể tự điều chỉnh các yếu tố để phù hợp với loại cây trồng đang canh tác, mang lại nhiều lợi ích không chỉ cho người trồng cây mà còn cả người tiêu dùng, những người

trực tiếp tiêu thụ các sản phẩm nông nghiệp trồng trong nhà kính. Đặc biệt các nhà kính có quy mô diện tích từ vài chục mét vuông đến hàng chục nghìn mét vuông thì phát triển vi khí hậu không đồng đều trong toàn bộ khu phức hợp, đòi hỏi mức độ giám sát cao của con người. Nếu sử dụng hệ thống giám sát truyền thống (mạng cảm biến có dây, các thiết bị đo cảm tay hoặc giám sát bằng quan sát trực tiếp) thì sẽ gặp nhiều khó khăn. Ngoài hệ thống cảm biến không dây giám sát thông số môi trường canh tác nhà kính thay thế cho hệ thống giám sát truyền thống thì sử dụng robot di động cũng là một giải pháp phát triển nhà kính hiện đại hơn.

Robot di động trong nhà kính nông nghiệp được phát triển nhằm thực hiện các nhiệm vụ tự động hóa trong môi trường canh tác có điều kiện điều khiển đặc thù, nơi nhiều công đoạn vẫn phụ thuộc vào sức lao động thủ công. Các nhiệm vụ chính của robot di động bao gồm thu hoạch, chăm sóc, vận chuyển, phun thuốc, bón phân và giám sát cây trồng. Tuy nhiên, trong hệ thống canh tác nhà kính hiện đại, việc giám sát chính xác và liên tục các yếu tố ảnh hưởng đến sinh trưởng cây trồng là yêu cầu cốt lõi để tối ưu hóa năng suất và chất lượng nông sản. Robot di động được xem là nền tảng quan trọng trong quá trình này, đảm nhiệm nhiệm vụ thu thập dữ liệu cảm biến và giám sát sự phát triển của cây trồng một cách tự động, chính xác và kịp thời. Chính vì vậy, hiện nay nhiều nhà nghiên cứu cũng như các cơ sở sản xuất nông nghiệp đã và đang quan tâm đến robot di động hoạt động trong nhà kính nông nghiệp.

1.2.1 Tình hình nghiên cứu trong nước

Nhà kính nông nghiệp đã và đang được ứng dụng rộng rãi trong sản xuất nông nghiệp công nghệ cao ở Việt Nam. Việc nghiên cứu và phát triển nhà kính nông nghiệp được một số nhóm nghiên cứu trong nước quan tâm và triển khai đến những công nghệ và kỹ thuật sử dụng trong nhà kính nông nghiệp. Các nhóm nghiên cứu trong nước tập trung nghiên cứu, thiết kế, chế tạo và ứng dụng hệ thống cảm biến. Hệ thống này có nhiệm vụ giám sát nhiệt độ, độ ẩm không khí và ánh sáng trong nhà kính. Từ đó cung cấp dữ liệu cho hệ thống điều khiển để điều khiển quạt, phun sương và một số hệ thống khác trong nhà kính nông nghiệp. Trong đó, nghiên cứu [5] đã chế tạo thiết bị tích hợp các cảm biến, vi điều khiển và công nghệ IoT gồm các module cảm biến kết nối WiFi với mô đun trung tâm để giám sát vi khí hậu như nhiệt độ, độ ẩm, ánh sáng trong nhà màng. Tương tự như vậy, nghiên cứu [6] đã thiết kế, chế tạo hệ thống thu thập và lưu trữ dữ liệu các thông số ảnh hưởng đến quá trình sinh trưởng và phát triển của cây trồng trong nhà lưới. Cũng thiết kế hệ thống thu thập dữ liệu môi trường trong nhà màng, các tác giả của [7] đã sử dụng nhiều cảm biến và cho phép truyền dữ liệu không dây để theo dõi thông số môi trường trong nhà màng. Các dữ liệu thu thập từ cảm biến được xử lý từ máy tính nhỏ sau đó truyền về máy chủ thông qua chuẩn kết nối mạng không dây.

Với mạng truyền thông như vậy phù hợp với việc truyền dữ liệu khoảng cách ngắn và nhà màng diện tích nhỏ. Các nghiên cứu trên đề xuất việc thu thập dữ liệu phục vụ giám sát môi trường nhà kính nhỏ nên giải pháp nghiên cứu đề xuất để thu thập dữ liệu môi trường canh tác nhà kính là sử dụng các cảm biến cố định.

Các tác giả trong nghiên cứu [8] đã xây dựng quỹ đạo cục bộ nhằm tránh các vật cản tĩnh và động sử dụng thuật toán TEB (Timed Elastic Bands) dựa trên bản đồ, định vị đồng thời SLAM (Simultaneous Localization and Mapping) cho robot tự hành hoạt động trong các nhà lưới trồng cây nông nghiệp. Nghiên cứu chỉ dừng ở việc mô phỏng với một nhà lưới quy mô nhỏ, là bước đầu cho bài toán điều hướng robot di động trong nhà kính nông nghiệp mà chưa gắn với nhiệm vụ cụ thể của robot di động hoạt động trong nhà lưới đó.

Một số các công bố khác [9], [10] đã nghiên cứu đến việc điều hướng cho robot di động trong môi trường sản xuất nông nghiệp cụ thể hơn. Các nghiên cứu này đề xuất xây dựng định vị, điều hướng dựa trên SLAM và điều khiển bám quỹ đạo dẫn đường canh tác của robot nông nghiệp bằng bộ điều khiển phản hồi trạng thái tuyến tính.

Ngoài ra, giám sát sự phát triển của cây trồng trong nhà lưới thông qua thu thập dữ liệu hình ảnh cây trồng và phát triển hệ thống phát hiện sâu bệnh cây trồng cũng được một số nhà nghiên cứu trong nước quan tâm. Các tác giả của [11] đã nghiên cứu và thiết kế một hệ thống giám sát sâu bệnh trên cây dưa chuột trồng trong nhà kính dựa trên việc cải tiến mô hình trí tuệ nhân tạo phát hiện sâu bệnh cây trồng có độ chính xác đạt yêu cầu và hệ thống bước đầu hoạt động ổn định.


1.2.2 Tình hình nghiên cứu ngoài nước

Trên thế giới, nhà kính nông nghiệp thông minh được ứng dụng rộng rãi và ngày càng phát triển hơn. Vì vậy, đã có nhiều nghiên cứu về công nghệ tiên tiến sử dụng trong nhà kính nông nghiệp hiện đại và vấn đề quản lý nhà kính nông nghiệp.

Nghiên cứu [12] thì cho rằng hệ thống đo lường và điều khiển môi trường sản xuất nhà kính nông nghiệp đã ứng dụng công nghệ IoT. Các tín hiệu quan trọng về nhiệt độ, độ ẩm và đất được thu thập theo thời gian thực trong quá trình sản xuất nông nghiệp, được truyền qua mạng không dây thông qua nền tảng hỗ trợ M2M (máy với máy). Hệ thống này thu thập dữ liệu thời gian thực về môi trường sản xuất nông nghiệp bằng cách sử dụng SMS (Dịch vụ nhắn tin ngắn), web, WAP (giao thức ứng dụng không dây), để thiết bị đầu cuối có thể nắm bắt thông tin nhằm hướng dẫn sản xuất (Hình 1.3).

Tuy nhiên, một thách thức phổ biến trong các nhà kính có diện tích từ vài chục nghìn mét vuông trở lên là sự không đồng đều của vi khí hậu giữa các khu vực bên trong, đòi hỏi hệ thống giám sát và điều khiển môi trường vi mô theo từng vùng, thay thế cho phương pháp thủ công vốn tiêu tốn nhiều thời gian và công sức. Giải pháp

đầu tiên cho hệ thống giám sát và điều khiển môi trường nhà kính phải kể đến đó là mạng cảm biến không dây. Nghiên cứu [13] chỉ ra rằng phần lớn hệ thống nhà kính trước đây dùng cảm biến có dây đều khó lắp đặt, khó mở rộng và tốn kém chi phí bảo trì hơn so với hệ thống không dây. Việc đưa WSNs vào nhà kính cho phép triển khai mạng cảm biến mật độ cao với chi phí hợp lý, qua đó phản ánh chính xác hơn sự biến động vi khí hậu trong không gian trồng trọt. Đồng thời, hệ thống WSNs giúp cải thiện đáng kể khả năng bảo trì và tận dụng không gian so với giải pháp có dây truyền thống [14]. Vì vậy, có nhiều nghiên cứu trên thế giới đã đề xuất xây dựng mạng cảm biến không dây để thu thập dữ liệu môi trường canh tác nhà kính với các diện tích cũng như cây trồng khác nhau.



Hình 1.3 Hệ thống đo lường và điều khiển môi trường nhà kính nông nghiệp [12]

Nghiên cứu [15] đã triển khai một mạng cảm biến không dây trong nhà kính trồng cà chua diện tích khoảng một nghìn mét vuông nhằm giám sát vi khí hậu và phục vụ hệ thống hỗ trợ ra quyết định trong nông nghiệp chính xác. Mạng cảm biến gồm các nút cố định bố trí theo dạng lưới, mỗi nút được trang bị cảm biến đo nhiệt độ không khí, độ ẩm, nhiệt độ đất và truyền dữ liệu định kỳ (mỗi phút) qua giao thức SensiNet™ theo chuẩn IEEE 802.15.4, đến nút cầu nối và trạm gốc để lưu trữ và xử lý. Dữ liệu được thu thập liên tục nhằm thiết lập tương quan giữa tín hiệu cảm biến và điều kiện vi khí hậu, hỗ trợ phát hiện nguy cơ phát sinh bệnh trên cây trồng và tối

ưu hóa việc bón phân, tưới nước và phun thuốc. Hay trong nghiên cứu [16], nhóm tác giả đã phát triển một mạng cảm biến không dây nhằm giám sát các thông số vi khí hậu trong nhà kính, bao gồm nhiệt độ, độ ẩm, cường độ ánh sáng và nồng độ CO₂. Hệ thống sử dụng các nút cảm biến cố định được tích hợp từ nền tảng Sensinode với các cảm biến thương mại, truyền dữ liệu qua giao thức 6LoWPAN/IEEE 802.15.4 đến nút trung tâm theo kiến trúc sao. Mỗi nút hoạt động theo chu kỳ ngủ - thức định kỳ, gửi dữ liệu về máy tính trung tâm đặt bên ngoài nhà kính để xử lý và lưu trữ. Kết quả cho thấy hệ thống có khả năng phát hiện sự khác biệt về vi khí hậu giữa các tầng cây trồng, tuy nhiên phạm vi truyền thông bị giới hạn (chỉ khoảng 10 m trong môi trường cây trồng dày đặc), cùng với tỷ lệ mất gói dữ liệu khoảng 5%.


Mạng cảm biến không dây cũng đã được triển khai tại các nhà kính có diện tích lớn hơn như ở trong nghiên cứu [17], [18]. Mạng cảm biến trong nghiên cứu [17] được triển khai tại nhà kính 500–1000 m², sử dụng LoRaWAN cho liên lạc xa, với các cảm biến đo nhiệt độ, độ ẩm, ánh sáng, CO₂, EC. Các hộp cảm biến được treo trên ray phía trên luống cây, đảm bảo thông gió để đo chính xác. Dữ liệu được truyền định kỳ 5 phút/lần về nút trung tâm và hiển thị trên bảng điều khiển phục vụ giám sát cây trồng. Trong khi đó, mạng cảm biến trong nghiên cứu [18] gồm 100 nút cảm biến được phân bố đều trong nhà kính dưa chuột (90×170) m, mỗi nút cảm biến đo nhiệt độ và độ ẩm ở độ cao 1,8 m. Dữ liệu truyền về trạm gốc qua sóng radio, khoảng cách liên lạc hiệu quả trong nhà kính khoảng (30–65) m (tùy điều kiện).

Nghiên cứu [19] đã triển khai một mạng cảm biến không dây để giám sát sự phân bố không gian và thời gian của nhiệt độ và độ ẩm tương đối trong các nhà kính thương mại trồng hoa và rau. Hệ thống sử dụng 100 nút cảm biến không dây bố trí theo lưới cố định trong không gian nhà kính (mật độ 58–128 cảm biến/ha), hoạt động ở độ cao ngang tán cây và truyền dữ liệu định kỳ mỗi phút về trạm gốc qua giao thức kết nối không dây để xử lý và phân tích. Dữ liệu thu được được dùng để xác định các điểm lạnh hoặc ẩm cục bộ, phục vụ tối ưu hóa hệ thống tưới, thông gió và tiết kiệm năng lượng.

Các nghiên cứu trên chứng minh hiệu quả của mạng cảm biến không dây chỉ sử dụng các cảm biến đặt cố định để thực hiện nhiệm vụ thu thập dữ liệu nhằm giám sát môi trường canh tác nhà kính nông nghiệp. Tuy nhiên, phương thức thu thập dữ liệu này có nhiều hạn chế như: (1) các nút cảm biến cố định chỉ phản ánh thông tin tại các vị trí đặt trước, khó bao quát toàn bộ biến động vi khí hậu; (2) chi phí triển khai và bảo trì cao khi số lượng cảm biến lớn; (3) suy giảm tín hiệu và độ tin cậy trong môi trường ẩm và nhiều vật cản; (4) hao tổn năng lượng do truyền dữ liệu liên tục. Những hạn chế này cho thấy nếu trong mạng cảm biến không dây chỉ sử dụng

các cảm biến cố định khó đảm bảo tính linh hoạt và hiệu quả lâu dài trong các mô hình nhà kính quy mô lớn. Do đó, hướng nghiên cứu sử dụng kết hợp các nút cảm biến cố định và robot di động để di chuyển thu thập dữ liệu tại các nút cảm biến đầu cụm là giải pháp khả thi giúp giảm mật độ cảm biến, tiết kiệm năng lượng, nâng cao độ chính xác và khả năng mở rộng của hệ thống giám sát môi trường và cây trồng trong nông nghiệp.

Một số nghiên cứu cũng như nhà kính nông nghiệp thực tế đã chọn giải pháp sử dụng hệ thống robot di động thu thập dữ liệu từ mạng cảm biến không để giám sát môi trường và cây trồng trong nông nghiệp (Hình 1.4)



Hình 1.4 Mạng cảm biến không dây tích hợp robot di động [20]

Các nghiên cứu đã đề xuất điều hướng cho robot di động thu thập dữ liệu môi trường sản xuất nông nghiệp theo các phương pháp khác nhau.

Cụ thể như, hệ thống robot tự động AGRI-BOT đã được phát triển và triển khai [21]. AGRI-BOT là một loại robot chuyên dụng, được thiết kế để vận hành trong môi trường nhà kính công nghiệp hiện đại, nơi có đủ không gian cho robot di chuyển và thực hiện các tác vụ một cách hiệu quả. Trong nghiên cứu này, robot này di chuyển tự động theo lộ trình định sẵn, dừng tại các điểm kiểm tra để thu thập dữ liệu môi trường như nhiệt độ, độ ẩm, ánh sáng và nồng độ khí.

Nghiên cứu [22] sử dụng một bồn thu (mobile sink) di động tuần tự di chuyển trong vùng cảm biến để thu thập dữ liệu từ các nút phân tán. Trong quá trình thu thập, thông tin về năng lượng còn lại của các nút được ghi nhận nhằm lập lịch vị trí dừng kế tiếp cho bồn thu và khi đó bồn thu có xu hướng tiến tới các nút còn nhiều năng


lượng. Phương pháp này sẽ dẫn đến sự mất cân bằng trong tiêu thụ năng lượng giữa các nút vẫn tồn tại và trở thành nguyên nhân chính làm giảm tuổi thọ mạng.

Trong khi đó, các tác giả trong nghiên cứu [23] trình bày bài toán giám sát khu vực trong nhà kính bằng robot di động (Hình 1.5). Nhà kính trong nghiên cứu có kích thước $40 \times 50 \text{ m}^2$ (chia thành 10 tiểu vùng), sử dụng robot di động gắn cảm biến thay vì các nút cảm biến tĩnh. Robot di chuyển theo một quỹ đạo cho trước, được điều hướng qua khu vực giám sát đã xác định dọc theo quỹ đạo. Nghiên cứu đề xuất một robot di động giám sát khu vực (Mobile Robot for Area Monitoring - MRAM). MRAM được trang bị một mô-đun vô tuyến không dây, một bộ nguồn và các cảm biến khác nhau như camera và cảm biến độ ẩm. Lớp ứng dụng hoặc máy chủ đám mây thực hiện nhiệm vụ giám sát khu vực; cụ thể là, máy chủ đám mây phân tích nhiệm vụ thành nhiều bước và xác định các lệnh chính cho các nút di động theo thông tin toàn cục của nhà kính. MRAM hoàn tất việc giám sát khu vực theo các lệnh đám mây đưa ra. Cuối cùng, MRAM di chuyển dọc theo đường dẫn lập kế hoạch, nó sẽ truyền thông tin đến máy chủ đám mây thông qua hệ thống IoT.

Trong nghiên cứu [24], robot thông minh được thiết kế để hoạt động trong nhà kính có địa hình gồ ghề, ẩm ướt và điều kiện môi trường không đồng đều, nơi cây trồng dễ chịu ảnh hưởng bởi nhiệt độ, độ ẩm, CO_2 và tia UV. Robot có khả năng di chuyển tự động theo lộ trình định sẵn, tránh va chạm nhờ cảm biến siêu âm và điều khiển ổn định bằng bộ PID kết hợp hệ thống bánh xích. Kết quả thực nghiệm cho thấy robot có thể làm việc liên tục 8 giờ trong nhà kính 2500 m^2 , thu thập dữ liệu môi trường tại nhiều điểm và truyền về nút trung tâm qua LoRaWan, ngay cả khi thiếu kết nối Internet. Dữ liệu này được xử lý bằng thuật toán K-means để phân loại các khu vực cây trồng thành ba nhóm (tối ưu, tiêu chuẩn, kém), với độ chính xác trên 90% so với đánh giá của nông dân.

Trong nghiên cứu tại [25], nhóm tác giả đã phát triển một robot di động tuần tra tự động nhằm thu thập thông tin môi trường trong nhà kính trồng cây trên giàn cao, nơi việc lắp đặt nhiều cảm biến cố định gây tốn kém và thiếu linh hoạt. Robot có kích thước nhỏ gọn, được trang bị cảm biến CO_2 , nhiệt độ, độ ẩm và máy quét laser đo khoảng cách, hoạt động trên nền tảng ROS để vừa lập bản đồ vừa tránh chướng ngại vật. Kết quả thực nghiệm cho thấy robot có thể di chuyển ổn định theo lộ trình định sẵn với tốc độ $0,17 \text{ m/s}$, thu thập khoảng 500 điểm dữ liệu mỗi lần tuần tra, tương đương hiệu quả của hàng chục cảm biến cố định. Hệ thống này đã chứng minh khả năng cung cấp bản đồ môi trường trực quan, hỗ trợ nông dân đánh giá điều kiện trong toàn bộ nhà kính theo thời gian thực.

Các nghiên cứu này đề xuất giải pháp điều hướng cho robot tránh chướng ngại vật trong quá trình di chuyển. Tuy nhiên, các robot trong nghiên cứu như một nút cảm biến di động đi thu thập dữ liệu môi trường nhà kính mà chưa đề cập đến nhiệm vụ thu thập dữ liệu tại các nút cảm biến đầu cụm của mạng cảm biến không dây.



Hình 1.5 Giám sát khu vực trong nhà kính bằng robot di động [23]

Trong thực tiễn trên thế giới, nhà kính quy mô lớn thường được thiết kế với diện tích từ hàng chục nghìn đến hàng trăm nghìn mét vuông, đáp ứng yêu cầu canh tác nông nghiệp công nghệ cao đối với các loại cây trồng có giá trị như cà chua, dưa chuột, hoa và các loại rau thủy canh. Một ví dụ điển hình là tổ hợp nhà kính Thanet Earth tại Vương quốc Anh [26], là hệ thống nhà kính thương mại lớn nhất quốc gia này với tổng diện tích lên đến khoảng 90 ha. Tại đây, việc canh tác được thực hiện hoàn toàn trong môi trường khép kín với hệ thống nhiệt và điện kết hợp, sử dụng khí CO₂ tái chế và robot hỗ trợ thụ phấn nhằm tối ưu hóa hiệu quả sản xuất.

Ngoài ra, cây trồng trong nhà kính nông nghiệp hiện đại luôn được giám sát chặt chẽ về quá trình sinh trưởng và phát triển, đặc biệt phát hiện sâu bệnh trên cây trồng. Việc giám sát cây trồng thông qua các công nghệ sử dụng đầu vào là hình ảnh từ camera đã được phát triển và nghiên cứu trong nhiều năm trở lại đây khi sự phát triển mạnh mẽ của thị giác máy tính và trí tuệ nhân tạo. Đã có nhiều công trình nghiên cứu sử dụng công nghệ xử lý ảnh [27], trí tuệ nhân tạo bằng việc thông qua hình ảnh của lá có thể xác định được thiếu hụt dinh dưỡng [28], sâu bệnh [29], [30] của cây trồng.


Trong hệ thống phát hiện bệnh trên cây trồng trong nhà kính nông nghiệp, robot có thể tham gia và đảm nhiệm nhiều giai đoạn quan trọng, góp phần tự động hóa, nâng cao hiệu quả cũng như tính kịp thời của quá trình giám sát. Nhiều các nhà nghiên cứu đã quan tâm đến việc nghiên cứu, thiết kế và chế tạo hệ thống robot có khả năng phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp trên cơ sở trí tuệ

nhân tạo. Cụ thể, nghiên cứu [31] xây dựng robot có khả năng giám sát điều kiện đất, phát hiện bệnh lá và tự động thực hiện tưới tiêu hoặc phun thuốc, kết hợp cảnh báo SMS đến người nông dân. Robot trong nghiên cứu được điều khiển bằng ứng dụng hệ điều hành Android để di chuyển trong nhà kính thực hiện nhiệm vụ của nó. Các tác giả trong nghiên cứu [32] đã thiết kế một robot triển khai việc phân tích thực địa về sức khỏe cây trồng bằng phương pháp quang phổ khả kiến và cận hồng ngoại. Robot được thử nghiệm trong môi trường nhà kính trồng cà chua. Hình 1.6 minh họa cách hệ thống robot được sử dụng trong nhà kính để đo lường sức khỏe cây cà chua. Góc của giá đỡ camera có thể được điều chỉnh thông qua chân máy đơn để đặt camera ở góc mong muốn. Robot di chuyển các luống thẳng được trang bị hệ thống nhận diện chướng ngại vật, chụp ảnh các chậu cây bằng cả camera RGB và NIR để tính toán chỉ số NDVI và lập bản đồ sức khỏe.




Hình 1.6 Hệ thống robot trong nhà kính trồng cà chua [32]

Trong khi đó, các nghiên cứu [33-36] đều đề xuất hệ thống robot di động trong nhà kính trồng cây cà chua có gắn camera hỗ trợ thu thập hình ảnh cây trồng phục vụ phát hiện sâu bệnh. Tuy nhiên, các hệ thống robot này đều di chuyển trên các đường ray được thiết kế sẵn trong nhà kính thể hiện trên Hình 1.7. Điều này làm giảm tính linh hoạt của hệ thống robot đồng thời tăng chi phí cho hệ thống giám sát cây trồng ở những khu vực mà robot đi qua.



Hình 1.7 Các hệ thống robot giám sát sâu bệnh trong nhà kính trồng cây cà chua

Bên cạnh đó, chỉ ít các nghiên cứu đề cập đến bài toán điều hướng cho robot di động trong nhà kính nông nghiệp. Trong đó, nghiên cứu [37] đề xuất một thuật toán hợp nhất lập kế hoạch đường đi tích hợp thuật toán A* cải tiến và thuật toán tiếp cận cửa sổ động mờ (FDWA) nhằm tránh chướng ngại vật cho robot di động bốn bánh trong nhà kính diện tích nhỏ (Hình 1.8).



Hình 1.8 Nền tảng robot di động [37]

Một nghiên cứu gần đây của các tác giả trong [38] đã đề xuất một thuật toán tối ưu bộ phân lai cải tiến (Hybrid Dung Beetle Optimization – HDBO) nhằm giải quyết các thách thức trong bài toán lập kế hoạch đường đi. Kết quả thực nghiệm cho thấy, đối với 7 hàm thử nghiệm đơn cực, HDBO đạt tốc độ hội tụ nhanh nhất. Đối với hầu hết các hàm đa cực, HDBO thể hiện hiệu năng tốt nhất. Với những phân tích từ các nghiên cứu trên, bài toán điều hướng cho robot di động hoạt động trong nhà kính diện

tích lớn khoảng hàng chục nghìn mét vuông trở lên chưa được các tác giả nghiên cứu đến. Đặc biệt các nghiên cứu chưa gắn bài toán điều hướng cho robot di động với nhiệm vụ giám sát môi trường và sự phát triển của cây trồng trong nhà kính đó.

Từ những phân tích về tình hình nghiên cứu trong và ngoài nước trên, có nhiều nghiên cứu quan tâm đến hoạt động của robot di động trong nhà kính thực hiện các nhiệm vụ khác nhau. Tuy nhiên, các nghiên cứu vẫn chưa đề cập nhiều đến robot hoạt động trong nhà kính có diện tích canh tác lớn vài hecta trở lên. Trong khi đó, yêu cầu về giám sát môi trường và sự phát triển của cây trồng trong nhà kính này thường phức tạp hơn. Vì vậy, việc nghiên cứu giải pháp điều hướng cho robot di động giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp, cụ thể trong nhà kính nông nghiệp có diện tích canh tác lớn là hết sức cần thiết. Hướng nghiên cứu này giúp nâng cao hiệu quả giám sát, tiết kiệm năng lượng và tăng năng suất cây trồng.

Từ những phân tích trên có thể nhận thấy, để đáp ứng yêu cầu giám sát môi trường và theo dõi sự phát triển của cây trồng trong các nhà kính nông nghiệp có quy mô lớn, robot di động cần được nghiên cứu cụ thể về đặc điểm hoạt động, cấu trúc hệ thống và chức năng giám sát của robot di động trong môi trường nhà kính nông nghiệp thông minh.


1.3 Robot di động giám sát môi trường và sự phát triển của cây trồng trong nhà kính nông nghiệp thông minh

Nhà kính nông nghiệp thông minh là môi trường được kiểm soát khá cao (về ánh sáng, nhiệt độ, độ ẩm, CO₂...), nhưng đồng thời có độ phức tạp về cấu trúc, mật độ cây, và yêu cầu cao về quản lý môi trường vi khí hậu. **Tuy nhiên, nhà kính nông nghiệp tạo ra nhiều điều kiện thuận lợi robot di động thực hiện giám sát môi trường và sự phát triển của cây trồng. Trước hết, không gian trong** nhà kính thường có cấu trúc rõ ràng với các luống trồng và lối đi được bố trí cố định, giúp môi trường dễ dàng được mô hình hóa và xây dựng bản đồ phục vụ cho các thuật toán điều hướng. Bên cạnh đó, nhà kính là môi trường khép kín, ít chịu tác động của các yếu tố thời tiết khắc nghiệt như mưa, gió hay bùn lầy, từ đó tạo điều kiện cho robot di chuyển ổn định và an toàn trong thời gian dài. Ngoài ra, việc triển khai các hệ thống cảm biến và camera cố định trong nhà kính tương đối thuận lợi, cho phép robot di động kết hợp hiệu quả giữa điều hướng và thu thập dữ liệu giám sát môi trường cũng như hình ảnh cây trồng. Điều kiện chiếu sáng và thời gian hoạt động trong nhà kính cũng có thể được kiểm soát tốt hơn so với môi trường ngoài trời, góp phần nâng cao độ ổn định của nhận thức thị giác và hiệu quả giám sát sự phát triển của cây trồng.

Ngoài ra, cây trồng trong nhà kính nông nghiệp mang các đặc điểm sinh trưởng nhanh, bố trí mật độ cao, hình thái biến đổi theo thời gian và yêu cầu bảo vệ nghiêm ngặt. Những đặc điểm này ảnh hưởng đến bài toán thiết kế và giải pháp điều hướng robot di động phục vụ giám sát môi trường và sự phát triển của cây trồng. Khi đó,

các điểm dừng, tốc độ di chuyển và quỹ đạo robot phải phù hợp với yêu cầu quan sát sinh trưởng (chiều cao cây, lá, hoa, quả). Đường đi không tối ưu chỉ theo tiêu chí ngắn nhất, mà còn theo mức độ bao phủ thông tin giám sát.

Các yếu tố chính cần giám sát trong nhà kính thể hiện trên Hình 1.9.



Hình 1.9 Các yếu tố cần giám sát và điều khiển trong nhà kính ảnh hưởng đến sự phát triển của cây trồng

Hình 1.10 minh họa mô hình nhà kính diện tích lớn được trang bị robot di động và các cảm biến môi trường, cảm biến hình ảnh đặt trong mạng cảm biến không dây phục vụ công tác giám sát điều kiện vi khí hậu và quá trình sinh trưởng của cây trồng.



Hình 1.10 Mô hình nhà kính nông nghiệp diện tích vài hecta trồng cây cà chua


*** Mạng cảm biến không dây**

Một nhà kính hiện đại có thể bao gồm quạt thông gió, hệ thống phun sương hoặc tấm làm mát cellulose. Ngoài ra, có thể lắp đặt hệ thống chiếu sáng nhân tạo.

Phần lớn năng lượng trong nhà kính được tiêu thụ cho các hệ thống sưởi ấm và thông gió. Mạng cảm biến không dây (WSNs) có thể hỗ trợ trong việc điều khiển các thiết bị này và cung cấp một môi trường tối ưu cho cây trồng [39].

Trước đây, việc giám sát và quản lý nhà kính chủ yếu theo phương pháp truyền thống: việc theo dõi các yếu tố môi trường (như nhiệt độ, độ ẩm, ánh sáng, nồng độ CO₂, độ ẩm đất...) chủ yếu được thực hiện thủ công. Người vận hành thường phải trực tiếp đến từng khu vực trong nhà kính để đo đạc bằng các thiết bị đơn lẻ như nhiệt kế, ẩm kế, máy đo độ pH hay cảm biến cầm tay. Dữ liệu thu được thường được ghi chép và tổng hợp thủ công, sau đó mới được dùng để đưa ra các quyết định điều chỉnh hệ thống tưới, thông gió hoặc chiếu sáng. Nhưng trong các nhà kính nông nghiệp thông minh, mạng cảm biến không dây đã thay thế phương pháp truyền thống, đặc biệt ở khả năng thu thập dữ liệu theo thời gian thực, tính linh hoạt trong triển khai và hiệu quả trong tối ưu hóa điều kiện canh tác.

Các nút cảm biến trong mạng cảm biến không dây bao gồm cảm biến đo các thông số trên, thiết bị xử lý dữ liệu và giao tiếp làm nhiệm vụ giám sát môi trường canh tác nhà kính (Hình 1.11).



Hình 1.11 Cấu trúc của một nút cảm biến [40]

Trong đó một nút cảm biến bao gồm 4 khối chính:

- + Khối cảm biến (Sensing Unit): Gồm các cảm biến (nhiệt độ, độ ẩm, ánh sáng, khí gas, pH, CO₂,...) và bộ chuyển đổi tương tự-số (ADC), có nhiệm vụ thu thập tín hiệu từ môi trường và chuyển đổi thành dữ liệu số.

- + Khối xử lý (Processing Unit): Gồm vi điều khiển hoặc vi xử lý nhỏ gọn (MCU/MPU), có nhiệm vụ: xử lý, lưu trữ tạm thời dữ liệu và chạy các thuật toán định tuyến, giao tiếp.

- + Khối truyền thông (Communication Unit): Gồm bộ thu/phát không dây có nhiệm vụ trao đổi dữ liệu với các nút khác hoặc gửi dữ liệu đến nút trung gian (gateway).

+ Khối năng lượng (Power Unit): sử dụng pin có nhiệm vụ cung cấp năng lượng cho toàn bộ nút.

*** *Hệ thống camera giám sát cây trồng***

Hệ thống camera giám sát cây trồng lắp cố định là các thiết bị được bố trí tại một số vị trí khu vực trồng trọt cần giám sát nhằm thu thập dữ liệu hình ảnh theo thời gian thực. Hệ thống này ít bị ảnh hưởng bởi thời tiết, có chi phí vận hành thấp và phù hợp với mô hình giám sát dài hạn [41]. Hệ thống bao gồm camera/cảm biến hình ảnh, bộ nhớ, bộ thu phát và bộ xử lý dữ liệu. Hệ thống thực hiện các nhiệm vụ như: theo dõi sinh trưởng cây trồng (chiều cao, số lá, màu sắc tán lá), phát hiện sâu bệnh hoặc tình trạng bất thường sớm, giám sát điều kiện môi trường như độ ẩm bề mặt đất hoặc độ phủ tán và hỗ trợ ra quyết định trong quản lý tưới tiêu, chiếu sáng và dinh dưỡng.

*** *Hệ thống robot di động***

Việc sử dụng robot di động trong nhà kính nhằm mục đích tự động hóa, tăng năng suất, giảm sức lao động, đồng thời cải thiện chất lượng sản phẩm. Robot di động thực hiện các nhiệm vụ khác nhau trong nhà kính được trình bày trong Bảng 1.1

Bảng 1.1 Mô tả nhiệm vụ của robot di động trong nhà kính nông nghiệp [42]

Nhiệm vụ	Mô tả chi tiết
Theo dõi và giám sát trạng thái cây trồng & môi trường	Robot có thể di chuyển theo tuyến trong nhà kính để thu thập dữ liệu về nhiệt độ, độ ẩm, ánh sáng, CO ₂ , pH đất, độ ẩm đất, sự phát triển của cây, dấu hiệu sâu bệnh hoặc stress môi trường.
Quản lý vi khí hậu	Tự động điều chỉnh các thiết bị hỗ trợ như hệ thống sưởi, làm mát, thông gió, tưới nước hoặc che nắng để duy trì điều kiện tối ưu cho sự sinh trưởng của cây. Đây là nhiệm vụ quan trọng vì vi khí hậu không đồng đều trong nhà kính có thể ảnh hưởng lớn tới năng suất và chất lượng.
Tưới tiêu và dinh dưỡng	Dựa vào dữ liệu đo đạc thực tế, robot có thể hỗ trợ điều khiển hệ thống tưới nước, phân bón (nếu có tích hợp), hoặc đưa ra cảnh báo khi cần bổ sung dinh dưỡng. Điều này giúp sử dụng nước và phân bón hiệu quả hơn, giảm lãng phí.
Phát hiện sâu bệnh, cỏ dại, hoặc các yếu tố bất thường	Sử dụng máy ảnh, thị giác máy tính, cảm biến quang học để phát hiện dấu hiệu bất thường như sâu bệnh, cỏ dại, hoặc bệnh hại. Việc phát hiện sớm giúp can thiệp kịp thời.
Thu hoạch và phân loại	Trong một số ứng dụng, robot di động có thể thực hiện thu hoạch, cắt tỉa, hoặc phân loại sản phẩm ngay trong nhà kính. Mặc dù đây là nhiệm vụ phức tạp hơn do yêu cầu về thao tác tinh, nhận dạng hình ảnh, và tiếp cận cây trồng, nhưng các nghiên cứu đang tiến tới khả năng này.
Vận chuyển nội bộ	Robot có thể làm nhiệm vụ vận chuyển công cụ, sản phẩm đã thu hoạch, vật tư bên trong nhà kính, giảm công lao động và rủi ro vận chuyển.

Một trong những nhiệm vụ quan trọng của hệ thống robot di động hoạt động trong nhà kính thông minh trong sản xuất nông nghiệp là thu thập dữ liệu thông tin trong nhà kính bao gồm thông số môi trường canh tác (nhiệt độ, độ ẩm, ánh sáng, nồng độ khí CO₂...) và tình trạng sinh trưởng, phát triển của cây trồng trong nhà kính. Trong khi đó, thông số môi trường canh tác trong nhà kính như đã trình bày ở trên được thu thập từ mạng cảm biến không dây. Luận án tập trung nghiên cứu nhiệm vụ của robot di động là thu thập dữ liệu thông số môi trường nhà kính từ các nút cảm biến của mạng cảm biến không dây. Đối với việc giám sát sự phát triển của cây trồng thì hệ thống camera giám sát cây trồng sẽ cung cấp dữ liệu hình ảnh cây trồng nên luận án tập trung nghiên cứu nhiệm vụ robot di động thu thập và xử lý dữ liệu hình ảnh cây trồng trong nhà kính nông nghiệp.

1.3.1 Robot di động thu thập thông số môi trường canh tác nhà kính nông nghiệp

• Mô hình năng lượng tại nút cảm biến

Năng lượng tiêu thụ của nút cảm biến bao gồm năng lượng cho việc truyền dữ liệu, nhận dữ liệu và xử lý dữ liệu [43].

Năng lượng tiêu thụ của nút cảm biến cho việc truyền dữ liệu:

$$E_T(\gamma) = E_{elec} \cdot \gamma + E_{amp} \cdot d^\alpha \cdot \gamma \quad (1.1)$$

Năng lượng tiêu thụ của nút cảm biến cho việc nhận dữ liệu:

$$E_R(\gamma) = E_{elec} \cdot \gamma \quad (1.2)$$

Năng lượng tiêu thụ của nút cảm biến cho việc xử lý dữ liệu:

$$E_{cpu}(\gamma) = E_{cpu} \cdot \gamma \quad (1.3)$$

Trong đó: γ - độ dài gói tin (bits)

d - khoảng cách truyền tin (m)

E_{elec} – Năng lượng tiêu thụ để chạy mạch điện tử của bộ thu phát (nJ/bit)

E_{amp} - Năng lượng khuếch đại tín hiệu (nJ/bit/m²)

E_{cpu} - năng lượng xử lý dữ liệu (nJ/bit)

χ - Hệ số suy hao đường truyền

Năng lượng tiêu thụ tổng cho một nút cảm biến thứ k :

$$\begin{aligned} E_k(t) &= E_T(\gamma) + E_R(\gamma) + E_{cpu}(\gamma) \\ &= \gamma(2E_{elec} + E_{cpu} + E_{amp} \cdot d^\chi) \end{aligned} \quad (1.4)$$

Như vậy, năng lượng tiêu thụ của một nút cảm biến tỷ lệ thuận với kích thước gói tin γ và khoảng cách truyền. Nếu xét các nút cảm biến cùng truyền kích thước gói tin như nhau thì khoảng cách truyền càng xa thì năng lượng tiêu thụ càng lớn.

Giảm khoảng cách truyền giữa các nút cảm biến sẽ giảm năng lượng tiêu thụ của các nút cảm biến, từ đó tiết kiệm được năng lượng đáng kể tại các nút cảm biến đó.

Tuổi thọ của mạng cảm biến (LF_k) liên quan đến thời gian mà năng lượng dư của nút cảm biến (E_{re}) trong mạng nhỏ hơn ngưỡng (θ). Do đó, ta có:

$$E_{re}(t) = E_0 - \sum_{t=1}^{LF_k} E_k(t) \leq \theta, \{k = 1, \dots, N\} \quad (1.5)$$

Trong đó: E_0 – năng lượng ban đầu của nút cảm biến.

Mức năng lượng tiêu thụ càng cao thì năng lượng còn lại của nút cảm biến đó càng nhỏ. Như vậy, giảm khoảng cách truyền tin sẽ nâng cao được tuổi thọ của mạng.

• **Mạng cảm biến không dây với các nút cảm biến cố định và nút cảm biến di động**

Mạng cảm biến không dây là một trong những thành phần quan trọng trong các hệ thống nông nghiệp thông minh, đặc biệt trong giám sát môi trường canh tác và điều khiển tự động trong nhà kính. Cấu trúc của WSNs có thể chia thành hai loại chính: mạng cảm biến chỉ sử dụng các nút cảm biến cố định và mạng cảm biến có bổ sung các nút cảm biến di động (Mobile Sensor Nodes – MSNs) hoặc robot di động làm nhiệm vụ thu thập dữ liệu. Mỗi loại mạng có những ưu, nhược điểm riêng, ảnh

hưởng trực tiếp đến hiệu quả thu thập dữ liệu, độ tin cậy truyền tin và mức tiêu thụ năng lượng của toàn hệ thống.

- *Mạng cảm biến không dây với các nút cảm biến cố định*

Trong mô hình truyền thống, các nút cảm biến được bố trí cố định trong khu vực giám sát để thực hiện các nhiệm vụ thu thập, xử lý cục bộ và truyền dữ liệu về trạm gốc (sink node) thông qua các tuyến truyền đa bước. Mô hình này có ưu điểm là đơn giản trong thiết kế và vận hành, dữ liệu được cập nhật liên tục và theo thời gian thực, giúp phản ánh chính xác trạng thái môi trường canh tác. Tuy nhiên, khi các nút cảm biến của WSNs được lắp cố định một chỗ, hệ thống vẫn bộc lộ những hạn chế nhất định. Trước hết, bản thân các nút WSN là những thiết bị rất nhỏ gọn sử dụng pin nên năng lượng dự trữ có hạn, công suất xử lý và bộ nhớ cũng rất hạn chế. Năng lượng tiêu hao để nút cảm biến truyền dữ liệu về trạm chủ phụ thuộc vào khoảng cách truyền (1.1) nên với các nút cảm biến cố định tiêu hao năng lượng cho việc truyền dữ liệu càng lớn khi khoảng cách truyền càng xa. Do đó, tuổi thọ mạng cảm biến bị giới hạn bởi thời lượng pin của các nút cảm biến. Thứ hai, việc bố trí cố định các cảm biến dễ dẫn đến vùng phủ giám sát không đồng đều; để phản ánh đầy đủ sự thay đổi các yếu tố vi khí hậu trong nhà kính đòi hỏi phải lắp đặt mạng cảm biến với mật độ đủ dày đặc. Việc phải triển khai số lượng cảm biến lớn không chỉ làm tăng chi phí và độ phức tạp của hệ thống, mà còn có nguy cơ gây nghẽn mạng khi nhiều nút truyền dữ liệu đồng thời. Thêm vào đó, trong một số kiến trúc mạng WSN như mạng mesh, việc bổ sung hoặc thay đổi vị trí các nút sau khi triển khai không hề đơn giản, làm giảm tính linh hoạt khi cần tái cấu hình hệ thống cảm biến. Đặc biệt, do vị trí cố định, các nút cảm biến phải duy trì liên kết truyền thông liên tục, dẫn đến tiêu hao năng lượng lớn, đặc biệt đối với các nút trung gian tham gia chuyển tiếp dữ liệu nhiều lần. Ngoài ra, trong các nhà kính có diện tích lớn (vài hecta trở lên), độ bao phủ tín hiệu và tính tin cậy truyền tin dễ bị ảnh hưởng bởi vật cản hoặc điều kiện môi trường. Khi một số nút bị hỏng hoặc cạn năng lượng, mạng có thể mất kết nối cục bộ gây suy giảm chất lượng giám sát.

- *Mạng cảm biến không dây kết hợp các nút cảm biến cố định và di động*

Khắc phục các hạn chế trên, nhiều nghiên cứu gần đây đề xuất sử dụng các nút cảm biến di động hoặc robot di động làm nhiệm vụ thu thập dữ liệu thay cho truyền tin đa bước. Khi đó, robot di động thu thập dữ liệu tại các nút cảm biến với khoảng cách ngắn hơn so với các trạm trung tâm. Điều này dẫn đến giảm năng lượng tiêu hao của các nút cảm biến do khoảng cách truyền giảm. Trong mô hình này, các nút cảm biến cố định hoạt động chủ yếu ở chế độ ngủ tiết kiệm năng lượng và chỉ truyền dữ liệu khi robot di động đi qua và yêu cầu truy xuất. Cách tiếp cận này giúp giảm đáng kể tiêu hao năng lượng tại các nút cảm biến cố định, kéo dài tuổi thọ mạng, đồng thời đảm bảo thu thập dữ liệu đầy đủ mà không cần duy trì kết nối liên tục. Ngoài ra, robot

đi động có thể kết hợp nhiều chức năng như thu thập dữ liệu, kiểm tra trực quan, giám sát hình ảnh, giúp tăng độ chính xác và hiệu quả của hệ thống. Tuy nhiên, mô hình này đòi hỏi phải có thuật toán điều hướng tối ưu để đảm bảo robot di chuyển đến đúng vị trí các cụm cảm biến trong thời gian giới hạn, đồng thời tránh lãng phí năng lượng và đảm bảo tính kịp thời của dữ liệu.


Luận án tập trung giải quyết bài toán sử dụng robot di động thu thập dữ liệu từ các nút cảm biến đầu cụm để rút ngắn khoảng cách thu thập truyền tín hiệu, từ đó tiết kiệm năng lượng cho các nút cảm biến.

Để giải quyết bài toán trên, robot di động di chuyển đến các một số nút cảm biến, thu thập dữ liệu thông tin môi trường canh tác nhà kính. Rồi sau đó, robot di chuyển về trung tâm điều khiển, gửi dữ liệu thu thập được về trung tâm điều khiển xử lý và đưa ra quyết định điều khiển giám sát.

Tại một số nút cảm biến hoặc khu vực gần nút cảm biến có đặt cảm biến hình ảnh hoặc hệ thống camera để thu hình ảnh cây trồng phục vụ cho việc giám sát sự phát triển của cây trồng. Khi robot di chuyển đến nút cảm biến để thu thập dữ liệu thông số môi trường nếu tại nút đó có cảm biến hình ảnh cung cấp dữ liệu về hình ảnh cây trồng thì robot sẽ đồng thời thu thập bộ dữ liệu này và gửi về trung tâm điều khiển để xử lý và đưa ra quyết định.

1.3.2 Robot di động thu thập, xử lý dữ liệu và nhận diện hình ảnh cây trồng

Để có thông tin, dữ liệu cho hệ thống điều khiển giám sát cây trồng ngoài có thông số môi trường như nhiệt độ, độ ẩm, ánh sáng,... thì cần có cả dữ liệu về hình ảnh cây trồng (Hình 1.12). Các loại cảm biến khác nhau được đưa vào trong mạng cảm biến không dây như: cảm biến đo nhiệt độ, cảm biến đo độ ẩm, cảm biến đo cường độ ánh sáng và cảm biến hình ảnh sẽ cung cấp bộ dữ liệu cho hệ thống. Mặc dù các thông số môi trường như nhiệt độ, độ ẩm không khí, độ ẩm đất, cường độ ánh sáng hay nồng độ CO₂ đóng vai trò quan trọng trong việc điều chỉnh quá trình sinh lý của cây trồng, các dữ liệu này chỉ phản ánh điều kiện ngoại cảnh, chứ không thể phản ánh đầy đủ đáp ứng sinh lý và biểu hiện hình thái của cây trước các điều kiện đó. Để giám sát sự phát triển của cây trồng phụ thuộc không chỉ vào môi trường mà còn vào biểu hiện trực tiếp của cây hay thông qua hình ảnh cây trồng, bao gồm cấu trúc lá, màu sắc, kết cấu bề mặt và các triệu chứng bệnh lý [44],[45].



Hình 1.12 Sơ đồ hệ thống điều khiển giám sát sự phát triển của cây trồng [46]


Hình ảnh cây trồng có thể được thu thập thông qua các phương thức khác nhau như: từ các cảm biến hình ảnh trong hệ thống camera giám sát cây trồng đặt cố định ở một số vị trí trong khu vực cần giám sát, gắn camera trực tiếp trên hệ thống di động hoặc phương thức thủ công là do con người trực tiếp đi chụp ảnh cây trồng. Mỗi một phương thức có ưu nhược điểm khác nhau, tuy nhiên việc đặt hệ thống camera cố định ở một số vị trí cần giám sát phù hợp với phạm vi giám sát rộng và yêu cầu giám sát liên tục hình thái cây trồng. Hệ thống camera này được đặt tại hoặc gần các nút cảm biến trong mạng cảm biến không dây và sử dụng phương thức truyền thông không dây của mạng. Tuy nhiên, khối lượng dữ liệu hình ảnh rất lớn, cùng với yêu cầu thu thập định kỳ, đầy đủ và đồng bộ. Việc truyền trực tiếp toàn bộ dữ liệu hình ảnh qua mạng không dây sẽ gây tắc nghẽn băng thông, tăng tiêu thụ năng lượng và giảm tuổi thọ mạng cảm biến.

Như đã trình bày ở mục 1.2.1, robot di động được điều khiển đến các nút cảm biến trong mạng cảm biến không dây thu thập dữ liệu tại các nút đó. Như vậy, tại một số nút hoặc khu vực gần nút cảm biến đó nếu có cảm biến hình ảnh trong hệ thống camera đặt tại đó thì sẽ cung cấp bộ dữ liệu hình ảnh cây trồng cho robot di động. Khi đó, robot di động nhận bộ dữ liệu này và chuyển về trung tâm điều khiển (Hình 1.13).

Hệ thống camera giám sát cây trồng thường sử dụng một số loại như:

(1) Camera RGB cung cấp ảnh hình ảnh cây trồng có thể được phân tích để phát hiện sự thay đổi về chiều cao cây, quá trình sinh trưởng và cung cấp thông tin về đặc điểm, màu sắc và những dấu hiệu triệu chứng về thiếu hụt dinh dưỡng hoặc sâu bệnh trên cây trồng. (2) Camera siêu phổ (hyperspectral) có khả năng xác định các bước sóng

ánh sáng phản xạ từ cây, từ đó nhận diện các loài thực vật khác nhau [47]. (3) Camera nhiệt có thể phát hiện bức xạ nhiệt từ cây để đánh giá tình trạng sức khỏe của chúng [48].




Hình 1.13 Robot di động thu thập dữ liệu hình ảnh cây trồng từ camera cố định

Dữ liệu hình ảnh cây trồng được thu thập bởi các camera cố định đặt trong nhà kính, nhà lưới hoặc các khu vực canh tác yêu cầu theo dõi liên tục. Các hình ảnh này sau đó được truyền theo phương thức truyền tin không dây tới robot di động làm nhiệm vụ thu thập dữ liệu và chuyển về trung tâm điều khiển để phân tích. Tuy nhiên, trong điều kiện thực tế, chất lượng ảnh thường bị suy giảm do nhiều yếu tố như điều kiện ánh sáng thay đổi, bụi, độ ẩm, nhiễu do tín hiệu truyền không dây hoặc rung lắc của camera. Do vậy, khử nhiễu ảnh là bước tiền xử lý quan trọng giúp đảm bảo độ tin cậy của các thuật toán phân tích thị giác máy tính phía sau (ví dụ: phân đoạn lá, phát hiện sâu bệnh, ước lượng sinh trưởng). Chất lượng ảnh đầu vào càng cao thì hiệu suất của toàn bộ hệ thống điều khiển giám sát cây trồng trong nông nghiệp càng ổn định.

Khử nhiễu ảnh giúp nâng cao độ chính xác của các thuật toán thị giác máy tính với sự biến dạng tín hiệu. Nhiễu không chỉ làm suy giảm các chi tiết quan trọng như đường biên, cấu trúc lá và chỉ số màu mà còn gây sai lệch đặc trưng đầu vào, dẫn đến suy giảm hiệu suất phân đoạn, nhận dạng và đánh giá tình trạng sinh trưởng, phát triển và phát hiện sâu bệnh của cây trồng. Bên cạnh đó, khử nhiễu ảnh còn góp phần tối ưu hoá quá trình truyền thông không dây giữa các nút camera và robot di động. Khi ảnh bị nhiễu, nhiều hệ thống buộc phải nén mạnh để đáp ứng giới hạn băng thông,

làm giảm chất lượng hình ảnh suy giảm thêm trong quá trình giải nén. Việc giảm nhiễu ngay từ phía thu nhận làm giảm yêu cầu nén và cải thiện tỉ lệ lỗi tín hiệu trong truyền dẫn. Ngoài ra, trong các ứng dụng điều khiển và giám sát thời gian thực như phát hiện sâu bệnh, nhận biết tình trạng thiếu nước hoặc theo dõi biến động môi trường, hình ảnh sạch giúp hệ thống ra quyết định linh hoạt và ổn định hơn, giảm hiện tượng cảnh báo sai và tránh các tác động điều khiển không cần thiết. Nói cách khác, khử nhiễu ảnh không chỉ cải thiện chất lượng dữ liệu mà còn ảnh hưởng trực tiếp đến hiệu quả vận hành của toàn bộ hệ thống điều khiển tự động trong nông nghiệp, từ tác vụ đánh giá đến quá trình điều khiển tác động.

Với sự phát triển mạnh mẽ của trí tuệ nhân tạo (Artificial Intelligence - AI), việc giám sát sự phát triển của cây trồng nông nghiệp, đặc biệt trong nhận diện hình ảnh cây trồng để phát hiện sâu bệnh đã trở thành hướng nghiên cứu chủ đạo trong nông nghiệp chính xác. Hai nhóm kỹ thuật AI chính thường được sử dụng là học máy (Machine Learning - ML) và học sâu (Deep Learning - DL). Trong ML, các thuật toán như K-Nearest Neighbors (KNN), Decision Tree (DT), Random Forest (RF), Support Vector Machine (SVM) hay Naive Bayes thường được sử dụng để phân loại các loại bệnh dựa trên các đặc trưng được trích xuất thủ công từ ảnh. Trong khi đó, DL sử dụng các mạng nơ-ron sâu, đặc biệt là mạng nơ-ron tích chập (Convolutional Neural Network – CNN), để học trực tiếp từ dữ liệu đầu vào, từ đó tự động xác định và phân biệt các triệu chứng bệnh trên lá cây với độ chính xác cao. Các kiến trúc học sâu như AlexNet, VGGNet, ResNet, DenseNet, MobileNet, EfficientNet, Xception và YOLO đã được áp dụng thành công trong nhiều nghiên cứu, với độ chính xác phân loại đạt từ 90% đến 99% tùy thuộc vào chất lượng và kích thước tập dữ liệu. Việc sử dụng mô hình tiền huấn luyện kết hợp với học chuyển tiếp cũng giúp tiết kiệm thời gian huấn luyện và cải thiện hiệu suất trên các tập dữ liệu giới hạn [49], [50].



Hình 1.14 Sơ đồ quy trình triển khai sử dụng học sâu để phân loại và phát hiện sâu bệnh cây trồng [51]

Hình 1.14 biểu diễn quy trình ứng dụng học sâu để phân loại và phát hiện sâu bệnh trên cây trồng. Đầu tiên, tập dữ liệu được thu thập sau đó được chia thành hai phần, thường là 80% tập huấn luyện và 20% tập xác thực. Sau đó, các mô hình DL được huấn luyện từ đầu hoặc bằng kỹ thuật học chuyển giao, và các biểu đồ huấn luyện/xác thực của chúng được thu thập để chỉ ra ý nghĩa của các mô hình. Tiếp theo, các số liệu hiệu suất được sử dụng để phân loại hình ảnh (loại bệnh cây cụ thể), và cuối cùng, các kỹ thuật trực quan hóa/ánh xạ được sử dụng để phát hiện/định vị/phân loại hình ảnh [51].

Mạng nơ-ron tích chập đã và đang được ứng dụng rộng rãi trong lĩnh vực nông nghiệp, đặc biệt là trong nhiệm vụ chẩn đoán bệnh trên cây trồng. Đây là quá trình phát hiện và phân loại các biểu hiện bất thường do tác nhân gây bệnh, thông qua việc phân tích hình ảnh lá, thân hoặc quả của cây. Các loại bệnh nếu không được phát hiện và xử lý kịp thời sẽ ảnh hưởng nghiêm trọng đến sức khỏe cây trồng, làm suy giảm sản lượng và chất lượng nông sản, đồng thời tạo điều kiện cho dịch bệnh lây lan nhanh chóng trên diện rộng, gây tổn thất kinh tế và ảnh hưởng đến an toàn thực phẩm. Ứng dụng CNN trong nhận dạng sâu bệnh cây trồng cho phép tự động trích xuất và học các đặc trưng hình ảnh liên quan đến triệu chứng bệnh, giúp nâng cao độ chính xác trong phát hiện bệnh cũng như rút ngắn thời gian chẩn đoán. Nhờ đó, các biện pháp xử lý có thể được triển khai sớm và có mục tiêu, góp phần tối ưu hóa quy trình quản lý dịch hại và bảo vệ mùa màng một cách hiệu quả [52-54].

Trong kiến trúc của CNN, lớp tích chập (convolutional layer) là các bộ lọc hoặc hạt nhân cho tính toán tích chập được sử dụng để tạo ra các lớp tích chập. Các bộ lọc này chia toàn bộ hình ảnh thành ba hoặc năm lưới nhỏ, sau đó tích chập các lưới nhỏ này bằng hạt nhân hoặc bộ lọc để tạo ra bản đồ đặc điểm. Lớp tích chập là lớp quan trọng nhất vì nó chiếm phần lớn thời gian của mạng, trích xuất dữ liệu không gian cục bộ và thực hiện phần lớn các tác vụ tính toán chuyên sâu. Lớp gộp (pooling layer) được chèn vào sau lớp kích hoạt ReLU và trước lớp tích chập tiếp theo nhằm nâng cao khả năng trích xuất đặc trưng của mạng nơ-ron tích chập. Việc bổ sung lớp gộp giúp tăng cường tính bất biến tịnh tiến, nghĩa là mạng vẫn nhận diện được các đặc trưng quan trọng ngay cả khi chúng bị dịch chuyển nhỏ trong không gian ảnh. Cơ chế này hoạt động thông qua việc giảm độ phân giải không gian của bản đồ đặc trưng, làm mờ đi các thay đổi cục bộ không quan trọng nhưng vẫn giữ lại thông tin cốt lõi. Ngoài ra, lớp gộp còn góp phần hạn chế hiện tượng quá khớp (overfitting) bằng cách giảm số lượng tham số và mức độ phức tạp của mô hình, từ đó cải thiện khả năng tổng quát hóa trên các tập dữ liệu mới. Nhờ những ưu điểm này, lớp gộp đóng vai trò quan trọng trong việc ổn định hoạt động của mạng và tăng độ tin cậy của các đặc trưng được trích xuất trong bài toán xử lý ảnh. Lớp kết nối đầy đủ chịu trách nhiệm thực hiện toàn bộ quy trình bằng cách lấy dữ liệu đầu vào từ tất cả các lớp trích xuất đặc điểm và thực hiện phân tích toàn cầu về đầu ra từ tất cả các lớp trước đó. Nó được kết nối đầy đủ với tất cả các hoạt động của các lớp trước đó.

Các hàm kích hoạt giúp mạng nơ-ron đưa ra quyết định và học các khía cạnh phức tạp từ hình ảnh đầu vào. Khi học các mẫu phức tạp từ dữ liệu đầu vào thô, việc sử dụng đúng hàm kích hoạt có thể tăng tốc quá trình đào tạo. Mạng nơ-ron tích chập được đào tạo trên một tập dữ liệu lớn và đa dạng.

Các mô hình học sâu phát triển trọng số và độ lệch của mô hình trong khi được đào tạo với khối lượng dữ liệu lớn, sau đó các mô hình mạng thay thế được kiểm tra bằng các trọng số này. Các mô hình được đào tạo trước được sử dụng vì việc học một mạng từ đầu có thể mất nhiều tuần và đòi hỏi nhiều sức mạnh xử lý hơn khi đào tạo các mô hình lớn trên các tập dữ liệu lớn. Sử dụng các trọng số đã được đào tạo để đào tạo mạng mới giúp tăng tốc quá trình học.

Hai phương pháp phổ biến nhất bao gồm sử dụng các mô hình đã trải qua quá trình đào tạo trước và tinh chỉnh sâu rộng. Các mô hình này có thể được áp dụng trực tiếp hoặc thông qua học chuyển giao và chúng có thể được sửa đổi khi cần thiết, mô hình có thể được đào tạo trước bằng các tập dữ liệu có sẵn công khai và các thiết lập trình trích xuất tính năng có thể được sử dụng lại. Trong những năm gần đây đã chứng kiến những tiến bộ đáng kể trong kiến trúc mạng sâu với nhiều mô hình được đào tạo trước đã có trong các thư viện, Keras và TensorFlow. Có nhiều kiến trúc được đào

tạo trước có sẵn, chẳng hạn như VGG16, VGG1, GoogleNe, ResNet50, InceptionV3, MobileNet và Xception. Kiến trúc mạng tích chập được sử dụng bởi các mạng VGG và AlexNet là kiến trúc thông thường. MobileNet là kiến trúc Xception đã được đơn giản hóa và được thiết kế riêng cho các ứng dụng di động. Các kiến trúc EfficientNet, ResNet, Inception, Xception và RegNet, do khả năng thích ứng của chúng, đã trở thành điểm tham chiếu cho các nghiên cứu trong tương lai về thị giác máy tính.

Trong việc ứng dụng mô hình CNN để nhận diện đối tượng trong thời gian thực phải kể đến đó là mô hình YOLO (You Only Look Once). Việc ứng dụng mô hình YOLO trong nhận diện hình ảnh cây trồng mang lại nhiều ưu điểm vượt trội, đặc biệt trong các hệ thống giám sát sự phát triển của cây trồng và phát hiện sớm sâu bệnh. YOLO hoạt động dựa trên cơ chế suy luận một lần, cho phép thực hiện phát hiện đối tượng theo thời gian thực với tốc độ rất cao mà vẫn duy trì độ chính xác ổn định. Đối với môi trường nông nghiệp, nơi dữ liệu hình ảnh được thu thập liên tục từ camera cố định hoặc camera gắn trên robot di động, đặc tính xử lý nhanh của YOLO giúp hệ thống kịp thời nhận diện các dấu hiệu bất thường như đốm lá, vết bệnh, sự xuất hiện của côn trùng gây hại hoặc biến dạng cấu trúc lá. Bên cạnh đó, YOLO có khả năng phát hiện đa đối tượng trong một khung hình, rất phù hợp với hình ảnh cây trồng có cấu trúc phức tạp, nhiều lá chồng lên nhau và bối cảnh đa dạng. Kiến trúc dựa trên mạng tích chập sâu cho phép mô hình học được các đặc trưng hình thái phức tạp của cây, từ đó cải thiện hiệu quả phân loại và định vị. Ngoài ra, việc tối ưu hóa số lượng tham số và cơ chế gán nhãn anchor linh hoạt giúp YOLO có khả năng triển khai trên các thiết bị biên như robot nông nghiệp hoặc các hệ thống xử lý cục bộ trong nhà kính, từ đó giảm thời gian truyền dữ liệu và tăng tính tự chủ cho hệ thống giám sát. Nhờ những ưu điểm này, YOLO trở thành lựa chọn phù hợp cho các bài toán theo dõi sinh trưởng và phát hiện sâu bệnh, góp phần nâng cao độ tin cậy, độ chính xác và hiệu quả của hệ thống điều khiển và giám sát nông nghiệp thông minh.


Từ những phân tích trên có thể thấy, việc kết hợp robot di động thu thập dữ liệu hình ảnh cây trồng từ các camera cố định với phương pháp tiền xử lý dữ liệu sau đo và mô hình AI để giám sát sự phát triển của cây trồng nông nghiệp là xu hướng tất yếu trong giám sát nông nghiệp thông minh. Hướng nghiên cứu này không chỉ giúp nâng cao chất lượng giám sát cây trồng, phát hiện sớm các vấn đề sâu bệnh, mà còn góp phần tối ưu chi phí vận hành, nâng cao độ chính xác và tự động hóa trong quản lý nhà kính nông nghiệp.

Robot di động tham gia giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp có hiệu quả hay không nhờ vào sự di chuyển của robot di động trong môi trường giám sát có hợp lý hay không. Một trong những giải pháp giúp robot

di chuyển hợp lý là tìm giải pháp điều hướng phù hợp cho robot di động hoạt động trong môi trường giám sát đó.

1.3.3 Quá trình điều hướng cho robot di động hoạt động trong môi trường nông nghiệp

Trong luận án này, NCS lựa chọn hệ thống robot di động bốn bánh đa hướng như mô tả ở Hình 1.15. Đây là một robot bốn bánh đa hướng thường có khung gầm hình chữ nhật với bốn bánh xe đặc biệt gắn ở bốn góc, cho phép robot di chuyển tự do theo mọi hướng trên mặt phẳng. Các bánh xe này gọi là bánh xe đa hướng (omni-wheel hoặc Mecanum), mỗi bánh có nhiều con lăn nhỏ gắn quanh vành, đặt nghiêng một góc nhất định (thường 90° đối với omni-wheel hoặc 45° đối với bánh Mecanum) so với trục bánh [55]. Thiết kế này cho phép bánh lăn theo phương vuông góc với hướng quay chính: bánh xe tạo lực kéo theo phương dọc trục động cơ, đồng thời các con lăn cho phép trượt ngang một cách hầu như không ma sát. Bằng cách gắn bốn bánh đa hướng ở bốn góc để, robot di động này thuộc loại robot holonomic, có thể chuyển động thẳng theo bất kỳ hướng nào và quay quanh trục đứng mà không cần đổi hướng bánh xe. Robot di động bốn bánh đa hướng này phù hợp với nhiệm vụ robot giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp. Robot được đặt trong một hệ quy chiếu quán tính Oxy đặt tại một vị trí cố định trong không gian hoạt động của robot.



Hình 1.15 Mô hình robot di động bốn bánh đa hướng [56]

Nếu đặt 1 hệ trục tọa độ $X_M P Y_M$ lên thân Robot với P gắn tại tâm của robot di động ta được vec tơ vận tốc của bánh xe robot như sau:

$$\mathbf{V}_\psi = [\dot{x}_M \quad \dot{y}_M \quad \dot{\phi}] = \mathbf{H}(\phi) \dot{\boldsymbol{\eta}} \quad (1.6)$$

Trong đó:

$$\mathbf{H}(\phi) = \begin{bmatrix} \cos\phi & \sin\phi & 0 \\ -\sin\phi & \cos\phi & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (1.7)$$

$\dot{\boldsymbol{\eta}} = [\dot{x} \quad \dot{y} \quad \dot{\phi}]$ là vec tơ vận tốc của robot gắn với hệ quy chiếu quán tính XOY

ψ - là góc quay của bánh xe quanh trục chính

ϕ - là góc hướng của robot

Giả sử mô hình robot di động đang xét được thiết kế với các bánh xe có cùng kích thước $r_i = r$ (bán kính của bánh xe robot) và khoảng cách giữa các bánh xe $i = 1, 2, 3, 4$ đến trọng tâm P của robot là đối xứng nhau với chiều dài $l_i = l$.

Phương trình động học của Robot di động bốn bánh đa hướng đang xét có dạng như sau [50]:

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\phi} \end{bmatrix} = \frac{1}{2} r \mathbf{J}^+ \begin{bmatrix} \dot{\psi}_1 \\ \dot{\psi}_2 \\ \dot{\psi}_3 \\ \dot{\psi}_4 \end{bmatrix} \quad (1.8)$$


Trong đó:

Ma trận Jacobian được xác định theo công thức

$$\mathbf{J} = \begin{bmatrix} -1 & -1 & -\sqrt{2}l \sin\left(\frac{\pi}{4} - \alpha\right) \\ -1 & 1 & -\sqrt{2}l \sin\left(\frac{\pi}{4} - \alpha\right) \\ 1 & 1 & -\sqrt{2}l \sin\left(\frac{\pi}{4} - \alpha\right) \\ 1 & -1 & -\sqrt{2}l \sin\left(\frac{\pi}{4} - \alpha\right) \end{bmatrix} \begin{bmatrix} \cos\phi & \sin\phi & 0 \\ -\sin\phi & \cos\phi & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (1.9)$$

$\mathbf{J}^+ = (\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T$ là ma trận giả nghịch đảo của $\mathbf{J}$


Robot di động bốn bánh đa hướng thực hiện giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp là một nền tảng tự hành có cấu trúc khung chắc chắn gắn bốn bánh xe đa hướng ở bốn góc, cho phép robot di chuyển theo mọi hướng mà không cần quay đầu thân robot [57]. Bánh xe đa hướng này mang lại tính linh hoạt cao, giúp robot dễ dàng di chuyển dọc các luống cây hẹp và tiến lùi hoặc di chuyển ngang để tiếp cận mọi khu vực trong môi trường nông nghiệp, nơi đặt các nút cảm biến để robot di chuyển đến thu thập dữ liệu. Trên khung robot được bố trí nhiều tầng để lắp đặt phần cứng, bao gồm bộ điều khiển trung tâm, nguồn điện (pin) và hệ thống thu nhận dữ liệu (Hình 1.16).



Hình 1.16 Phần cứng mô hình robot di động bốn bánh đa hướng


Để robot di động thực hiện nhiệm vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp cần điều hướng cho robot di động có thể di chuyển an toàn trong khi thực hiện nhiệm vụ. Quá trình điều hướng cho robot di động gồm: Giai đoạn bản đồ hóa môi trường, định vị vị trí của robot (SLAM) và giai đoạn lập kế hoạch đường đi.

Quá trình SLAM thể hiện trên hình 1.17:




Hình 1.17 Cấu trúc hệ thống SLAM cho robot di động

Khi mô phỏng mô hình robot di động được đề cập ở trên sẽ thu được kết quả quá trình SLAM như sau (Hình 1.18):




Hình 1.18 Quá trình SLAM của robot và kết quả bản đồ hoá môi trường

Khi robot đã có thông tin về môi trường và vị trí của nó từ hệ thống SLAM, các vị trí đích có thể được đặt nhưng chỉ trong vùng môi trường đã xác định. Để robot có thể di chuyển tự động và an toàn (tránh các vật cản tĩnh, động của môi trường thực tế) trong suốt quá trình di chuyển đồng thời phải bám sát quỹ đạo từ vị trí ban đầu đến vị trí mong muốn thì cần xây dựng hệ thống điều hướng cho robot bao gồm 2 phần chính là lập quỹ đạo toàn cục (Global planner) và lập quỹ đạo cục bộ (Local planner) (Hình 1.19).



Hình 1.19 Cấu trúc hệ thống điều hướng cho robot di động

Tiến hành mô phỏng mô hình robot di động để xây dựng quỹ đạo toàn cục dựa trên thuật toán A* [58] và quỹ đạo cục bộ dựa theo thuật toán TEB [59] được kết quả như trong hình 1.20:



Hình 1.20 Kết quả điều hướng robot di động dựa trên thuật toán A* và TEB

1.4 Kết luận chương 1

Chương 1 đã trình bày tổng quan về công trình nghiên cứu trong và ngoài nước liên quan đến hoạt động của robot di động phục vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp, tập trung vào môi trường nhà kính nông nghiệp và ứng dụng trí tuệ nhân tạo để giám sát sự phát triển và sâu bệnh của cây trồng.

Từ việc phân tích các nghiên cứu đó, NCS đã đưa ra nhiệm vụ của luận án và các nội dung của từng nhiệm vụ này sẽ được trình bày ở các chương tiếp theo của luận án. Luận án sẽ tập trung nghiên cứu và điều hướng cho robot di động thực hiện nhiệm vụ thu thập dữ liệu môi trường canh tác và hình ảnh cây trồng từ các nút cảm biến đầu cụm của mạng cảm biến không dây phục vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp, được trình bày ở chương 2. Tiếp đó, luận án giải quyết bài toán thứ hai là giám sát sự phát triển của cây trồng trong nhà kính nông nghiệp, ưu tiên phát hiện sâu bệnh cây trồng trên cơ sở trí tuệ nhân tạo, được trình bày ở chương 3.

Các đóng góp của chương 1 được công bố ở công trình sau:

[CT1] **N. T. Duyên**, N.M.Tiến, Đ.Q.Hiệp, Đ.M. Đông, “*Xây dựng hệ định vị, bản đồ hóa cho robot tự hành trong nhà kính nông nghiệp dựa trên hệ điều hành lập trình cho robot*”. Tạp chí KH&CN quân sự, Số Đặc san Hội thảo Quốc gia FEE, 10/2021, tr.168-175

[CT2] **N. T. Duyên**, N.M.Tiến, Đ.Q.Hiệp, Đ.M. Đông, B.V.Tuấn, “*Xây dựng hệ điều hướng trên bản đồ, định vị SLAM cho Robot tự hành trong nhà kính nông nghiệp dựa trên hệ điều hành ROS*” Proceedings the 6th Vietnam International Conference and Exhibition on Control and Automation VCCA-2021, ISBN 978-604-73-5569-3.


Chương 2. GIẢI PHÁP ĐIỀU HƯỚNG CHO ROBOT DI ĐỘNG THU THẬP DỮ LIỆU GIÁM SÁT TRONG NÔNG NGHIỆP

Như đã trình bày ở chương 1, robot di động có nhiệm vụ thu thập dữ liệu môi trường canh tác nhà kính từ mạng cảm biến không dây là rất cần thiết cho việc giám sát môi trường và cây trồng trong nông nghiệp. Hiệu quả của việc thu thập dữ liệu từ mạng cảm biến không dây phụ thuộc vào việc di chuyển của robot di động. Ở chương này, trước tiên luận án nghiên cứu hệ thống mạng cảm biến không dây trong nhà kính nông nghiệp. Sau đó, luận án nghiên cứu, đề xuất giải pháp điều hướng cho robot di động đảm bảo thực hiện nhiệm vụ thu thập dữ liệu thông số môi trường và hình ảnh cây trồng trong khoảng thời gian cho trước định sẵn, ưu tiên tiết kiệm năng lượng cho các nút cảm biến đầu cụm. Cuối cùng là phần kết luận chương.

2.1 Mạng cảm biến không dây trong nhà kính sản xuất nông nghiệp

2.1.1 Giới thiệu về mạng cảm biến không dây


Mạng cảm biến không dây (Wireless Sensor Networks – WSNs) là hệ thống bao gồm nhiều nút cảm biến (sensor nodes), được tích hợp các thiết bị đo lường môi trường như cảm biến nhiệt độ, độ ẩm, ánh sáng,... đồng thời có khả năng kết nối và trao đổi dữ liệu qua giao tiếp không dây (Hình 2.1). Các nút này liên kết với nhau tạo thành một mạng phủ sóng trên một khu vực vật lý xác định, phục vụ mục đích giám sát, theo dõi và quản lý. Dữ liệu thu thập từ từng nút cảm biến sẽ được chuyển tiếp qua nhiều nút trung gian đến trạm gốc (base station/gateway), sau đó truyền qua Internet về trung tâm dữ liệu để lưu trữ, phân tích và xử lý [60].



Hình 2.1 Cấu trúc cơ bản của WSNs

Hình 2.2 biểu diễn mô hình của một mạng cảm biến không dây giám sát một khu vực trồng cây. Nút cảm biến (Sensor node) là thiết bị có khả năng thu thập các thông tin từ môi trường xung quanh thông qua các loại cảm biến khác nhau như nhiệt

độ, độ ẩm, độ pH, cường độ ánh sáng, tốc độ và hướng gió, hình ảnh... (tùy thuộc vào cảm biến được tích hợp). Bên cạnh đó, nút cảm biến còn có chức năng trao đổi dữ liệu với các nút khác trong phạm vi phủ sóng và truyền thông tin thu thập được về trạm trung gian thông qua kết nối không dây. Nút quản lý vùng là thành phần chịu trách nhiệm giám sát và điều phối hoạt động của các nút cảm biến trong phạm vi phủ sóng. Nó đóng vai trò như cầu nối trung gian giữa các nút cảm biến và trung tâm điều hành, đảm nhận việc thu nhận dữ liệu từ các nút cảm biến và chuyển tiếp đến trung tâm gần nhất. Đồng thời, nút quản lý vùng cũng tiếp nhận lệnh từ trung tâm điều hành và truyền lại cho các nút cảm biến để thực hiện theo yêu cầu.



Hình 2.2 Kiến trúc mô hình giám sát sử dụng WSNs [61]

2.1.2 Mô hình mạng cảm biến không dây trong nhà kính nông nghiệp

Với nhà kính nông nghiệp diện tích khoảng vài hecta trở lên được chia thành nhiều khu trồng nên sẽ có nhiều cụm cảm biến được bố trí theo từng khu, mỗi cụm cảm biến có một nút cảm biến đầu cụm.

Nút cảm biến đầu cụm (Cluster Head- CH) là nút trung tâm của một cụm cảm biến, chịu trách nhiệm thu thập dữ liệu từ các nút cảm biến địa phương, xử lý sơ bộ và truyền dữ liệu đến trạm gốc, hay còn được gọi là cụm trưởng.

Cụm trưởng được chọn theo điều kiện về năng lượng lưu trữ lớn nhất và khoảng cách so với các nút cảm biến còn lại của cụm cảm biến đó trong giới hạn có

thể thu nhận tín hiệu từ các nút cảm biến địa phương. Cụm trưởng được chọn theo thuật toán CHE [62]- chọn cụm trưởng (Cluster Head Election-CHE): chọn ra các cụm trưởng (CH) sao cho năng lượng tiêu thụ cân bằng và tổng chi phí truyền thông trong mạng là nhỏ nhất. Cụ thể bài toán như sau:

- Chia vùng cảm biến thành M vùng con bằng nhau
- Mỗi nút trong vùng phát bản tin “HELLO” chứa ID, vị trí, độ dài đường ngắn nhất đến các nút khác và năng lượng còn lại.
- Mỗi nút tính giá trị ưu tiên (Prior Value- PV) theo công thức (2.1):

$$PV_k = \alpha_k \frac{E_{re}(t)}{E_0} + \beta_k \frac{1}{l_k} \quad (2.1)$$


Trong đó: $E_{re}(t)$ và E_0 - năng lượng còn lại và ban đầu của nút cảm biến thứ k ; $E_{re}(t)$ được xác định theo (1.5).

l_k - tổng độ dài các đường ngắn nhất từ nút đang xét đến các nút khác trong cụm.

$\alpha_k + \beta_k = 1$: hệ số trọng số tối ưu.

Nút cảm biến nào có PV_k cao nhất trong vùng được chọn làm nút cụm trưởng.

Mô hình mạng cảm biến không dây mà luận án nghiên cứu là một mạng cảm biến có khoảng từ 200 đến 250 nút cảm biến được bố trí phân tán đều ở các vị trí khác nhau sao cho bao phủ được toàn bộ nhà kính sử dụng phương thức truyền thông không dây (Hình 2.3).




Hình 2.3 Mô hình mạng cảm biến không dây

- Vị trí đặt trung tâm điều khiển mạng (NCC), nút cảm biến và cảm biến
 + Trung tâm điều khiển mạng (NCC): đặt ở trung tâm khu vực canh tác cần giám sát.

+ Các nút cảm biến: lắp đặt trên cột giàn, đảm bảo tín hiệu truyền thông ổn định và tránh cản trở hoạt động canh tác.

+ Các cảm biến đơn lẻ:

Các loại cảm biến dùng trong nhà kính nông nghiệp được trình bày trên Hình 2.4:



Hình 2.4 Các loại cảm biến trong nhà kính nông nghiệp

Cảm biến nhiệt độ và độ ẩm không khí: đặt ở nhiều vị trí trong nhà kính, độ cao ngang tán lá cà chua (khoảng 1,2–1,5 m), đồng thời có thể bố trí thêm một số điểm gần trần nhà kính để giám sát phân tầng nhiệt.

Cảm biến ánh sáng (PAR, bức xạ): đặt phía trên tán cây, gần mái kính để đo cường độ ánh sáng thực tế mà cây nhận được.

Cảm biến độ ẩm đất hoặc giá thể: cắm trực tiếp vào vùng rễ, mỗi luống hoặc mỗi khu tưới nên có ít nhất 1–2 điểm đo để phản ánh chính xác tình trạng ẩm.

Cảm biến CO₂: đặt ở một số vị trí cần theo dõi nồng độ khí này, ngang tán cây để đo nồng độ khí phục vụ quang hợp.

- *Giao thức truyền tin*

Bảng 2.1. So sánh các phương thức truyền tin trong mạng cảm biến không dây [63]

Tham số	Tiêu chuẩn	Tốc độ dữ liệu	Dải tần số	Mức tiêu thụ năng lượng	Phạm vi truyền	Chi phí
WiFi	IEEE 802.11 a/c/b/d/g/n	1 Mbps đến 6,75 Gbps	5 – 60 GHz	Cao	20 – 100 m	Lớn
LoRaWAN	LoRaWAN R1.0	0,3 – 50 Kb/s	868 – 90 MHz	Rất thấp	< 30 km	Lớn
RFID	ISO-18000 6C	40 – 160 Kb/s	860 – 960MHz	Thấp	1 – 5 m	Nhỏ
MQTT	OASIS	250 Kb/s	2.4 GHz	Thấp	-	Nhỏ
SigFox	SigFox	100 – 600 bit/s	200 KHz	Thấp	30 – 50 km	Nhỏ
WiMax	IEEE 802.16	1 Mbps – 1 Gbps (cố định), 50 – 100 Gbps (di động)	2 – 66 GHz	Trung bình	< 50 km	Lớn
Bluetooth	IEEE 802.15.1	1 – 24 Mb/s	2,4 GHz	Rất thấp	8 – 10 m	Nhỏ
ZigBee	IEEE 802.15.4	40 – 250 Kb/s	2,4 GHz	Thấp	10 – 20 m	Nhỏ

Với diện tích nhà kính và số lượng nút cảm biến trong phạm vi nghiên cứu trung bình có khoảng 60 nút/ha. Như vậy, khoảng cách trung bình giữa các nút cảm biến trong mạng WSNs nằm trong khoảng 12–18 m.

Căn cứ vào bảng so sánh các phương thức truyền tin (Bảng 2.1), có thể nhận thấy chuẩn IEEE 802.15.4/ZigBee (tần số 2,4 GHz) là lựa chọn phù hợp cho việc truyền thông giữa các nút cảm biến địa phương với cụm cảm biến đầu cụm (Cluster Head – CH). Ưu điểm của ZigBee được thể hiện ở các khía cạnh sau: (i) tiêu thụ năng lượng thấp, (ii) tốc độ truyền dữ liệu 250 kbps đáp ứng yêu cầu ứng dụng, (iii) phạm vi truyền 10–20 m trong nhà khi có các vật cản và có thể đạt từ 75–100m trong điều kiện lý tưởng (tầm nhìn trực tiếp, ăngten được nâng cao, nhiễu thấp và các tham số phần cứng/thu phát được tối ưu hóa....), (iv) độ tin cậy cao nhờ cơ chế truyền đa bước (multi-hop), và (v) khả năng mở rộng linh hoạt khi thêm hoặc bớt nút mà không làm ảnh hưởng đến cấu trúc mạng.

Như đã trình bày trong mục 1.2 (Chương 1) của luận án, dữ liệu từ các nút cảm biến địa phương được tập trung tại CH, sau đó robot di động chỉ cần thu thập dữ liệu tại các CH thay vì phải tiếp cận từng nút riêng lẻ. Cách tiếp cận này mang lại các lợi ích quan trọng:

- Tiết kiệm năng lượng cho nút cảm biến địa phương: mỗi nút chỉ truyền dữ liệu trong phạm vi ngắn đến CH gần nhất, thay vì gửi trực tiếp đến robot hoặc trạm gốc, từ đó kéo dài thời gian hoạt động của pin.

- Giảm số điểm robot di động phải ghé thăm: thay vì di chuyển đến toàn bộ 250 nút, robot chỉ cần tiếp cận số lượng CH, qua đó rút ngắn quãng đường và thời gian đi thu thập dữ liệu của robot.

- Đảm bảo tính tập trung dữ liệu: CH có khả năng lưu trữ đệm dữ liệu từ các nút con trong một chu kỳ định sẵn, cho phép robot thu nhận toàn bộ dữ liệu tại một thời điểm.

- Tăng độ tin cậy trong truyền thông: robot di động chỉ cần thiết lập liên kết truyền tin cự ly ngắn với CH (qua Wi-Fi Direct, ZigBee hoặc BLE), giảm nguy cơ mất gói so với việc phải kết nối trực tiếp với số lượng lớn các nút cảm biến nhỏ lẻ.

2.1.3 Giả thiết mô hình mạng cảm biến không dây và yêu cầu thu thập dữ liệu

Để giới hạn phạm vi nghiên cứu và đơn giản hóa mô hình, trước tiên NCS đưa ra các giả thiết tổng quát về mô hình WSNs được sử dụng trong nội dung của luận án này như sau:

- Các nút cảm biến (N) trong mạng được phân bố đồng đều, có năng lượng ban đầu giới hạn E_0 và không thay đổi vị trí sau khi triển khai.

- Số lượng các nút cảm biến trong mỗi cụm là như nhau.

➤ Thiết bị thu thập dữ liệu cảm biến từ các cụm cảm biến đầu cụm là robot di động (Mobile Robot- MR) có khả năng di chuyển tự do trong khu vực giám sát, không bị giới hạn về năng lượng cũng như dung lượng lưu trữ. MR chỉ thu nhận dữ liệu từ cụm cảm biến đầu cụm (CH) khi nằm trong phạm vi truyền của CH đó. MR không dừng trong quá trình di chuyển giữa các CH. MR có thể định kỳ trở về trung tâm hỗ trợ để sạc lại năng lượng.

➤ Trong mỗi vòng hoạt động, sau khi hoàn tất quá trình xác định CH của các cụm cảm biến, toàn bộ thông tin vị trí địa lý của các CH sẽ được gửi đến Trung tâm điều khiển mạng (Network Control Center - NCC). Tại đây, các thông tin này được phân tích nhằm điều hướng di chuyển của MR đảm bảo các yêu cầu đặt ra. NCC là nơi MR bắt đầu và kết thúc chu trình thu thập dữ liệu.

➤ Trong nghiên cứu này, tuổi thọ mạng được định nghĩa là số vòng hoạt động cho đến khi 85% tổng số nút trong mạng cạn kiệt năng lượng (năng lượng dư thừa không đủ để nút cảm biến đó hoạt động).

➤ Trong thời gian báo cáo ξ_0 được xác định trước, tất cả dữ liệu được lưu trữ đệm tại CH phải được truyền tới MR nhằm tránh tình trạng tràn bộ nhớ đệm, gây mất dữ liệu.

➤ Trong phạm vi nghiên cứu của luận án, T_r được hiểu là chu kỳ thời gian mà dữ liệu cảm biến từ tất cả các nút N trong mạng có thể được thu thập thành công tại NCC. Trong mỗi vòng hoạt động, mỗi nút cảm biến sẽ tạo ra một mẫu dữ liệu có kích thước γ bit, và phải truyền gói dữ liệu này đến CH tương ứng của nó.

Yêu cầu về thu thập dữ liệu mạng cảm biến không dây

Đảm bảo tiết kiệm năng lượng tiêu thụ tại các nút cảm biến và cân bằng năng lượng giữa các nút cảm biến, từ đó nâng cao tuổi thọ của toàn mạng cảm biến.

Đảm bảo dữ liệu từ các nút cảm biến được thu thập đầy đủ trong thời gian yêu cầu, phục vụ cho các ứng dụng thời gian thực.

Để đảm bảo các yêu cầu trên luận án đề xuất giải pháp: chia vùng cảm biến thành các cụm cảm biến phù hợp tương đương với số lượng nút cảm biến đầu cụm vì mỗi cụm sẽ chọn ra một nút cụm trưởng và sử dụng robot di động thu thập dữ liệu từ cụm trưởng.


2.2. Xác định số lượng nút cảm biến đầu cụm

Nếu mỗi nút cảm biến đều gửi dữ liệu trực tiếp về trạm gốc hoặc trung tâm điều khiển thì các nút ở xa sẽ phải truyền với công suất cao, khoảng cách xa dẫn đến tiêu tốn nhiều năng lượng, kết quả năng lượng dư thừa tại nút cảm biến đó thấp ảnh hưởng đến tuổi thọ của mạng cảm biến. Giải pháp để giải quyết vấn đề này là cần chia vùng cảm biến ra thành các cụm. Tại mỗi cụm chọn ra một nút cảm biến đầu

cụm (CH) nhận dữ liệu của các nút cảm biến còn lại trong cụm như đã trình bày tại mục 2.1.2. Khi đó các nút còn lại trong một cụm cảm biến chỉ cần gửi dữ liệu đến cụm trưởng với khoảng cách ngắn. Sau đó, CH sẽ tổng hợp dữ liệu và gửi về trung tâm điều khiển thông qua robot di động. Giải pháp này có ý nghĩa:

- Giảm số lần truyền xa, tránh tiêu tốn nhiều năng lượng.
- Tránh trùng lặp dữ liệu vì CH có thể loại bỏ dữ liệu dư thừa.
- Cân bằng tải năng lượng giữa các nút.

Nếu số nút cảm biến đầu cụm quá ít thì mỗi CH phải nhận từ nhiều nút cảm biến địa phương trong cụm một lượng dữ liệu lớn và khoảng cách truyền xa hơn dẫn đến CH tiêu hao nhiều năng lượng. Nếu số CH quá nhiều thì robot di động sẽ phải đi đến nhiều vị trí để thu thập điều này dẫn đến dữ liệu không được thu thập đầy đủ trong thời gian cho phép. Để giải quyết vấn đề này, luận án tiến hành xác định số lượng nút cảm biến đầu cụm phù hợp, giúp tiết kiệm được năng lượng tiêu hao tại các nút cảm biến và đảm bảo thời gian thu thập dữ liệu trong khoảng thời gian cho phép xác định trước.



Hình 2.5 Xác định số lượng nút cảm biến đầu cụm (CH)

Xét với một mạng cảm biến không dây hình chữ nhật như minh họa trong Hình 2.5. Trong đó, l_1 và l_2 lần lượt là chiều dài và chiều rộng của vùng cảm biến hình chữ nhật. Trong giai đoạn triển khai mạng ban đầu, mỗi nút cảm biến đều có cùng vùng truyền thông với bán kính truyền $R_t = d_0$. Vị trí của NCC được đặt tại trung tâm của mạng cảm biến. Để xác định số lượng nút cảm biến đầu cụm tương đương với số cụm cảm biến khi chia vùng cảm biến thành M bằng nhau sao cho phù hợp, định lý được phát biểu như sau:

Định lý 1

Giả sử $l_{\max}$ là khoảng cách lớn nhất giữa NCC và một nút cảm biến trong vùng cảm biến đang xét, R là tốc độ truyền dữ liệu giữa CH và MR, v là tốc độ được chỉ định của MR, sẽ tồn tại một phương án phù hợp khi chia trường cảm biến thành M phần bằng nhau nếu điều kiện sau đây được thỏa mãn:

$$M \geq \frac{\gamma l_1 l_2 v}{\pi d_0^2 R (\xi_0 v - 2l_{\max})} \quad (2.2)$$

Chứng minh định lý 1:

Để đạt được khả năng bao phủ toàn phần trong mạng cảm biến không dây, giả định mô hình sao cho vùng truyền thông của toàn bộ N nút cảm biến phải bao phủ tất cả diện tích của vùng cảm biến [64]. Điều này có nghĩa mong muốn mạng được phủ đầy đủ (không quá nhiều chồng lấn, không bỏ sót vùng nào), một cách ước lượng là cho tổng diện tích phủ của các CH bằng diện tích toàn mạng nên ta có:

$$N\pi d_0^2 = l_1 l_2 \quad (2.3)$$

Suy ra:

$$N = \frac{l_1 l_2}{\pi d_0^2} \quad (2.4)$$

Gọi N_m , với $m \in [1, M]$, là số lượng nút trong cụm A_m . Giả thiết số lượng các nút trong mỗi cụm là như nhau. Nên ta có:

$$N_m M = N = \frac{l_1 l_2}{\pi d_0^2} \quad (2.5)$$

Hoặc

$$N_m = \frac{l_1 l_2}{M\pi d_0^2} \quad (2.6)$$

Với giả thiết, robot di động di chuyển không dừng trong quãng đường giữa các CH với nhau. Để bảo đảm rằng tất cả các nút cảm biến có thể được thu thập dữ liệu kịp thời, và không cần sử dụng nhiều hơn một thiết bị thu thập di động (MR) để đến thăm một cụm trường nhằm thu thập dữ liệu, tổng thời gian MR sử dụng cho việc di chuyển (t_{tr0}) và thu thập dữ liệu (t_{col0}) từ một cụm trường xa nhất phải nhỏ hơn một ngưỡng thời gian báo cáo (ξ_0).

$$t_{tr0} + t_{col0} \leq \xi_0 \quad (2.7)$$

Khoảng thời gian dài nhất cần thiết cho quá trình di chuyển của robot được định nghĩa là thời gian để robot di chuyển từ trung tâm điều khiển mạng (NCC) đến nút cảm biến xa nhất (ở khoảng cách $l_{\max}$) và sau đó quay trở lại NCC với giả định

đường đi của robot di động là đường thẳng, chiều dài đi và về như nhau, vận tốc không đổi trong quá trình di chuyển. Khoảng thời gian này được xác định theo công thức (2.8).

$$t_{tr0} = \frac{2l_{max}}{v} \quad (2.8)$$

Thời gian tiêu tốn của robot di động để thu thập toàn bộ dữ liệu cảm biến từ N_m nút được tính theo phương trình (2.9).

$$t_{col0} = \frac{\gamma N_m}{R} \quad (2.9)$$

Từ các phương trình (2.8) và (2.9), chúng ta có thể viết lại phương trình (2.7) như sau:

$$\frac{2l_{max}}{v} + \frac{\gamma N_m}{R} \leq \xi_0 \quad (2.10)$$

Trong đó R - tốc độ truyền dữ liệu từ nút phát đến nút thu, γ - tổng số gói dữ liệu được tạo ra bởi mỗi nút cảm biến trong mỗi vòng lặp. Ta có:

$$N_m \leq \frac{R}{\gamma} \left(\xi_0 - \frac{2l_{max}}{v} \right) \quad (2.11)$$

Thay (2.6) vào (2.11) ta có:

$$M \geq \frac{\gamma l_1 l_2 v}{\pi d_0^2 R (\xi_0 v - 2l_{max})}$$

Vậy định lý 1 được chứng minh.

Do mỗi một cụm cảm biến sẽ chọn ra một nút cảm biến đầu cụm, số lượng cụm trường sẽ bằng số lượng M vùng cảm biến xác định được theo điều kiện (2.2).

2.3 Điều hướng robot di động thu thập dữ liệu trong mạng cảm biến

Như đã phân tích ở trên, luận án đề xuất giải pháp robot di động di chuyển đến các nút cảm biến đầu cụm để thu thập dữ liệu. Tuy nhiên, việc chọn các cụm trường (CH) của mỗi cụm dựa vào năng lượng dư thừa của nút cảm biến ở các thời điểm khác nhau nên cụm trường của mỗi cụm cảm biến sẽ thay đổi trong mỗi vòng lặp mà robot di động đi thu thập dữ liệu. Hay nói cách khác, đường đi của robot di động trong mỗi lần đi thu thập dữ liệu thay đổi. Luận án đề xuất giải pháp điều hướng cho robot di động phù hợp để đạt được yêu cầu về thu thập dữ liệu mạng cảm biến không dây tại mục 2.1.3.

Bài toán điều hướng robot di động sẽ từ NCC đi đến các nút cụm trường thu thập dữ liệu và di chuyển về NCC để gửi dữ liệu thu thập được tại đó.


Đường đi của MR được xây dựng dựa trên giải pháp hình học heuristic [65] là phương pháp xấp xỉ TSP (Travelling Saleman Problem) dựa trên tính chất hình

học của các nút trong WSNs nhằm đạt được lời giải gần tối ưu với chi phí tính toán thấp, giải pháp này cho phép xây dựng đường đi ngắn.

Các bước chính của giải pháp hình học heuristic như sau:


- Chia vùng (Hình 2.6): vùng hình quạt tròn bán kính R và góc θ được chia thành 3 phần gồm hai hình quạt tròn ở phía trong đối xứng nhau (ký hiệu A và C) và một vành ngoài (ký hiệu B). Việc chia được xác định bởi tham số: $\rho = \frac{R'}{R}$

Với r là bán kính chuẩn hóa được xác định $r = \frac{d}{R}$ (d - khoảng cách từ điểm trong vùng hình quạt đến đỉnh hình quạt). Các miền A và C là những miền có $r < \rho$, và B là miền có $r \geq \rho$.



Hình 2.6. Phân vùng trong phương pháp heuristic

- Tiếp theo, đường đi được xây dựng bằng cách thăm các điểm trong A, C theo thứ tự bán kính và thăm các điểm trong B theo thứ tự góc. Kết quả thu được 3 đường mở, mỗi đường nằm trong một phần (Hình 2.7a). Tiếp tục nối hai đầu ngoài của các đường ở A và C với hai đầu của đường trong B thì ta được một đường đi khép kín qua tất cả các điểm (Hình 2.7b).



Hình 2.7. Cách ghép nối các điểm và đường mở

Khi đó, bài toán xây dựng đường đi của robot di động thu thập dữ liệu với mô hình mạng cảm biến không dây của luận án như sau:

Theo giải pháp hình học heuristic được trình bày ở trên, để xác định đường đi của robot di động trong vùng cần thu thập dữ liệu cần tiến hành xác định khu vực đó cho robot di động. Bằng cách chọn góc hình quạt cho MR sao cho tất cả các nút CH trong vùng phân công, được robot di động ghé thăm, đều được phân bố trên một vùng

hình quạt tròn. Đỉnh hình quạt sẽ nằm trên NCC, đóng vai trò vừa là điểm bắt đầu vừa là điểm kết thúc đường đi của robot di động. Như có thể thấy trong hình 2.8a, nếu bán kính trung bình của hình quạt tròn là $l_f = 0,5(l_{f1} + l_{f2})$, diện tích của hình quạt tròn là:

$$H_f = \frac{\varphi_f l_f^2}{2} \quad (2.12)$$

Số lượng nút bên trong khu vực được phân công của MR_f là:

$$N_f = \rho H_f \quad (2.13)$$

Thay (2.12), (2.13) vào (2.10) với $N_m = N_f$ ta được:

$$\varphi_f \leq \frac{2R}{\gamma \rho l_f^2} \left(\xi_0 - \frac{2l_{max}}{v(t)} \right) \quad (2.14)$$


Xét diện tích khu vực được phân công của MR_f , ta có:

$$2l_{max} \geq 2l_f \quad (2.15)$$

Vì vậy, công thức (2.14) được viết lại là:

$$\varphi_f \leq \frac{2R}{\gamma \rho l_f^2} \left(\xi_0 - \frac{2l_f}{v(t)} \right) \quad (2.16)$$

Theo (2.16), chọn góc hình quạt phù hợp φ_f của vùng được phân công thu thập dữ liệu cảm biến của MR_f , đảm bảo rằng tất cả dữ liệu cảm biến có thể được truyền kịp thời đến NCC.



Hình 2.8 Đường đi của MR theo phương pháp heuristic

Có thể thấy trong Hình 2.8a, để tìm đường đi của robot di động, theo phương pháp heuristic, hình quạt tròn được chia thành ba phần bao gồm hai tam giác vuông ($\Delta C_1 C_2 C_3$, $\Delta C_1 C_3 C_4$) và một vành tròn $\Delta C_4 C_5 C_2$. Khi kết nối tất cả các điểm ghé thăm (vị trí của CH) trong mỗi phần, kết quả có ba đường mở. Hình 2.8b minh họa đường mở của mỗi đường. Đường đi của MR sẽ được tìm thấy khi ta nối các đường này lại với nhau. Đường đi của MR được thể hiện trong Hình 2.8c.

Tổng chiều dài đường đi của MR_f phụ thuộc vào góc hình quạt φ_f , số lượng CH cần ghé thăm, tổng số nút cảm biến trong vùng phân công của MR_f , và vị trí địa lý của các CH. Do đó, theo ngưỡng ξ_0 , góc hình quạt φ_f sẽ được điều chỉnh theo thứ tự mỗi nút cụm trường trong hình quạt tròn sẽ được ghé thăm trong thời gian báo cáo.

Robot di động thu thập dữ liệu từ mạng cảm biến không dây với yêu cầu như sau: thu thập đầy đủ dữ liệu từ N_f nút trong vùng cảm biến được phân công, trong một khoảng thời gian hoạt động xác định trước ξ_0 .

Để đạt được yêu cầu trên, định lý được phát biểu như sau:

Định lý 2: Giả sử $\mathcal{R}_f(t)$ là tổng chiều dài đường đi của MR_f trong khu vực công tác của robot tại vòng hiện tại thứ t . Để thu thập được tất cả dữ liệu cảm biến từ N_f nút cảm biến trong ngưỡng thời gian báo cáo ξ_0 , MR_f phải di chuyển với tốc độ $v(t)$ sau khi thu thập dữ liệu tại mọi vị trí CH với tốc độ truyền dữ liệu R . Một thuật toán được gọi là có hiệu quả để thu thập dữ liệu đảm bảo không thất thoát dữ liệu cảm biến tồn tại khi và chỉ khi thỏa mãn điều kiện sau đây:

$$\left(\frac{\mathcal{R}_f(t)}{v(t)} + \frac{\gamma N_f}{R} \right) \leq \xi_0 \quad (2.17)$$

Chứng minh định lý 2:

Để thu thập dữ liệu từ tất cả các nút cảm biến bên trong vùng được phân của MR_f một cách kịp thời, thời gian báo cáo tại mỗi chu kỳ thời gian $\xi(t)$ phải nhỏ hơn hoặc bằng ngưỡng thời gian báo cáo ξ_0 .

$$\xi(t) = t_{tr}(t) + t_{col} \leq \xi_0 \quad (2.18)$$

Tổng thời gian di chuyển của MR_f tại vòng hiện tại thứ t được tính theo công thức (2.19)

$$t_{tr}(t) = \frac{\mathcal{R}_f(t)}{v(t)} \quad (2.19)$$

Và tổng thời gian mà MR_f dành cho việc thu thập dữ liệu từ các nút cảm biến N_f được xác định theo (2.20).

$$t_{col}(t) = \frac{\gamma N_f}{R} \quad (2.20)$$

Thay (2.19), (2.20) vào (2.18), thời gian báo cáo được xác định theo (2.21) như sau:

$$\xi(t) = \frac{\mathcal{R}_f(t)}{v(t)} + \frac{\gamma N_f}{R} \quad (2.21)$$

Do đó, tổng thời gian sử dụng của MR_f trong mỗi vòng hoạt động được xác định theo công thức sau:

$$\left(\frac{\mathcal{R}_f(t)}{v(t)} + \frac{\gamma N_f}{R} \right) \leq \xi_0$$

Định lý 2 đã được chứng minh.

2.4 Đề xuất thuật toán điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây

2.4.1 Mục tiêu và các ràng buộc của bài toán

Bài toán điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây phục vụ giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp đảm bảo các điều kiện sau:

- Giảm thiểu tổng chiều dài quỹ đạo di chuyển của robot di động.
- Mỗi nút cảm biến đầu cụm phải được robot di động ghé thăm nghĩa là không có nút cảm biến đầu cụm nào bị bỏ qua trong mỗi vòng thu thập của robot di động.
- Robot di động hoàn thành một vòng thu thập dữ liệu của mình trong ngưỡng thời gian báo cáo ξ_0 .

Mục tiêu của bài toán là tối thiểu hoá tổng chi phí di chuyển và thu thập dữ liệu của robot di động, được biểu diễn bởi (2.22):

$$\min \left\{ \sum_{i=0}^N \sum_{j=0}^N \sum_{i \neq j}^N \xi_{ij} x_{ij} \right\} \quad (2.22)$$

Trong đó, các tham số và biến quyết định được định nghĩa như sau:

$x_{ij} \in \{0, 1\}$: biến nhị phân, bằng 0 nếu không có cung từ nút i đến nút j và 1 nếu $i \neq j$; $i, j \in \{0, 1, \dots, N\}$;

N : tổng số nút cảm biến trong mạng;

ξ_{ij} : chi phí (thời gian thực hiện để truyền dữ liệu và MR di chuyển từ nút i đến nút j).

Với các ràng buộc:

$$\sum_{i=1}^N x_{ij} = 1 \quad \text{với } j = 0 \quad (2.23)$$

$$\sum_{j=1}^N x_{ij} = 1 \quad \text{với } i = 0 \quad (2.24)$$

$$\sum_{i=0}^N \sum_{j=0, i \neq j}^N \xi_{ij} x_{ij} \leq \xi_0, \quad (2.25)$$


Ràng buộc (2.23) thể hiện là robot di động chỉ có một cung đi ra từ NCC. Ràng buộc (2.24) đảm bảo rằng chỉ có một cung đi vào NCC. Ràng buộc (2.25) đảm bảo rằng tổng thời gian của MR để di chuyển và thu thập dữ liệu luôn nhỏ hơn thời gian báo cáo ngưỡng.

2.4.2 Thuật toán điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây.

Như đã phân tích ở mục 1.3.1, để robot di động có thể di chuyển thu thập dữ liệu hiệu quả từ mạng cảm biến không dây phục vụ cho giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp, cần thiết phải xây dựng một thuật toán điều hướng nhằm xác định đường đi di chuyển hợp lý giữa các nút cảm biến đầu cụm, thuật toán này được đặt tên là MRNA (Monitoring Robot Navigation Algorithm). Ngoài ra, như đã đề cập trong mục 2.1.2, mô hình mạng cảm biến không dây là mô hình động có nghĩa là vị trí của các cụm trường mà robot di động sẽ ghé thăm thay đổi sau mỗi chu kỳ di thu thập dữ liệu. Vì thế, việc xây dựng thuật toán xác định đường đi của robot di động trong mỗi chu kỳ thu thập dữ liệu giúp việc điều hướng cho robot di động đạt được mục tiêu đề ra. Mục tiêu của thuật toán không chỉ đảm bảo robot di động hoàn thành nhiệm vụ trong khoảng thời gian cho phép, mà còn phải giảm thiểu năng lượng tiêu thụ của các nút cảm biến trong toàn mạng. Việc xác định số lượng cụm, phân vùng hoạt động, và lựa chọn cụm trường đóng vai trò quan trọng trong hiệu quả của toàn bộ hệ thống. Bên cạnh đó, thuật toán cần tính đến các yếu tố khác như tốc độ di chuyển của MR, tốc

độ truyền dữ liệu, năng lượng ban đầu của các nút cảm biến và thời gian báo cáo dữ liệu.

Thuật toán được đề xuất MRNA sử dụng nguyên lý tối thiểu chi phí thời gian và tiết kiệm năng lượng của các nút cảm biến, đảm bảo rằng MR luôn lựa chọn đường đi ngắn nhất giữa các CH trong khi vẫn đáp ứng giới hạn thời gian định trước. Quá trình điều hướng được thực hiện tuần tự cho đến khi tất cả các CH được robot di động ghé thăm. Kết quả mong đợi là một đường đi hợp lý giúp MR thu thập đầy đủ dữ liệu, tiết kiệm năng lượng tại các nút cảm biến, duy trì cân bằng năng lượng trong mạng và nâng cao tuổi thọ hệ thống WSNs. Lưu đồ thuật toán được thể hiện trên hình 2.9.



Hình 2.9 Lưu đồ thuật toán MRNA

Thuật toán MRNA

Đầu vào: Các tham số mô hình: Số lượng nút cảm biến N , kích thước mạng $l_1 \times l_2$; Tốc độ của robot di động (v); Năng lượng ban đầu E_0 ; Ngưỡng thời gian báo cáo ξ_0 ; Gói dữ liệu γ -bit; Mật độ nút (ρ); Tốc độ truyền dữ liệu (R).

Đầu ra:

- Số lượng nút cảm biến đầu cụm M ;
- Vùng cảm biến phân công thu thập dữ liệu cho MR φ_i ;
- Đường đi của MR tại vùng cảm biến thu thập dữ liệu $\mathcal{R}_f(t)$.

1: Xác định số lượng nút cảm biến đầu cụm (M) trong WSNs dựa trên phương trình (2.2).

2: Xác định vùng cảm biến phân công (2.16) cho MR để thu thập dữ liệu.

Các bước 1 và 2 sẽ được thực hiện bởi NCC.

Sau các bước này, NCC sẽ phát tán thông tin này tới tất cả các nút cảm biến trong vùng cảm biến. Tại từng cụm cảm biến sẽ xác định nút cảm biến đầu cụm (CH) là nút có PV_k đạt giá trị lớn nhất (PV_k được xác định theo (2.1)). Vị trí của các cụm trưởng này sẽ được gửi về cho NCC để NCC bắt đầu điều khiển robot di động tìm đường đi của nó theo yêu cầu về thu thập dữ liệu cảm biến.

3: Bắt đầu quỹ đạo của robot di động từ NCC (điểm xuất phát) $\mathcal{R}_f^i=0$.

4: Trong tất cả các CH chưa được MR ghé thăm trong khu vực phân công của robot di động, chọn CH xa nhất từ NCC và thêm vào quỹ đạo hiện tại của MR: $\mathcal{R}_f^i=1$.

5: Nếu tất cả các CH đã được ghé thăm, chuyển đến bước 7.

Nếu không, chuyển đến bước 6

6: Tìm nút ứng viên tốt nhất trong các CH chưa được thăm, sao cho MR dự kiến sẽ ghé thăm CH đó với chi phí thời gian nhỏ nhất được xác định theo (2.22). Cập nhật thời gian báo cáo $\xi(t)$ của MR. Quay lại bước 5.

7: Thuật toán sẽ kết thúc với đường đi của robot di động đảm bảo yêu cầu về thu thập dữ liệu cảm biến.

2.5. Mô phỏng và đánh giá hiệu quả của thuật toán MRNA

Phần này luận án trình bày kết quả mô phỏng của thuật toán điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây.

Luận án mô phỏng thuật toán với 2 kịch bản:

- Kịch bản 1: Mạng cảm biến không dây kích thước (200mx200m) chứa 250 nút cảm biến.

- Kịch bản 2: Mạng cảm biến không dây kích thước (150mx150m) chứa 200 nút cảm biến.

Kết quả mô phỏng của thuật toán đề xuất được thực hiện trong môi trường MATLAB.


Các tham số cài đặt phục vụ cho quá trình mô phỏng được thể hiện trong **Bảng 2.2**. Một nút cảm biến không thể truyền hoặc cảm nhận dữ liệu được gọi là nút chết nếu năng lượng còn lại của nó thấp hơn $\theta = 0,0001(J)$.

Bảng 2.2. Thiết lập các tham số mô phỏng

Tham số	Giá trị
Nút triển khai	Ngẫu nhiên và đồng đều
Năng lượng ban đầu (E_0)	0,1 (J)
Năng lượng cho tập dữ liệu (E_{DA})	5 (nJ/bit)
Năng lượng tiêu thụ E_{elec}	50 (nJ/bit)
ε_{fs}	10 (pJ/bit/m ²)
ε_{mp}	0,0013 (pJ/bit/m ⁴)
Độ dài gói (γ)	4000 (bits)
Phạm vi truyền (R_t)	30 (m)
Tốc độ truyền dữ liệu (R)	250 (Kb/s)
Thời gian báo cáo (ξ_0)	60 (s)

2.5.1 Đánh giá kết quả mô phỏng thuật toán MRNA

Trong phần này, các thí nghiệm đã được thực hiện để đo thời gian robot di động thực hiện thu thập dữ liệu ξ , và chiều dài $\mathcal{R}_t(t)$ đường đi của robot di động trong vùng cảm biến mà robot di động được phân công thu thập dữ liệu.



Hình 2.10 Quỹ đạo của MR theo thuật toán MRNA

Hình 2.10 hiển thị đường đi của robot di động với thời gian tiêu tốn nhỏ nhất thu thập đầy đủ dữ liệu cảm biến (robot di động di chuyển qua tất cả các nút cảm biến đầu cụm trong vùng cảm biến được phân công) theo thuật toán điều hướng đề xuất.

Bảng 2.3 tóm tắt kết quả từ hai kịch bản với kích thước mạng khác nhau (200x200, 150x150) và số lượng nút triển khai ($N = 250, 200$):

➤ Trong kịch bản thứ nhất: 250 nút cảm biến được triển khai đồng đều trên khu vực 200m x 200m. Robot di động di chuyển với tốc độ 3 m/s thì thu được thời gian thu thập dữ liệu cảm biến dao động từ 54,2 giây đến 59,5 giây.

➤ Trong kịch bản thứ hai: 200 nút cảm biến được triển khai trong khu vực cảm biến 150m x 150 m. Như được trình bày trong Bảng 2.3, để đảm bảo thu thập dữ liệu hoàn chỉnh từ tất cả các nút, robot di chuyển với tốc độ 2 m/s.

Kết quả mô phỏng cho thấy rằng, trong tất cả các kết quả thí nghiệm, robot di động di chuyển trên con đường ngắn nhất để thu thập tất cả dữ liệu cảm biến trong khu vực được giao trong thời gian báo cáo $\xi_0 = 60s$.

Bảng 2.3. Chiều dài quỹ đạo và thời gian thực hiện của robot di động

TT	Kích thước mạng		N	ξ_0	v (m/s)	Chiều dài quỹ đạo của Robot (m)	Thời gian thực hiện ξ (s)
	l_1 (m)	l_2 (m)					
1	200	200	250	60	3,0	397,5	58,1
2	200	200	250	60	3,0	395,4	56,6
3	200	200	250	60	3,0	391,5	54,0
4	200	200	250	60	3,0	389,4	52,6
5	200	200	250	60	3,0	399,3	59,3
6	200	200	250	60	3,0	399,6	59,5
7	200	200	250	60	3,0	391,8	54,2
8	200	200	250	60	3,0	395,1	56,4
9	200	200	250	60	3,0	396,6	57,5
10	200	200	250	60	3,0	394,8	56,2
11	150	150	200	60	2,0	348,1	49,5
12	150	150	200	60	2,0	349,6	51,1
13	150	150	200	60	2,0	350,0	51,5
14	150	150	200	60	2,0	347,9	49,3
15	150	150	200	60	2,0	348,6	50,0
16	150	150	200	60	2,0	348,2	49,6
17	150	150	200	60	2,0	349,3	50,8
18	150	150	200	60	2,0	348,6	50,0
19	150	150	200	60	2,0	348,3	49,7
20	150	150	200	60	2,0	349,7	51,2

Luận án đã thực hiện thêm các mô phỏng bằng cách thay đổi mật độ và bán kính truyền của các nút cảm biến trong WSNs để đánh giá giải pháp điều hướng robot di động thu thập dữ liệu từ mạng cảm biến không dây đến tuổi thọ mạng. Kết quả mô phỏng được trình bày trong Bảng 2.4 chỉ ra rằng việc tăng bán kính truyền của mỗi nút cảm biến dẫn đến việc giảm mạnh tuổi thọ tổng thể của mạng. Kết quả này khẳng định rằng năng lượng tiêu thụ của các nút cảm biến tăng theo cấp số nhân với khoảng cách truyền dữ liệu theo công thức (1.1).

Bảng 2.4. Tuổi thọ mạng theo kích thước và mật độ mạng

TT	Kích thước mạng		N	R_t (m)	Tuổi thọ của mạng
	l_1 (m)	L_2 (m)			
1	200	200	250	10	3417
2				15	3364
3				20	3311
4				25	3258
5				30	3125
6				35	3056
7				40	2542
8				45	2318
9				50	1872
10				55	1561
11	150	150	200	10	3381
12				15	3325
13				20	3247
14				25	3115
15				30	3057
16				35	2465
17				40	2084
18				45	1912
19				50	1815
20				55	1673

2.5.2 So sánh hiệu suất của thuật toán MRNA với một số thuật toán tương tự khác ảnh hưởng đến tuổi thọ của mạng cảm biến không dây.

Việc kéo dài tuổi thọ của WSNs là một vấn đề quan trọng trong nhiều nghiên cứu. Cũng đã có bằng chứng rằng việc sử dụng robot di động là một trong những chiến lược hiệu quả nhất để nâng cao độ bền của mạng và cải thiện tuổi thọ mạng.

Trong phần này, hiệu suất của thuật toán điều hướng cho robot di động mà luận án đã đề xuất được đánh giá và so sánh với ba phương pháp tương tự:

➤ Phương pháp đầu tiên là sử dụng các nút di động thu thập dữ liệu, di chuyển dọc theo ranh giới mạng (thuật toán định tuyến- Routing Algorithm [66]). Trong [66], các nút di động di chuyển dọc theo ranh giới mạng để thu thập dữ liệu giám sát tại các khu vực khác nhau. Trong trường hợp này, một số nút cảm biến được đặt ở trung

tâm của khu vực, cách xa vị trí đỗ của các nút di động, có thể tiêu tốn nhiều năng lượng hơn so với các nút cảm biến khác.

➤ Thuật toán thứ hai là OMS1 (Optimal Movement Strategy), sử dụng một nút di động di chuyển trên con đường ngắn nhất để thu thập dữ liệu [62]. Trong thuật toán OMS1, các nút đầu cụm phải thay đổi phạm vi truyền tải của chúng, điều này có thể làm tăng mức tiêu thụ năng lượng theo cấp số nhân.


➤ Thuật toán cuối cùng là OMS2, gửi một số nút di động đến các khu vực mạng để thu thập dữ liệu [62].

Luận án tiến hành mô phỏng bốn thuật toán trên trong cùng một điều kiện (triển khai ngẫu nhiên, cùng mô hình truyền thông vô tuyến, cùng năng lượng ban đầu E_0 , cùng kích thước gói tin, và cùng trạm gốc), mỗi giá trị N ($10 \rightarrow 250$ nút) mô phỏng lặp lại nhiều lần, lấy trung bình số vòng cho tới khi 85% nút chết (năng lượng còn lại không đủ để nút cảm biến hoạt động), từ đó xác định số vòng và vẽ số lượng nút cảm biến sống (các nút vẫn hoạt động được) theo vòng.

Kết quả mô phỏng về tuổi thọ mạng với số lượng nút cảm biến thay đổi từ 10 đến 250 được trình bày trong Hình 2.11.

Từ Hình 2.11, có thể suy ra rằng thuật toán điều hướng cho robot di động của luận án đề xuất vượt trội hơn so với hai thuật toán OMS1, OMS2 và thuật toán định tuyến. Những yếu tố này dẫn đến sự mất cân đối trong việc tiêu thụ năng lượng giữa các nút trong mạng. Do đó, việc đạt được sự cân bằng trong việc tiêu thụ năng lượng giữa các nút cảm biến trong mạng sau mỗi vòng hoạt động là yếu tố quan trọng ảnh hưởng đến tuổi thọ mạng. Với việc duy trì mức tiêu thụ năng lượng cân bằng hơn giữa các nút cảm biến trong mạng, thuật toán điều hướng cho robot di động mà luận án đề xuất và thuật toán OMS2 đạt được tuổi thọ mạng cao hơn so với thuật toán OMS1 và thuật toán định tuyến được đề xuất trong [66].

Dựa trên kết quả thu được từ 350 lần mô phỏng thử nghiệm, tuổi thọ mạng tối đa đạt được khi sử dụng thuật toán OMS2 là 2964 vòng. Ngược lại, thuật toán mà luận án đề xuất liên tục vượt trội hơn OMS2 trong các điều kiện thực nghiệm tương tự, đạt được tuổi thọ mạng tối đa trung bình là 3125 vòng.



Hình 2.11 So sánh tuổi thọ của WSNs giữa các thuật toán OMS1, OMS2, Routing Algorithm và MRNA

Điều này chứng minh tuổi thọ của mạng được cải thiện khoảng 5,4%. Để đánh giá ý nghĩa thống kê của sự khác biệt này, luận án đã thực hiện kiểm định hai mẫu, và kết quả xác nhận rằng sự cải thiện quan sát được có ý nghĩa thống kê ở mức độ tin cậy 95% ($p < 0,05$). Những phát hiện này cho thấy thuật toán của luận án không chỉ kéo dài tuổi thọ mạng mà còn duy trì hiệu suất ổn định, khẳng định lợi thế thực tiễn của nó trong các ứng dụng mạng cảm biến thực tế. Dựa trên các kết quả này, giải pháp điều hướng cho robot di động thu thập dữ liệu từ mạng cảm biến không dây mà luận án đã đề xuất vượt trội hơn so với phương pháp sử dụng toàn bộ cảm biến cố định trong mạng cảm không dây để thu thập dữ liệu và có thể được áp dụng trong bất kỳ ứng dụng nào yêu cầu truyền và nhận dữ liệu giám sát kịp thời với chi phí thấp nhất.

Tuy nhiên, kết quả đạt được trong luận án dựa trên một số giả định về cấu trúc của WSNs đã trình bày trong mục 2.1.3. Những điều kiện thực tế sẽ được luận án đề xuất trong hướng nghiên cứu tương lai của luận án.

2.6 Kết luận chương 2

Trong chương 2 đã thực hiện được một số nội dung chính để đạt được mục tiêu nghiên cứu như sau:

- Nghiên cứu mạng cảm biến không dây trong nhà kính sản xuất nông nghiệp.
- Chia vùng cảm biến thành các cụm cảm biến và xác định số lượng các cụm cảm biến, đề xuất tại mỗi cụm có một nút cảm biến đầu cụm thu thập dữ liệu từ các nút cảm biến còn lại trong cụm. Đề xuất giải pháp robot di động đi đến tất cả các nút cảm biến đầu cụm trong vùng cảm biến được phân công thu thập dữ liệu trong thời

gian cho phép. Giải pháp đề xuất giúp tiết kiệm năng lượng tại các nút cảm biến và cân bằng năng lượng giữa các nút trong toàn mạng.

- **Đề xuất thuật toán điều hướng cho robot di động nhằm đảm bảo yêu cầu thu thập đầy đủ dữ liệu cảm biến trong thời gian cho phép.** Kết quả mô phỏng và so sánh với một số thuật toán tương tự đã chứng minh hiệu suất của thuật toán đề xuất.

Kết quả nghiên cứu trong chương 2 đã được công bố trong công trình sau:

[CT4] **N. T. Duyen**, P.X.Minh, N.M.Tien, N.Q.Uoc, N.T.Hoc “Enhancing network lifetime and data integrity in WSNs via optimized mobile robot trajectories” *Journal of Robotics and Control (JRC)*, 2025, 6(5), pp. 2260-2271, <https://doi.org/10.18196/jrc.v6i5.26489>, Scopus indexed (Q2).

Chương 3. NÂNG CAO CHẤT LƯỢNG PHÁT HIỆN SÂU BỆNH CÂY TRỒNG TRÊN CƠ SỞ TRÍ TUỆ NHÂN TẠO


Robot di động sau khi thực hiện thu thập dữ liệu từ các nút cảm biến đầu cụm của mạng cảm biến không dây theo bài toán điều hướng ở chương 2, chuyển dữ liệu về trung tâm điều khiển để xử lý và đưa ra quyết định. Để nâng cao khả năng giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp, ưu tiên nhiệm vụ phát hiện sâu bệnh cây trồng, ở chương này, tại mục 3.2, NCS sẽ đề xuất phương pháp xử lý dữ liệu hình ảnh cây trồng mà robot di động thu thập được từ các cảm biến hình ảnh trong khu vực cần giám sát. Luận án đề xuất giải pháp nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nông nghiệp trên cơ sở trí tuệ nhân tạo ở mục 3.4. Cuối cùng là kết luận chương.

3.1 Đặt vấn đề

Trong hệ thống nhà kính nông nghiệp hiện đại, giám sát sự phát triển của cây trồng là một nhiệm vụ quan trọng nhằm đảm bảo năng suất và chất lượng sản phẩm. Bên cạnh việc thu thập các dữ liệu môi trường từ mạng cảm biến không dây, việc quan sát trực tiếp tình trạng cây trồng thông qua hình ảnh giúp cung cấp thông tin chi tiết và trực quan hơn. Để thực hiện điều này, trong quá trình robot di động di chuyển đến các cảm biến đầu cụm của mạng cảm biến không dây như đã đề xuất ở chương 2 của luận án, tại một số vị trí trong khu vực cần giám sát đặt cảm biến hình ảnh tích hợp trong hệ thống camera thì robot **di động** đồng thời thu thập dữ liệu hình ảnh cây trồng và đưa dữ liệu về trung tâm điều khiển để xử lý. Tuy nhiên, thách thức đặt ra là cần có phương pháp xử lý dữ liệu hình ảnh hiệu quả nhằm phát hiện chính xác sự sinh trưởng, tình trạng dinh dưỡng cũng như dấu hiệu sâu bệnh trên cây.


Các kỹ thuật xử lý ảnh dựa trên chỉ số màu đơn thuần thường gặp hạn chế khi dữ liệu hình ảnh thu được từ môi trường phức tạp trong nhà kính như ánh sáng thay đổi, mật độ cây trồng cao hoặc hình thái cây khác nhau theo giai đoạn phát triển [67]. Việc lựa chọn phương pháp xử lý dữ liệu tiên tiến kết hợp với cải tiến mô hình trí tuệ nhân tạo là cần thiết để nâng cao độ chính xác và khả năng ứng dụng thực tiễn. Đặc biệt, ưu tiên phát hiện và giám sát sâu bệnh hại cây trồng sẽ giúp hỗ trợ nhà nông đưa ra biện pháp can thiệp kịp thời, giảm thiểu thiệt hại và tối ưu hóa quá trình sản xuất.

Trong chương này, luận án tập trung giải quyết bài toán giám sát sự phát triển cây trồng dựa trên dữ liệu hình ảnh cây trồng mà robot di động thu thập được từ cảm biến hình ảnh trong hệ thống camera giám sát cây trồng, đồng thời đề xuất các cải tiến về mô hình trí tuệ nhân tạo nhằm đáp ứng yêu cầu thực tiễn của hệ thống nhà kính thông minh (Hình 3.1).



Hình 3.1 Mô hình robot di động thu thập dữ liệu cảm biến và giám sát cây trồng

Việc phát hiện sâu bệnh trong nhà kính có ý nghĩa đặc biệt quan trọng đối với sản xuất nông nghiệp công nghệ cao. Trước hết, phát hiện kịp thời giúp ngăn chặn sự lây lan trong không gian khép kín, từ đó bảo vệ năng suất cũng như duy trì chất lượng nông sản ổn định. Đồng thời, việc xác định chính xác vị trí và mức độ bệnh tạo điều kiện cho ứng dụng các biện pháp canh tác chính xác, cho phép sử dụng thuốc bảo vệ thực vật một cách hợp lý, giảm chi phí và hạn chế tác động tiêu cực đến môi trường. Ngoài ra, dữ liệu thu được từ hệ thống phát hiện sâu bệnh đóng vai trò là nguồn thông tin quan trọng cho các hệ thống hỗ trợ ra quyết định, giúp nhà quản lý điều chỉnh lịch tưới, bón phân, chiếu sáng và thông gió nhằm tối ưu điều kiện sinh trưởng cho cây trồng.



Hình 3.2 Cấu trúc hệ thống phát hiện, cảnh báo và phòng trừ sâu bệnh

Từ sơ đồ cấu trúc hệ thống phát hiện, cảnh báo và phòng trừ sâu bệnh, NCS nhận thấy để nâng cao chất lượng phát hiện sâu bệnh cây trồng, luận án tập trung

nguyên cứu phương pháp xử lý dữ liệu sau đo, lựa chọn phương pháp phù hợp với bộ dữ liệu hình ảnh cây trồng mà robot di động thu thập từ cảm biến hình ảnh tích hợp trong hệ thống camera giám sát cây trồng tại một số vị trí trong khu vực cần giám sát và nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp trên cơ sở trí tuệ nhân tạo.

3.2 Khử nhiễu ảnh cây trồng do robot di động thu thập từ cảm biến hình ảnh tại một số nút cảm biến

3.2.1 Nhiễu trong ảnh cây trồng trong nhà kính nông nghiệp

Việc quản lý và giám sát sự phát triển của cây trồng trong nhà kính và nhà lưới ngày càng phụ thuộc vào các hệ thống tự động hóa cho việc thu nhận, phân tích và xử lý hình ảnh. Những hệ thống này đã chứng minh được hiệu quả đáng kể, độ chính xác cao, cũng như khả năng vận hành theo thời gian thực. Tuy nhiên, chất lượng của các hình ảnh được thu nhận vẫn là một hạn chế đáng kể, do chúng chịu ảnh hưởng mạnh mẽ từ các yếu tố môi trường trong điều kiện canh tác được kiểm soát.

Chẳng hạn, độ ẩm cao thường gây ra hiện tượng mờ sương, trong khi sự thay đổi cường độ chiếu sáng có thể dẫn đến hiện tượng phơi sáng quá mức hoặc thiếu sáng. Những suy giảm này làm ảnh hưởng đến độ tin cậy của các bước phân tích phía sau. Việc phát triển các kỹ thuật khử nhiễu và tăng cường chất lượng ảnh một cách tự động và mạnh mẽ là điều cần thiết.

Trong phần này, luận án đề cập đến vấn đề khử nhiễu ảnh cây trồng trong nhà kính nông nghiệp do robot di động thu thập từ cảm biến hình ảnh tích hợp trong hệ thống camera giám sát cây trồng đặt tại một số vị trí trong mạng khu vực cần giám sát. Nhìn chung, ba mô hình nhiễu chuẩn thường được xem xét trong xử lý ảnh [68], bao gồm nhiễu cộng (additive noise), nhiễu nhân (multiplicative noise) và nhiễu xung (impulse noise), vốn chiếm phần lớn các dạng suy giảm gặp phải trong các tình huống chụp ảnh thực tế.

Trong miền không gian, một ảnh bị nhiễu thuộc loại nhiễu cộng có thể được mô hình hóa toán học như được biểu diễn trong phương trình (3.1).

$$\hat{g} = g_{ij} + w_{i,j} \quad (3.1)$$


Ký hiệu $g_{i,j}$ biểu thị ma trận kích thước $N \times N$ của ảnh gốc, trong đó g là cường độ sáng tại điểm $(i, j), \{i, j = 1, 2, \dots, N\}$. $\hat{g}$ biểu thị ảnh quan sát được, và w tương ứng với nhiễu trắng Gaussian cộng, được giả định là độc lập và phân bố đồng nhất với trung bình bằng 0 và phương sai hữu hạn σ_n^2 .

Nhiễu được mô tả như sau: $w_{ij} \sim W(0, \sigma^2), \{i, j = 1, \dots, N\}$ trong đó tham số N được giới hạn là một lũy thừa của 2.

Hình 3.3 minh họa quá trình suy giảm chất lượng ảnh, trong đó ảnh gốc g bị ảnh hưởng bởi nhiễu cộng w .

Mục tiêu của quá trình khử nhiễu là khôi phục một ước lượng $\hat{g}$ sao cho gần nhất có thể với ảnh gốc g , bằng cách tối thiểu hóa sai số bình phương trung bình (Mean Square Error – MSE).

$$MSE(\hat{g}) = \frac{1}{N^2} \sum_{i,j=1}^N (\hat{g}_{ij} - g_{ij})^2 \quad (3.2)$$



Hình 3.3 Quá trình suy giảm chất lượng ảnh

Mô hình nhiễu nhân (multiplicative noise model) là một dạng suy giảm chất lượng ảnh khác thường được nghiên cứu. Đặc trưng nổi bật của mô hình này là chỉ một tập con các điểm ảnh (pixels) bị làm nhiễu bởi các giá trị ngẫu nhiên, trong khi các điểm ảnh còn lại không bị ảnh hưởng.

Biểu thức toán học của mô hình này, được Shamik và cộng sự (2011) mô tả trong [69], được trình bày trong phương trình (3.3).

$$\hat{g}_{ij} = g_{ij}(1 + \eta_{i,j}) \quad (3.3)$$

Trong đó, $\eta_{i,j}, \{i, j = 1, 2, \dots, N\}$ biểu thị hàm nhiễu có kích thước tương đương với ảnh đầu vào, tạo ra các giá trị ngẫu nhiên được lấy mẫu từ một phân bố tùy ý. Trong hầu hết các trường hợp, $\eta_{i,j}$ được giả định là phân bố đối xứng quanh giá trị 0, nhằm đảm bảo độ sáng trung bình của ảnh không bị thay đổi.

Mô hình nhiễu chuẩn thứ ba là nhiễu xung (impulse noise), được đặc trưng bởi việc giữ nguyên giá trị của một điểm ảnh với một xác suất nhất định $(1 - P)$, hoặc thay thế giá trị đó bằng một giá trị ngẫu nhiên với xác suất còn lại P .

Nhiễu xung thường xuất hiện do lỗi truyền dẫn hoặc nhiễu loạn khí quyển. Mặc dù trong nhiều trường hợp, đặc biệt là trong môi trường nhà kính nông nghiệp, nhiễu phụ thuộc vào đặc tính vật lý của thiết bị, môi trường truyền dẫn và các yếu tố khác, nhưng nhìn chung, nó vẫn thường được mô hình hóa dưới dạng một biến ngẫu nhiên, được đặc trưng bởi hàm mật độ xác suất (Probability Density Function – PDF).

Một số mô hình nhiễu cùng với hàm mật độ xác suất (PDF) tương ứng của chúng được sử dụng phổ biến trong xử lý ảnh được trình bày trong Bảng 3.1.

Bảng 3.1. Các mô hình nhiễu và hàm mật độ xác suất (PDF) của chúng

Noise model	PDF ($p(z)$)	Giá trị trung bình ($\bar{z}$)	Phương sai (σ^2)
Nhiều Gaussian	$\frac{1}{\sqrt{2\pi}b} e^{-\frac{(z-a)^2}{2b^2}} \quad -\infty < z < \infty$	a	b^2
Nhiều đều	$= \begin{cases} \frac{1}{b-a} & a \leq z \leq b \\ 0 & \text{ngược lại} \end{cases}$	$\frac{(a+b)}{2}$	$\frac{(b-a)^2}{12}$
Nhiều xung	$= \begin{cases} P_a & \text{với } z = a \\ P_b & \text{với } z = b \\ 0 & \text{ngược lại} \end{cases}$	$aP_a + bP_b$	$(a-\mu)^2 P_a + (b-\mu)^2 P_b$
Nhiều hạt	$= \begin{cases} ae^{-az} & \text{với } z \geq 0 \\ 0 & \text{với } z < 0 \end{cases}$	$\frac{1}{a}$	$\frac{1}{a^2}$

3.2.2 Phương pháp khử nhiễu ảnh dựa trên biến đổi Wavelet

Phương pháp khử nhiễu ảnh dựa trên biến đổi Wavelet là một trong những kỹ thuật được ứng dụng rộng rãi trong xử lý ảnh hiện đại. Biến đổi Wavelet cho phép phân tách ảnh thành các thành phần tần số khác nhau, giúp nhận diện và loại bỏ nhiễu trong khi vẫn bảo toàn được các đặc trưng quan trọng như cạnh (edges) và kết cấu (textures), phương pháp này cụ thể như sau:

a) Biến đổi Wavelet rời rạc hai chiều (2D-Discrete Wavelet Transformation)

Biến đổi Wavelet Rời rạc (DWT – Discrete Wavelet Transform) sử dụng các hàm sóng có độ dài hữu hạn và giá trị trung bình bằng 0, do đó hoàn toàn khác biệt so với các sóng sin được dùng làm hàm cơ sở trong phân tích Fourier (Fourier analysis).

Khác với sóng sin có miền mở rộng vô hạn, các wavelet có tính cục bộ và thường mang cấu trúc phi điều hòa, giúp biểu diễn tín hiệu hoặc ảnh một cách hiệu quả hơn trong miền không gian – tần số.

Biến đổi Wavelet Rời rạc Hai Chiều (2D-DWT) được thực hiện thông qua quá trình lọc thông thấp và lọc thông cao kế tiếp nhau trên ảnh. Quá trình này sẽ phân rã ảnh thành bốn miền con tương ứng với: LLk – thành phần xấp xỉ; LHk – thành phần chi tiết theo phương ngang; HLk – thành phần chi tiết theo phương dọc và HHk, $k=1,2,\dots,J$. Trong trường hợp này, k biểu thị cấp độ phân rã với J là cấp độ tối đa trong quá trình phân tích wavelet.


Dải con LL cung cấp xấp xỉ thô của ảnh gốc, với độ phân giải giảm xuống khoảng một nửa so với ảnh ban đầu. Trong khi đó, các dải con HL và LH biểu diễn các biến thiên hoặc biên cạnh theo hướng dọc và ngang tương ứng. Dải con HH chứa các chi tiết mịn tương ứng với thông tin tần số cao.

Biểu diễn đa phân giải này cho phép định vị đồng thời trong cả miền không gian và miền tần số, giúp biến đổi wavelet 2 chiều (2D-DWT) đặc biệt hiệu quả trong các ứng dụng như khử nhiễu ảnh, nén ảnh và trích chọn đặc trưng.


Quá trình phân rã ảnh thành ba mức wavelet được minh họa trong Hình 3.4, trong khi Hình 3.5 mô tả việc triển khai biến đổi DWT thuận ba mức bằng cấu trúc bộ lọc đệ quy hai kênh (two-channel recursive filter bank) [70].

Trong mô hình này:

- LP và HP lần lượt biểu thị bộ lọc phân tích thông thấp và bộ lọc phân tích thông cao.
- Khối $\downarrow 2$ biểu thị toán tử lấy mẫu xuống, có tác dụng giảm độ phân giải tín hiệu xuống một nửa.
- Ảnh đầu vào $g_{i,j}$ được phân rã đệ quy thành bốn dải con: LL^1, LH^1, HL^1 và HH^1 .




Hình 3.4 Biến đổi Wavelet Rời rạc 2 chiều (2D-DWT) ba mức trên một ảnh



Hình 3.5 Quá trình phân rã ảnh theo thuật toán Mallat [70]

Hình 3.6 thể hiện biến đổi Wavelet nghịch đảo ba mức (Three-level Inverse DWT) bằng cấu trúc bộ lọc đệ quy hai kênh. Trong đó, ${}^1\text{LP}$ và ${}^2\text{HP}$ lần lượt biểu thị bộ lọc tổng hợp thông thấp và bộ lọc tổng hợp thông cao. Khối $\uparrow 2$ biểu thị toán tử lấy mẫu lên với hệ số 2, có chức năng tăng gấp đôi độ phân giải tín hiệu trong quá trình tái tạo ảnh.



Hình 3.6 Quá trình tái tạo ảnh theo thuật toán Mallat

b) Phương pháp khử nhiễu ảnh dựa trên ngưỡng biến đổi Wavelet

Năm 1994, Donoho và Johnstone [71] đã giới thiệu kỹ thuật khử nhiễu bằng co ngưỡng wavelet. Kể từ đó, phương pháp này đã được ứng dụng rộng rãi nhờ tính đơn giản trong tính toán và hiệu quả cao trong việc khử nhiễu.

Bước cốt lõi của phương pháp là áp dụng ngưỡng lên các hệ số wavelet sau khi ảnh được phân rã, nhằm thu được các giá trị ước lượng. Trong quá trình này, hai vấn đề cơ bản cần được giải quyết:

1. Lựa chọn hàm ngưỡng.
2. Xác định giá trị ngưỡng thích hợp.

Cụ thể của hai vấn đề này như sau:

• Lựa chọn hàm ngưỡng

Việc lựa chọn hàm ngưỡng quyết định chiến lược và phương pháp ước lượng được áp dụng cho các hệ số Wavelet trong quá trình khử nhiễu.

Trong số các phương pháp được sử dụng phổ biến, hai loại hàm ngưỡng chủ đạo trong khử nhiễu dựa trên Wavelet [72] là:

- Hàm ngưỡng cứng (Hard Thresholding)
- Hàm ngưỡng mềm (Soft Thresholding)

Hai phương pháp này khác nhau ở cách xử lý các hệ số Wavelet nhỏ hơn ngưỡng, từ đó ảnh hưởng trực tiếp đến hiệu quả triệt nhiễu và khả năng bảo toàn chi tiết ảnh.

Hàm ngưỡng cứng được xác định theo công thức (3.4)

$$\hat{w}_{i,j} = \begin{cases} w_{ij}, & \text{nếu } w_{ij} > \lambda \\ 0, & \text{ngược lại} \end{cases} \quad (3.4)$$

Hàm ngưỡng mềm được xác định theo công thức (3.5)

$$\hat{w}_{i,j} = \begin{cases} w_{ij} - \lambda & \text{nếu } w_{ij} > \lambda \\ w_{ij} + \lambda & \text{nếu } w_{ij} < -\lambda \\ 0, & \text{ngược lại} \end{cases} \quad (3.5)$$

Trong đó: w_{ij} là hệ số wavelet gốc, $\hat{w}_{i,j}$ là hệ số sau khi áp dụng hàm ngưỡng, và λ là giá trị ngưỡng.

Hàm ngưỡng cứng và hàm ngưỡng mềm $\hat{w}_{i,j}$ lần lượt được minh họa trong Hình 3.7.a và 3.7.b.

Đề xuất hàm ngưỡng dựa trên hàm co ngưỡng kép (Dual-threshold shrinkage function- DuTS):

Nhằm giảm thiểu các hiện tượng tạo nhiễu giả do các hàm co ngưỡng truyền thống gây ra, hàm DuTS được đề xuất trong [73] đã giải quyết vấn đề như sau:


- Giữ nguyên các hệ số có biên độ lớn;
- Loại bỏ hoàn toàn các hệ số có biên độ rất nhỏ;
- Đối với các hệ số nằm giữa hai giá trị ngưỡng λ_1, λ_2 , áp dụng hàm suy giảm tuyến tính từng đoạn (piecewise linear attenuation), trong đó các hệ số nhỏ hơn trong khoảng này sẽ bị suy giảm mạnh hơn.

Hàm ngưỡng được đề xuất dựa trên hàm ngưỡng DuTS được biểu diễn trong công thức (3.6) và (3.7).

$$\hat{w}_{i,j}(\lambda_1, \lambda_2) = \begin{cases} w_{ij} & \text{nếu } |w_{ij}| > \lambda_2 \\ \text{sign}(w_{ij})A(w_{ij}) & \text{nếu } \lambda_1 < |w_{ij}| < \lambda_2 \\ 0, & \text{ngược lại} \end{cases} \quad (3.6)$$

$$A(w_{i,j}) = \frac{\lambda_1 \lambda_2 (|w_{i,j}| - \lambda_1)}{\lambda_2 - \lambda_1} \quad (3.7)$$

Trong đó: $\text{sign}(w_{i,j})$ là dấu của hệ số wavelet $w_{i,j}$. $\lambda_2 = \kappa \lambda_1, \kappa \in \mathbb{C}$ and $\kappa \neq 1$. Hàm ngưỡng DuTS $\hat{w}(\lambda_1, \lambda_2)$ được minh họa trên **Hình 3.7.c**.



Hình 3.7 Các hàm ngưỡng được áp dụng cho các hệ số wavelet

• Xác định giá trị ngưỡng thích hợp

Ngưỡng BayesShrink (BayesShrink Threshold):

Dựa trên đặc trưng thống kê của các hệ số wavelet trong ảnh tự nhiên, nghiên cứu [74] đã đề xuất phương pháp ước lượng ngưỡng BayesShrink.

Phương pháp này giả định rằng các hệ số wavelet của ảnh không nhiễu tuân theo phân bố Gaussian tổng quát (Generalized Gaussian Distribution – GGD). Các nghiên cứu thực nghiệm cho thấy rằng, ngoại trừ dải con LL, phần lớn các hệ số wavelet trong ảnh tự nhiên có phân bố đối xứng quanh giá trị 0, với đỉnh nhọn tại gốc tọa độ (sharp peak at the origin). Do đó, chúng có thể được mô hình hóa hiệu quả bằng GGD có trung bình bằng 0.

Ngưỡng BayesShrink được xây dựng trong khuôn khổ Bayes nhằm đạt được hiệu suất khử nhiễu tối ưu dựa trên giả định này. Cụ thể, nếu giả định rằng các hệ số wavelet tuân theo phân bố Gaussian tổng quát, thì ngưỡng tối ưu có thể được suy ra theo tiêu chuẩn ước lượng Bayes, và được biểu diễn bằng công thức sau:

$$\lambda = \frac{\hat{\sigma}_w^2}{\hat{\sigma}_x} \quad (3.8)$$

Trong đó: $\hat{\sigma}_w$ được xác định theo công thức sau:

$$\hat{\sigma}_w = \frac{\text{Median}(|C_{i,j}|)}{0.6745}, \quad C_{i,j} \in HH^1 \quad (3.9), \text{ và } \hat{\sigma}_x \text{ biểu thị tham số ước lượng được suy}$$

ra từ các hệ số wavelet trong từng dải con. Giá trị của $\hat{\sigma}_x$ được tính theo công thức (3.10) và (3.11).

$$\hat{\sigma}_x = \sqrt{\max(\hat{\sigma}_y^2 - \hat{\sigma}_w^2, 0)} \quad (3.10)$$

$$\hat{\sigma}_y = \frac{1}{n^2} \sum_{j,k=1}^n C_{j,k}^2 \quad (3.11)$$

• Đề xuất phương pháp ước lượng ngưỡng dựa trên cách tiếp cận BayesShrink

Như được trình bày trong công thức (3.8) và (3.10), ngưỡng thích hợp dựa trên

nguyên lý ước lượng Bayes được xác định trong phương trình (3.12):

$$\lambda = \frac{\hat{\sigma}_w^2}{\hat{\sigma}_x} = \frac{\hat{\sigma}_w^2}{\sqrt{\max(\hat{\sigma}_y^2 - \hat{\sigma}_w^2, 0)}} \quad (3.12)$$

Nếu $\hat{\sigma}_y^2 \leq \hat{\sigma}_w^2$ thì $\hat{\sigma}_x = 0$. Trong trường hợp này, giá trị của λ là không xác định ($\lambda \rightarrow \infty$). Kết quả là không thể xác định được giá trị ngưỡng thích hợp cho quá trình khử nhiễu ảnh. Để khắc phục nhược điểm này, luận án đề xuất ngưỡng λ_1 , được xác định theo công thức (3.13).

$$\lambda_1 = \begin{cases} \beta \frac{\hat{\sigma}_w^2}{\hat{\sigma}_x}, & \text{if } \hat{\sigma}_y^2 > \hat{\sigma}_w^2 \\ \max_{j,k=1,\dots,n} \{C_{j,k}\}, & \text{ngược lại} \end{cases} \quad (3.13)$$

Trong đó: tham số tỉ lệ β được xác định theo công thức:

$$\beta = \sqrt{\log \left(\frac{L_k}{J} \right)} \quad (3.14)$$

Trong đó: L_k biểu thị độ dài của dải con tương ứng với mức phân rã thứ k

Hệ số k trong (3.13) được gán các giá trị lần lượt là 2, 3, 4, 5, 6 và 10, nhằm đánh giá hiệu năng khử nhiễu của ảnh trong các điều kiện khác nhau.

• **Thuật toán: Khử nhiễu ảnh cây trồng do robot di động thu thập tại các cụm cảm biến trong nhà kính nông nghiệp**

Đầu vào: Ảnh gốc: $g_{i,j}, \{i, j = 1, 2, \dots, N\}$; Nhiễu cộng: $\eta_{i,j}, \{i, j = 1, 2, \dots, N\}$; Tổng số mức phân tích đa tỉ lệ của ảnh: J ; Giá trị hệ số: κ .

Đầu ra: Ảnh đã khử nhiễu: $\hat{g}_{i,j}, \{i, j = 1, 2, \dots, N\}$;

- 1: Thực hiện phân tích đa tỉ lệ cho ảnh bị suy giảm do nhiễu Gauss bằng phép biến đổi wavelet.
- 2: Ước lượng phương sai nhiễu $\hat{\sigma}_w$ tại cấp đầu tiên của phép phân tích biến đổi Wavelet bằng công thức (3.9).
- 3: Tại thang phụ $k^{th}, \{k = 1, 2, \dots, J\}$
 - Tính tham số tỉ lệ β bằng công thức (3.14).
 - Tính độ lệch chuẩn $\hat{\sigma}_x$ bằng công thức (3.10) và (3.11).
 - Tính ngưỡng λ_1 bằng công thức (3.13).
 - Áp dụng kỹ thuật làm mềm ngưỡng cho các hệ số nhiễu bằng công thức (3.5).
- 4: Thực hiện phép nghịch biến đổi wavelet đa tỉ lệ để tái tạo lại ảnh đã khử nhiễu $\hat{g}$
- 5: Thuật toán kết thúc với ảnh $\hat{g}$ nếu công thức (3.2) được thỏa mãn.

3.2.3 Mô phỏng và đánh giá kết quả

Hiệu suất của kết quả thực nghiệm được đánh giá định lượng bằng cách sử dụng tỷ số tín hiệu trên nhiễu đỉnh (PSNR) [74] và thời gian tính toán. PSNR được biểu thị bằng decibel (dB), trong khi thời gian tính toán được đo bằng giây và được định nghĩa như sau:

$$PSNR = 10 * \log_{10} \left[\frac{255^2 \times N^2}{\sum_{i,j=1}^N (g_{i,j} - \hat{g}_{i,j})^2} \right] \quad (3.15)$$

Để kiểm chứng hiệu quả của phương pháp khử nhiễu ảnh được đề xuất, trong luận án đã sử dụng bộ dữ liệu công khai PlantVillage [75], được thu thập bằng điện thoại thông minh và bao gồm 54306 ảnh của lá cây khỏe mạnh và bị bệnh, được ghi nhận trong điều kiện có kiểm soát.


Các ảnh này được thay đổi kích thước về 640x640 pixel và được phân loại thành 38 nhóm bệnh - cây trồng khác nhau. Sau đó, chúng được chuyển đổi thành ba định dạng dữ liệu riêng biệt: ảnh màu, ảnh thang xám và ảnh đã được phân đoạn.

Thiết lập mô phỏng thử nghiệm được sử dụng trong nghiên cứu này như sau: nền tảng tính toán bao gồm CPU Intel i7-7500 chạy ở 2,70 GHz, RAM 8,0 GB, và card đồ họa Intel Radeon R5 M430 (2 GB), Intel Graphics 620 (128 MB), mô phỏng trên phần mềm MATLAB R2022a.


Bộ ảnh gốc không bị nhiễu G được thể hiện trên Hình 3.8. Các thí nghiệm được tiến hành trên các ảnh bị nhiễu bởi nhiễu Gaussian trắng cộng (Additive White Gaussian Noise – AWGN), với mức nhiễu lần lượt là 0,01; 0,02; 0,03 và 0,04 (Hình 3.9) .

Để đánh giá toàn diện phương pháp khử nhiễu ảnh mà luận án đề xuất được đặt tên là OP (our proposed image denoising method) với các kỹ thuật khử nhiễu sau đây đã được sử dụng để so sánh trong quá trình phân tích mô phỏng thử nghiệm: Bayes Shrink (BS), Normal Shrink (NS), Adaptive Image (AI).

Kết quả khử nhiễu trên các ảnh kiểm thử được minh họa trong Hình 3.10.



Hình 3.8 Các ảnh thử nghiệm gốc (không nhiễu)




Hình 3.9 Các ảnh thử nghiệm với các mức nhiễu khác nhau: (a) $\sigma = 0,01$, (b) 0,02, (c) 0,03 và (d) 0,04



Hình 3.10 Kết quả khử nhiễu trên các ảnh thử nghiệm với mức nhiễu $\sigma = 0,01$ bằng các phương pháp: (a) BS, (b) NS, (c) AI, (d) OP.

Từ góc độ trực quan, cả bốn phương pháp khử nhiễu đều thể hiện khả năng giảm nhiễu nhất định. Tuy nhiên, khi so sánh các ảnh sau khử nhiễu, có thể nhận thấy rằng các phương pháp BS và NS cho hiệu quả kém hơn, do kết quả của chúng vẫn còn nhiều nhiễu dư và hình ảnh trở nên mờ hơn rõ rệt. Trong khi đó, các phương pháp AI và OP đạt được chất lượng hình ảnh trực quan cao hơn so với các phương pháp BS và NS.



Hình 3.11 Kết quả khử nhiễu trên lá cà chua

Để đánh giá khách quan hiệu suất của các thuật toán khử nhiễu, tỷ lệ tín hiệu trên nhiễu đỉnh (PSNR) của các ảnh thử nghiệm thu được bằng bốn phương pháp khử nhiễu khác nhau được trình bày trong Bảng 3.2. Mỗi giá trị đại diện cho kết quả trung bình của 50 lần chạy thử nghiệm độc lập. Từ các kết quả PSNR trình bày trong Bảng 3.2, có thể thấy rằng đối với các ảnh tiêu chuẩn có chất lượng thị giác cao, các giá trị PSNR thu được bởi cả bốn phương pháp khử nhiễu đều lớn hơn so với các giá trị đạt được trên ảnh cây cà chua trong bộ dữ liệu ở [75].

Hơn nữa, các giá trị PSNR tăng đáng kể, khoảng 4-8 dB, khi các phương pháp khử nhiễu được áp dụng cho các ảnh có mật độ nhiễu cao hơn. Kết quả PSNR thu được bằng phương pháp đề xuất của chúng tôi cũng cho thấy mức cải thiện trung bình khoảng 3,70 và 5,93% so với các phương pháp NS và BS, tương ứng. Với độ lệch PSNR chỉ 0,34%, có thể thấy mức độ tương đồng cao trong hiệu suất khử nhiễu giữa phương pháp OP và AI. Điều này cho thấy hiệu quả vượt trội của kỹ thuật khử nhiễu ảnh của OP, vốn dựa trên nguyên lý Bayes với ngưỡng được lựa chọn tối ưu.

Bảng 3.2 So sánh hiệu suất PSNR (dB) giữa các kỹ thuật ngưỡng wavelet khác nhau đối với các ảnh bị suy giảm bởi nhiễu Gaussian

Ảnh	Giá trị nhiễu	BS	NS	AI	OP
Người chụp ảnh	0,01	32,831	33,521	33,685	33,817
	0,02	30,158	30,637	31,577	31,273
	0,03	27,665	28,128	29,354	29,417
	0,04	26,318	26,839	27,519	27,382
Ngôi nhà	0,01	33,594	34,211	35,274	35,170
	0,02	31,072	31,712	32,172	32,451
	0,03	28,467	29,187	30,661	30,184
	0,04	26,818	27,088	28,497	28,167
Lena	0,01	32,751	33,837	34,671	34,114
	0,02	29,703	30,265	31,882	31,630
	0,03	27,844	28,475	29,641	29,381
	0,04	26,184	26,917	27,518	27,624
Quả ớt	0,01	32,761	33,633	34,287	34,306
	0,02	29,733	30,208	31,570	31,427
	0,03	27,056	27,817	28,611	28,439
	0,04	25,917	26,566	27,488	27,371
Cà chua 1	0,01	30,729	31,375	33,084	33,126
	0,02	28,457	29,429	31,211	31,330
	0,03	26,914	27,099	28,634	28,718
	0,04	24,866	25,118	26,871	26,655
Cà chua 2	0,01	29,515	30,738	31,973	31,873
	0,02	27,773	28,457	29,810	29,764
	0,03	26,874	27,184	28,665	28,477
	0,04	25,118	25,867	26,440	26,394
Cà chua 3	0,01	30,657	31,266	33,054	33,121
	0,02	28,443	29,567	31,261	31,176
	0,03	26,965	27,335	28,647	28,553
	0,04	25,143	25,473	26,848	26,176
Cà chua 4	0,01	31,518	32,068	33,718	33,613
	0,02	29,356	30,117	31,553	31,378
	0,03	27,084	27,436	28,377	28,410
	0,04	25,277	25,618	26,618	26,578

Thông qua các kết quả mô phỏng thử nghiệm cho thấy thuật toán OP được đề xuất mang lại hiệu suất khử nhiễu vượt trội, cả chủ quan về mặt chất lượng thị giác lẫn cơ sở tính toán theo giá trị PSNR. Ngược lại, các thuật toán BS và NS cho thấy hiệu suất thấp hơn so với các phương pháp AI và OP, mặc dù các giá trị PSNR của chúng vẫn nằm trong phạm vi chấp nhận được.

Sau khi quá trình khử nhiễu được thực hiện nhằm cải thiện chất lượng ảnh đầu vào, bộ dữ liệu hình ảnh cây trồng thu được có độ tin cậy cao hơn cho các bước xử lý thị giác máy tính tiếp theo. Chất lượng ảnh được nâng cao không chỉ giúp giảm sai lệch trong quá trình trích xuất đặc trưng, mà còn tạo nền tảng vững chắc cho việc áp

dụng các mô hình nhận dạng dựa trên trí tuệ nhân tạo. Trên cơ sở đó, luận án tiếp tục triển khai các thuật toán học sâu để phân loại và phát hiện các biểu hiện bất thường trên cây trồng. Việc kết hợp khử nhiễu ảnh với nhận diện hình ảnh trên cơ sở trí tuệ nhân tạo cho phép xây dựng một quy trình giám sát sự phát triển của cây trồng chính xác hơn, hỗ trợ phát hiện sớm sâu bệnh và các dấu hiệu suy giảm sức khỏe cây trồng trong điều kiện nông nghiệp có môi trường biến động.

3.3 Nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp trên cơ sở trí tuệ nhân tạo

3.3.1 Các phương pháp phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp

Hiện nay, có 3 nhóm phương pháp phát hiện sâu bệnh cây trồng:

➤ Nhóm phương pháp truyền thống bao gồm: quan sát trực tiếp, bẫy, bắt thủ công. Nhóm phương pháp này có ưu điểm đơn giản, chi phí thấp, dễ áp dụng nông hộ. Tuy nhiên, cách này tốn thời gian, phụ thuộc kinh nghiệm, dễ sai sót, phát hiện chậm.

➤ Nhóm phương pháp sinh học- phân tử: Nhóm này sử dụng các kỹ thuật huyết thanh học, sinh học phân tử và giải trình tự. Ưu điểm của nhóm phương pháp này là có độ chính xác cao, phát hiện sớm ngay cả khi chưa có triệu chứng rõ rệt nhưng chi phí cao, cần phòng thí nghiệm và chuyên gia.


➤ Nhóm phương pháp công nghệ cao- trí tuệ nhân tạo: bằng cách sử dụng cảm biến, IoT, thị giác máy tính và một số các thiết bị công nghệ khác. Đây là nhóm phương pháp được ứng dụng rộng rãi hiện nay bởi có tính ưu việt như giám sát diện rộng, tự động, cảnh báo sớm và tích hợp dữ liệu lớn. Tuy nhiên đòi hỏi chi phí đầu tư cao, cần hạ tầng và kỹ năng công nghệ.

Với ưu điểm của nhóm phương pháp công nghệ cao và trí tuệ nhân tạo, luận án lựa chọn và tập trung nghiên cứu mô hình trí tuệ nhân tạo (AI) phục vụ giám sát sự phát triển của cây trồng trong nông nghiệp, ưu tiên phát hiện sâu bệnh cây trồng.

3.3.2 Mô hình AI sử dụng trong phát hiện sâu bệnh trên cây trồng

a) Giới thiệu cấu trúc của mạng nơ-ron tích chập (Convolutional Neural Network-CNN)

Cấu trúc cơ bản của mạng CNN thường bao gồm năm thành phần chính: lớp đầu vào (Input Layer), lớp tích chập (Convolutional Layer), lớp gộp (Pooling Layer), lớp kết nối đầy đủ (Fully Connected Layer) và lớp đầu ra (Output Layer) (Hình 3.12).



Hình 3.12 Kiến trúc của CNN cơ bản [76]

- *Lớp đầu vào (Input Layer):*

Tiếp nhận dữ liệu thô, thường là hình ảnh được biểu diễn dưới dạng ma trận điểm ảnh (pixel values). Đây là nền tảng cho toàn bộ quá trình trích xuất và xử lý đặc trưng.

- *Lớp tích chập (Convolutional Layer):*

Thành phần cốt lõi của CNN, chịu trách nhiệm trích xuất đặc trưng từ dữ liệu đầu vào thông qua các bộ lọc (kernel/filter). Mỗi bộ lọc tập trung phát hiện một dạng đặc trưng khác nhau. Các lớp tích chập ban đầu thường phát hiện các đặc trưng đơn giản như biên, cạnh, họa tiết. Các lớp sâu hơn học được các đặc trưng trừu tượng và giàu ngữ nghĩa hơn, phục vụ cho việc phân loại và nhận dạng.

- *Lớp gộp (Pooling Layer):*

Thực hiện giảm kích thước không gian của bản đồ đặc trưng (feature maps) bằng cách tổng hợp thông tin trong một vùng cục bộ, thường sử dụng các phép Max-pooling hoặc Average-pooling. Mục tiêu là giảm số lượng tham số, tăng tính khái quát và hạn chế hiện tượng overfitting.

- *Lớp kết nối đầy đủ (Fully Connected Layer):*

Là lớp mạng nơ-ron truyền thống, nơi tất cả các nút được kết nối đầy đủ. Lớp này có nhiệm vụ kết hợp và ánh xạ các đặc trưng đã học từ các lớp trước thành các biểu diễn mức cao, làm cơ sở cho việc phân loại.

- *Lớp đầu ra (Output Layer):*


Thành phần cuối cùng của CNN, thường sử dụng các hàm kích hoạt như Softmax hoặc Sigmoid để đưa ra xác suất phân loại đối tượng hoặc dự đoán nhãn đầu ra.

b) *Phân loại mô hình CNN*

Mô hình CNN trong phát hiện sâu bệnh cây trồng bao gồm mô hình CNN phân loại ảnh và mô hình CNN phát hiện đối tượng trong ảnh. Trong luận án này, NCS tập trung nghiên cứu mô hình CNN phát hiện đối tượng trong ảnh.

Trong các kỹ thuật phát hiện đối tượng dựa trên mạng nơ-ron tích chập (CNN), cấu trúc tổng thể thường chia sẻ những thành phần cơ bản nhằm hướng

tới mục tiêu chung là phân loại và nhận dạng hình ảnh. Một mô hình phát hiện đối tượng điển hình thường bao gồm bốn thành phần chính: Đầu vào (Input), Xương sống (Backbone), Cổ (Neck) và Đầu (Head) (Hình 3.13) [77].



Hình 3.13 Kiến trúc chính của các mô hình phát hiện đối tượng [77]

1) Đầu vào (Input):

Là dữ liệu hình ảnh hoặc video cung cấp cho mô hình, có thể ở dạng ảnh tĩnh hoặc chuỗi khung hình thời gian thực, tùy thuộc vào mục đích ứng dụng.

2) Xương sống (Backbone):

Đây là thành phần cốt lõi, chịu trách nhiệm trích xuất bản đồ đặc trưng từ dữ liệu đầu vào thông qua các lớp tích chập. Các đặc trưng thu được đóng vai trò quan trọng trong việc nhận diện các đối tượng trong ảnh. Một số mạng CNN phổ biến thường đảm nhận vai trò này gồm VGG16, ResNet-50, Darknet53, CSPDarknet53.

3) Cổ (Neck):

Thành phần trung gian giúp củng cố và kết hợp đặc trưng từ nhiều cấp độ không gian khác nhau. Neck thường được sử dụng để cải thiện khả năng phân biệt đặc trưng và tăng độ bền vững của mô hình. Các kiến trúc tiêu biểu trong phần này gồm FPN (Feature Pyramid Network), PANet (Path Aggregation Network) và Bi-FPN (Bidirectional FPN).

4) Đầu (Head):

Là lớp xử lý cuối cùng, nơi diễn ra quá trình dự đoán và phân loại đối tượng. Có hai dạng chính:

- Single-stage detector (ví dụ: SSD, YOLO) – dự đoán trực tiếp từ bản đồ đặc trưng mà không cần giai đoạn trung gian.


- Two-stage detector (ví dụ: Faster R-CNN, Mask R-CNN) – hoạt động qua hai bước: sinh vùng quan tâm (Region Proposal) và phân loại đối tượng trong các vùng này.

YOLO (You Only Look Once) là một mô hình phát hiện đối tượng và phân đoạn hình ảnh phổ biến nhờ tốc độ và độ chính xác cao. Luận án lựa chọn và tập trung nghiên cứu mô hình YOLO cho bài toán nâng cao chất lượng phát hiện sâu

bệnh trên cây trồng trong nhà kính. Nội dung và kết quả nghiên cứu của luận án được trình bày trong các mục tiếp theo của chương này.


3.3.3 Mô hình YOLO trong phát hiện sâu bệnh cây trồng

YOLO là một kiến trúc mạng nơ-ron sâu được thiết kế để thực hiện tác vụ phát hiện đối tượng bằng cách dự đoán các hộp giới hạn (bounding boxes) và xác suất lớp (class probabilities) trực tiếp từ một hình ảnh duy nhất trong một lần truyền qua mạng (Hình 3.14)



Hình 3.14 Phát hiện vật thể bằng mô hình YOLO [78]

Khác với các phương pháp hai giai đoạn (two-stage detectors) như R-CNN, Faster R-CNN thì YOLO thực hiện cả phân loại và định vị đối tượng đồng thời, từ đó mang lại tốc độ xử lý vượt trội, rất phù hợp cho các ứng dụng đòi hỏi tính thời gian thực. Từ năm 2015 đến nay, YOLO ra mắt nhiều phiên bản khác nhau (Hình 3.15), phiên bản ra đời sau sẽ có ưu điểm hơn phiên bản trước.



Hình 3.15 Lịch sử phát triển các phiên bản YOLO [79]

Trong số nhiều kiến trúc thị giác máy tính, dòng YOLO đã khẳng định vị thế là một trong những khung mô hình hiệu quả nhất cho phát hiện đối tượng theo thời gian thực. Các biến thể YOLO đã được ứng dụng thành công trong nông nghiệp thông minh [80], đặc biệt là trong nhận dạng sâu bệnh cây trồng trên các loại cây trồng như lúa, lúa mì, cà chua, dưa chuột và nho [81-85]. Với ưu thế về tốc độ xử lý và độ chính

xác cao, các mô hình dựa trên YOLO đã thu hút sự quan tâm lớn trong các nhiệm vụ phát hiện bệnh theo thời gian thực.

Nghiên cứu [86] đã so sánh giữa các phiên bản YOLO khác nhau đã chứng minh tính khả thi của việc sử dụng YOLO trong chẩn đoán sâu bệnh cây trồng. Trong nghiên cứu [87], YOLOv5 được áp dụng để nhận diện nhiều loại bệnh trên lá dưa chuột dưới các điều kiện môi trường khác nhau, cho thấy độ chính xác phát hiện cao trong khi vẫn duy trì chi phí tính toán thấp.

Những cải tiến gần đây trong phát hiện sâu bệnh cây trồng dựa trên YOLO đã tích hợp các kỹ thuật tiên tiến như cơ chế chú ý (attention mechanisms) và tổng hợp đặc trưng (feature fusion) nhằm nâng cao hiệu năng nhận dạng. Cụ thể, một biến thể YOLOv7 được bổ sung cơ chế chú ý theo kênh đã được đề xuất để tăng độ chính xác trong phát hiện bệnh lá cà chua [88]. Tương tự, các mô hình YOLOv8 tích hợp cơ chế tổng hợp đặc trưng đa tỉ lệ đã chứng minh tính ổn định trong phát hiện bệnh dưa chuột ngay cả trong điều kiện ánh sáng phức tạp [89]. Những cải tiến này từ việc tái cấu trúc kiến trúc đến tối ưu hóa đặc trưng đã đồng thời góp phần nâng cao hiệu quả của YOLO trong các tác vụ nông nghiệp có độ phức tạp cao [90-93].


Đến nay, YOLO đã trải qua mười hai phiên bản, với các cải tiến liên tiếp chủ yếu tập trung vào tối ưu hóa kiến trúc và thuật toán để nâng cao độ chính xác phát hiện [94]. Phần lớn nghiên cứu tập trung vào việc chỉnh sửa xương sống mạng, thiết kế lớp chú ý và cải tiến hàm mất mát [95–97]. Tuy nhiên, các nghiên cứu về hàm kích hoạt vốn giữ vai trò then chốt trong động lực học của mạng nơ-ron sâu vẫn còn tương đối hạn chế. Trong khi các hàm kích hoạt như ReLU, LeakyReLU và Mish thường được sử dụng trong các phiên bản YOLO trước đây, các nghiên cứu gần đây đã khai thác hàm SiLU nhờ đặc tính đầu ra mượt mà, tạo điều kiện cho sự lan truyền gradient ổn định và quá trình hội tụ nhanh hơn [98]. Sự chuyển dịch này đã đóng góp đáng kể vào việc nâng cao độ chính xác phát hiện bệnh trên cây trồng. Với phân tích và đánh giá trên, luận án nghiên cứu và đề xuất cải tiến mô hình YOLO, tập trung vào hiệu chỉnh hàm kích hoạt nhằm nâng cao hiệu suất nhận diện hình ảnh, từ đó nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nông nghiệp.

3.3.4 Cải tiến mô hình YOLO nhằm nâng cao chất lượng phát hiện sâu bệnh cây trồng

a) Mô hình YOLOv11

Mô hình YOLOv11, như được giới thiệu trong [99], mang đến những cải tiến đáng kể về kiến trúc, bao gồm một bộ xương (backbone) tối ưu hóa, cơ chế chú ý tiên tiến và các kỹ thuật kết hợp đặc trưng hiệu quả hơn. Những cải tiến này giúp nâng cao hiệu suất trong nhiều tác vụ thị giác phức tạp. YOLOv11 đại diện cho một bước tiến

đáng kể trong phát hiện đối tượng, mang lại khả năng mở rộng, hiệu quả và tính linh hoạt trong các nhiệm vụ cao hơn. Với các biến thể mô hình từ nano đến siêu lớn, YOLOv11 có khả năng thích ứng tốt trong các bối cảnh triển khai khác nhau, từ các thiết bị biên có công suất thấp đến các môi trường tính toán hiệu suất cao. Phiên bản nano, đạt được những cải tiến đáng kể về tốc độ suy luận và khả năng phản hồi, khiến nó trở thành lựa chọn rất phù hợp cho các ứng dụng thời gian thực.



Hình 3.16 Kiến trúc tổng thể của mô hình YOLOv11 [99].

Kiến trúc của mô hình YOLOv11, như được minh họa trong Hình 3.16 và có các đổi mới kiến trúc chủ yếu như sau:


- **Backbone:** Bộ xương của YOLOv11 được thiết kế tỉ mỉ để trích xuất các đại diện đặc trưng một cách hiệu quả ở nhiều tỷ lệ khác nhau. Một cải tiến quan trọng là

sự ra mắt của khối C3k2 (khối Cross Stage Partial với kích thước kernel là 2), thay thế cho khối C2f trước đó. Khối này sử dụng hai phép tích chập nhỏ thay vì một phép tích chập lớn, giúp tăng tốc quá trình xử lý trong khi vẫn duy trì khả năng đại diện của mô hình. Thêm vào đó, YOLOv11 tiếp tục sử dụng mô-đun Spatial Pyramid Pooling - Fast (SPPF) để kết hợp đặc trưng đa tỷ lệ, được tăng cường bởi sự tích hợp của khối C2PSA (Cross Stage Partial với Parallel Spatial Attention). Khối C2PSA tận dụng cơ chế chú ý không gian để hướng sự tập trung của mô hình vào các vùng nổi bật của hình ảnh, từ đó cải thiện độ chính xác phát hiện, đặc biệt là đối với các đối tượng có kích thước khác nhau hoặc những đối tượng bị che khuất một phần.

- Neck: Trong YOLOv11, phần neck đóng vai trò là giai đoạn nơi các đặc trưng từ các tỷ lệ khác nhau được kết hợp và tinh chỉnh trước khi được chuyển đến phần head. Tương tự như phần backbone, YOLOv11 thay thế khối C2f bằng khối C3k2 hiệu quả về mặt tính toán hơn tại giai đoạn này. Hơn nữa, việc tích hợp cơ chế chú ý không gian qua mô-đun C2PSA giúp mô hình ưu tiên và nhấn mạnh thông tin không gian quan trọng, từ đó nâng cao độ bền và độ chính xác của quá trình phát hiện.


- Head: Phần head của YOLOv11 bao gồm nhiều khối C3k2 để xử lý các đại diện đặc trưng đã được tinh chỉnh ở các chiều sâu khác nhau, cân bằng hiệu quả tham số và khả năng biểu diễn của mô hình. Nó cũng tích hợp các khối CBS (Convolution-BatchNorm-SiLU), giúp ổn định quá trình huấn luyện thông qua việc chuẩn hóa và áp dụng hàm kích hoạt SiLU để tăng cường tính phi tuyến tính và cải thiện chất lượng trích xuất đặc trưng. Dự đoán cuối cùng được tạo ra thông qua các lớp tích chập kết hợp với lớp Detect, sản sinh ra tọa độ hộp giới hạn, điểm tin cậy đối tượng và xác suất các lớp.

Trong cấu trúc các lớp trong phần xương sống của mô hình YOLOv11 (Hình 3.17), tại lớp tích chập (Convolution- Conv) cho phép trích xuất đặc trưng quan trọng từ dữ liệu đầu vào, mỗi lớp có kiến trúc như Hình 3.18.



Hình 3.17 Chi tiết cấu trúc các lớp trong phần xương sống của mô hình YOLOv11 [91]

Một lớp tích chập



Hình 3.18 Lớp tích chập hoàn chỉnh với độ lệch b và hàm kích hoạt SiLU [100]

Để cải tiến cấu trúc của mô hình YOLO nhằm nâng cao hiệu suất của mô hình trong quá trình phát hiện đối tượng trong ảnh hay chính là phát hiện sâu bệnh cây trồng, luận án đề xuất cải tiến hàm kích hoạt SiLU trong mô hình YOLO.

b) Đề xuất hàm kích hoạt cải tiến mô hình YOLO

Hàm kích hoạt SiLU (Sigmoid-weighted Linear Unit), còn được gọi là Swish-1, đã trở thành hàm kích hoạt mặc định trong các phiên bản YOLO từ v5 đến v12. Hàm này mang lại sự cân bằng tối ưu giữa tính phi tuyến trong biểu diễn và hiệu quả tính toán, nhờ đó phù hợp với nhiều nhiệm vụ trong thị giác máy tính. Tuy nhiên, bên cạnh những ưu điểm thực tiễn, SiLU vẫn tồn tại một số hạn chế, trong đó đáng chú ý là dạng hàm cố định, có thể làm giảm khả năng thích ứng khi mô hình được áp dụng cho các phân phối dữ liệu đa dạng.

- Hàm SiLU (Sigmoid-weighted Linear Unit): là một loại hàm kích hoạt đã chứng minh hiệu quả đặc biệt trong việc xấp xỉ hàm trong các mạng nơ-ron, đặc biệt là trong học tăng cường.

SiLU được tính toán bằng cách nhân đầu vào của một đơn vị với đầu ra của hàm sigmoid áp dụng cho đầu vào đó [101]:

$$\alpha_k(x) = x \cdot \sigma(x) \quad (3.16)$$

Trong đó, x đại diện cho đầu vào của đơn vị và $\sigma(x)$ là hàm sigmoid. Hàm sigmoid được định nghĩa như sau:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.17)$$

Tuy nhiên, hàm SiLU có khả năng thích ứng với các phân phối dữ liệu khác nhau bị hạn chế và cơ chế phản ứng của nó khi xử lý các đầu vào có giá trị tuyệt đối lớn. Trên cơ sở này, luận án đề xuất hàm SiLU mới được gọi là hàm α SiLU.

- **Đề xuất hàm α SiLU:** là một biến thể của SiLU với tham số tỷ lệ α , cho phép điều chỉnh gradient một cách thích nghi. Hàm α SiLU được xác định:

$$f(x) = x\alpha \frac{1}{1 + e^{-\alpha x}} = \alpha x \cdot \text{sigmoid}(\alpha x) = \alpha x \cdot \sigma(\alpha x) \quad (3.18)$$


Đạo hàm của α SiLU:

$$\begin{aligned} f'(x) &= \alpha \frac{1}{1 + e^{-\alpha x}} + \alpha x \frac{\alpha e^{-\alpha x}}{(1 + e^{-\alpha x})^2} \\ &= \alpha \sigma(\alpha x) + \alpha^2 x (\sigma(\alpha x) - \sigma^2(\alpha x)) \\ &= \alpha [f(x) + \sigma(\alpha x)(1 - f(x))] \end{aligned} \quad (3.19)$$

Trong đó, $\sigma(x)$ đại diện cho hàm sigmoid, và α là tham số có thể điều chỉnh, kiểm soát độ dốc của hàm kích hoạt.

Hình 3.19a,b mô tả hành vi của hàm α -SiLU và đạo hàm của nó ứng với các giá trị α khác nhau. Như minh họa ở Hình 3.19a, khi α tăng, độ dốc của hàm trở nên lớn hơn, làm tăng đặc tính phi tuyến của hàm. Ngược lại, các giá trị α nhỏ hơn dẫn đến phản ứng mượt mà hơn, điều này có thể hữu ích trong việc giảm độ nhạy đối với nhiễu đầu vào. Hình 3.19b thể hiện các đạo hàm tương ứng: α lớn tạo ra gradient sắc

nét hơn, từ đó thúc đẩy động lực huấn luyện nhanh hơn; trong khi các giá trị nhỏ làm chậm tốc độ cập nhật, qua đó có thể cải thiện tính ổn định trong huấn luyện và giảm thiểu hiện tượng overfitting.



Hình 3.19 Mối quan hệ của α với hàm α SiLU (a) và đạo hàm của nó (b).

Bảng 3.3: Tóm tắt các đặc điểm chính khi so sánh các hàm kích hoạt cơ bản.

Hàm kích hoạt	Biểu thức	Đạo hàm	Phi tuyến
ReLU	$\max(0, x)$	1 nếu $x > 0$, 0 nếu $x \leq 0$	có
LeakyReLU	$\max(\alpha x, x)$	1 hoặc α	có
Mish	$x \cdot \tanh(\ln(1 + e^x))$	$\tanh(\ln(1 + e^x)) + x \cdot \sigma(x) \cdot (1 - \tanh^2(\ln(1 + e^x)))$	có
GELU	$x \cdot \phi(x)$ (Trong đó $\phi(x)$ là Gaussian PDF)	$\phi(x) + x \cdot \phi(x)$ (Trong đó $\phi(x)$ là Gaussian PDF)	có
ELU	x nếu $x > 0$, $\alpha(e^x - 1)$ nếu $x \leq 0$	1 nếu $x > 0$, αe^x nếu $x \leq 0$	có
SiLU	$x \cdot \sigma(x)$	$\sigma(x) + x\sigma(x)(1 - \sigma(x))$	có
α SiLU	$\alpha x \cdot \sigma(\alpha x)$	$\alpha\sigma(\alpha x) + \alpha^2 x\sigma(\alpha x)(1 - \sigma(\alpha x))$	có

Bảng 3.3 so sánh các thuộc tính chính của các hàm kích hoạt phổ biến thường được sử dụng trong các kiến trúc phát hiện đối tượng hiện đại. Hàm kích hoạt α SiLU được đề xuất cho thấy những lợi thế rõ rệt so với SiLU truyền thống nhờ vào việc giới thiệu tham số điều chỉnh α , cho phép tinh chỉnh dựa trên yêu cầu cụ thể của tác vụ. So với ReLU và Leaky ReLU, α SiLU hiệu quả trong việc giảm thiểu vấn đề gradient biến mất trong khi vẫn duy trì đường cong kích hoạt mượt mà, cải thiện luồng gradient. Khác với Mish và GELU, α SiLU cung cấp một lựa chọn thay thế tính

toán hiệu quả hơn trong khi vẫn giữ được tính phi tuyến và độ mượt mà. Ngoài ra, α SiLU cung cấp độ linh hoạt cao hơn so với ELU nhờ vào khả năng điều chỉnh dốc kích hoạt một cách động, cho phép tối ưu hóa tốt hơn trên các bộ dữ liệu và kiến trúc khác nhau. Với những đặc tính này, α SiLU đạt được sự cân bằng giữa hiệu quả tính toán, sự ổn định của gradient và khả năng thích ứng, khiến nó trở thành một hàm kích hoạt triển vọng cho các mô hình học sâu.

Hàm kích hoạt α SiLU giới thiệu một tham số điều chỉnh (α) để điều chỉnh độ dốc kích hoạt một cách động, từ đó cải thiện luồng gradient và tăng tốc độ hội tụ. Khác với SiLU truyền thống, trong đó yếu tố tỉ lệ là cố định, α SiLU cho phép tinh chỉnh dựa trên đặc điểm của bộ dữ liệu và kiến trúc mô hình.

3.3.5 Mô phỏng mô hình đề xuất

a) Bộ dữ liệu

Để đánh giá hàm kích hoạt α SiLU được đề xuất, NCS sử dụng hai bộ dữ liệu thực tế về sâu bệnh cây trồng, mỗi bộ bao gồm các hình ảnh của lá cây khỏe mạnh và lá cây bị bệnh:

- Bộ dữ liệu bệnh cây cà chua


Bộ dữ liệu này bao gồm tổng cộng 16075 hình ảnh, được phân loại thành tám lớp, trong đó có bảy loại bệnh phổ biến trên cây cà chua: đốm vi khuẩn (Bacterial Spot), đốm sớm (Early Blight), đốm muộn (Late Blight), mốc lá (Leaf Mold), virus xoắn lá vàng (Yellow Leaf Curl Virus), virus khảm (Mosaic Virus), đốm Septoria (Septoria Leaf Spot) và một lớp lá khỏe mạnh. Bộ dữ liệu bệnh lá cà chua được sử dụng trong nghiên cứu này được xây dựng bằng cách hợp nhất hai nguồn dữ liệu công khai: một bộ dữ liệu được thu thập trong điều kiện kiểm soát từ [102] và bộ dữ liệu PlantDoc thu thập ngoài thực địa từ [103]. Cả hai nguồn đều chứa các loại bệnh giống nhau, qua đó tạo điều kiện thuận lợi cho việc tích hợp một cách liền mạch.

Bộ dữ liệu từ [102] bao gồm các hình ảnh đã được đồng nhất kích thước về 256×256 pixel và được chụp trong điều kiện phòng thí nghiệm có kiểm soát. Các lá bị bệnh được tách thủ công khỏi cây và đặt trên nền xám trung tính trước khi chụp ảnh. Phương pháp này đảm bảo độ rõ nét cao cho hình ảnh và giảm thiểu nhiễu từ môi trường. Tuy nhiên, điều kiện chụp có kiểm soát cũng làm giảm sự đa dạng về độ phức tạp của phong nền và mức độ nghiêm trọng của bệnh, từ đó có thể làm giảm tính đại diện của bộ dữ liệu đối với các tình huống thực tế.


Ngược lại, bộ dữ liệu PlantDoc mang lại mức độ không đồng nhất cao hơn về độ phân giải hình ảnh (ví dụ: 400×275 , 800×599 pixel) và độ phức tạp của môi trường. Các hình ảnh trong PlantDoc được thu thập trong điều kiện tự nhiên ngoài thực địa, do đó phản ánh sự đa dạng lớn về ánh sáng, phong nền và biểu hiện của bệnh. Mặc

dù PlantDoc đóng góp số lượng mẫu ít hơn, nhưng việc đưa vào bộ dữ liệu này đã cải thiện đáng kể tính đa dạng và tính thực tiễn của toàn bộ tập dữ liệu.

Để đảm bảo tính nhất quán với yêu cầu đầu vào của mô hình YOLO, tất cả hình ảnh đã được tiền xử lý và chuyển đổi về kích thước 640×640 pixel. Bộ dữ liệu tổng hợp sau đó được chia ngẫu nhiên thành ba tập con: huấn luyện (80%), xác thực (10%) và kiểm tra (10%) nhằm hỗ trợ việc đánh giá mô hình một cách khách quan. Hình 3.20 minh họa các hình ảnh tiêu biểu từ bộ dữ liệu bệnh lá cà chua. Hình 3.21 thể hiện số lượng hình ảnh và các đối tượng được gán nhãn cho từng lớp bệnh cà chua trong ba tập huấn luyện, xác thực và kiểm tra.



Hình 3.20 Một số hình ảnh mẫu về bệnh trên cây cà chua [102], [103]



Hình 3.21 Tóm tắt số lượng hình ảnh và phân bố nhãn theo từng lớp bệnh cà chua trong các tập huấn luyện, xác thực và kiểm tra.

- Bộ Dữ liệu bệnh cây dưa chuột

Bộ dữ liệu này bao gồm 7920 hình ảnh, được phân loại thành ba lớp: lá dưa chuột khỏe mạnh, lá bị nhiễm bệnh sương mai (Powdery mildew), và lá bị nhiễm bệnh mốc sương (Downy mildew). Bộ dữ liệu bệnh lá dưa chuột được sử dụng trong

ngiên cứu này do nhóm nghiên cứu trong [104] cung cấp, bao gồm các hình ảnh có độ phân giải cao (ví dụ: 1280×1280 , 1224×1224 , 2448×2448 , 1620×1620 pixel) được thu thập trực tiếp trong điều kiện thực địa nông nghiệp.


Không giống như các bộ dữ liệu được thu thập trong phòng thí nghiệm có kiểm soát, tập hợp hình ảnh này phản ánh sự biến thiên thực tế về mức độ nghiêm trọng của bệnh, từ giai đoạn nhẹ đến nặng, cũng như điều kiện ánh sáng, từ môi trường thiếu sáng đến ánh sáng mặt trời tự nhiên mạnh. Sự đa dạng này làm tăng tính đại diện của bộ dữ liệu cho các tình huống triển khai thực tế và đồng thời đặt ra thách thức cho khả năng tổng quát hóa của mô hình trong các môi trường biến động.



Hình 3.22 Một số hình ảnh mẫu về bệnh trên cây dưa chuột [104]

Để chuẩn hóa đầu vào cho quá trình huấn luyện, tất cả hình ảnh đã được thay đổi kích thước về 640×640 pixel, phù hợp với yêu cầu của mô hình phát hiện dựa trên YOLO. Sau đó, bộ dữ liệu được chia ngẫu nhiên thành ba tập con: huấn luyện (80%), xác thực (10%) và kiểm tra (10%) nhằm đảm bảo đánh giá mô hình một cách nghiêm ngặt và không thiên lệch.

Hình 3.22 cung cấp các mẫu đại diện từ bộ dữ liệu bệnh cây dưa chuột, minh họa độ phức tạp thị giác và sự biến thiên vốn có trong các hình ảnh được thu thập. Hình 3.23 thể hiện phân bố số lượng hình ảnh và các nhãn tương ứng theo từng lớp bệnh dưa chuột, phản ánh cách bộ dữ liệu được phân chia trong ba tập huấn luyện, xác thực và kiểm tra.



Hình 3.23 Tóm tắt số lượng hình ảnh và phân bố nhãn theo từng lớp bệnh dưa chuột trong các tập huấn luyện, xác thực và kiểm tra.

b) Phương pháp đánh giá

Để đánh giá hiệu quả của hàm kích hoạt α -SiLU được đề xuất trong các mô hình YOLO luận án sử dụng một số chỉ số đánh giá chuẩn thường được áp dụng trong các bài toán phát hiện đối tượng.

Các chỉ số sau đây được sử dụng để định lượng và đánh giá hiệu năng của mô hình: Precision (P), Recall (R), F1-score, mAP@50 và mAP@50:95:

$$P = \frac{TP}{TP + FP} * 100\% \quad (3.19)$$

$$R = \frac{TP}{TP + FN} * 100\% \quad (3.10)$$

$$F1\text{-score} = 2 * \frac{P * R}{P + R} * 100\% \quad (3.21)$$

$$mAP = \frac{\sum_{c=1}^C AP(c)}{C} * 100\% \quad (3.22)$$

Trong đó:

- True Positives (TP): Các đối tượng trong ảnh được mô hình phát hiện và phân loại chính xác.

- False Positives (FP): Các dự đoán không khớp với bất kỳ đối tượng thực nào hoặc bị gán sai nhãn lớp.

- False Negatives (FN): Các đối tượng gốc (ground-truth) bị mô hình bỏ sót, do không được phát hiện hoặc do mức độ chồng lấn (IoU) quá thấp.

- Precision (P): Tỷ lệ các khung dự đoán đúng trên tổng số khung dự đoán, phản ánh khả năng mô hình tránh các phát hiện sai.

- Recall (R): Mức độ bao phủ các đối tượng thực của mô hình, cho thấy độ nhạy đối với việc bỏ sót.

- F1 Score: Trung bình điều hòa (harmonic mean) của Precision và Recall, cung cấp thước đo cân bằng, đặc biệt hữu ích trong các tình huống mất cân bằng lớp.

- Mean Average Precision (mAP): Chỉ số tổng hợp phản ánh độ chính xác nhận diện trên tất cả các loại đối tượng, được tính bằng cách lấy trung bình các giá trị Average Precision (AP):

- mAP@50: Tính tại ngưỡng IoU cố định 0,50.

- mAP@50:95: Tính bằng cách lấy trung bình AP trên các ngưỡng IoU từ 0,50 đến 0,95 với bước tăng 0,05, tuân theo giao thức đánh giá COCO.

c) Mô phỏng

Mô hình được huấn luyện trên nền tảng phần cứng bao gồm GPU NVIDIA GeForce GTX 1660 (6GB VRAM), CPU Intel Xeon E5-2689 và 64GB RAM, vận hành trên hệ điều hành Windows 10. Môi trường phần mềm sử dụng Python 3.9.19, PyTorch 2.3.1 với hỗ trợ CUDA 11.8, cùng với Ultralytics 8.3.9.


Luận án đã sử dụng công cụ trên công cụ Labelme để gắn nhãn cho từng nhóm đối tượng. Sau đó, tệp có đuôi .json được chuyển đổi thành tệp đuôi .txt bằng công cụ labelme2yolo để lấy tập dữ liệu cho quá trình huấn luyện. Quá trình ghi nhãn và mô tả được minh họa trong Hình 3.24.



Hình 3.24 Sơ đồ quá trình ghi nhãn đối tượng

Để đánh giá một cách chặt chẽ hiệu quả của hàm kích hoạt α SiLU được đề xuất, các thí nghiệm chuyên sâu trước tiên được tiến hành trên bộ dữ liệu chính về nhận diện bệnh trên cây cà chua, sử dụng kiến trúc YOLOv11n (mô hình có khả năng cân bằng tốt giữa độ chính xác và tốc độ, kích thước nhẹ, cùng tính linh hoạt cao phù hợp với phần cứng yếu thường được sử dụng trên robot di động).

Quá trình huấn luyện mô hình YOLO thể hiện trên hình 3.25



Hình 3.25 Quá trình huấn luyện mô hình YOLO

Nhằm kiểm chứng khả năng khái quát hóa của phương pháp, một bộ dữ liệu bổ sung về bệnh trên cây dưa chuột được sử dụng, tập trung vào việc đánh giá hiệu suất mô hình dưới cấu hình α tối ưu. Bên cạnh đó, để bảo đảm tính ứng dụng rộng rãi

và đối chiếu mức độ nhất quán trên nhiều kiến trúc khác nhau, α SiLU cũng được tích hợp vào nhiều biến thể YOLO khác cho mục đích phân tích so sánh mở rộng.

3.3.6 Kết quả mô phỏng và đánh giá hiệu suất của mô hình

a) Đánh giá trên mô hình YOLOv11n

Bảng 3.4 trình bày các kết quả thực nghiệm của mô hình trên bộ dữ liệu bệnh cà chua.

Bảng 3.4: Phân tích hiệu suất của YOLOv11n với các giá trị α khác nhau trên bộ dữ liệu bệnh cà chua

Mô hình	Hàm kích hoạt	α	P (%)	R (%)	F1-score (%)	mAP@50 (%)	mAP@50-95 (%)
YOLOv11n	α SiLU	0,5	95,70	83,40	89,13	91,80	82,00
	α SiLU	0,7	95,20	83,80	89,14	91,80	81,70
	α SiLU	0,8	96,10	82,80	89,14	92,20	82,10
	α SiLU	0,9	94,80	84,10	89,13	92,00	82,20
	α SiLU	0,95	95,30	84,60	89,63	91,90	81,90
	SiLU	1	95,20	83,40	88,91	91,30	81,30
	α SiLU	1,025	96,70	83,60	89,67	91,70	81,60
	α SiLU	1,05	95,70	84,40	89,70	92,40	82,00
	α SiLU	1,055	95,30	83,50	89,01	91,70	81,70
	α SiLU	1,1	95,20	83,30	88,85	91,60	81,80
	α SiLU	1,5	94,40	84,60	89,23	91,30	81,30
	α SiLU	1,8	95,60	83,80	89,31	91,50	81,40
	α SiLU	2	96,30	83,40	89,39	91,60	81,50

Bảng 3.4 trình bày đánh giá định lượng toàn diện về hàm kích hoạt α SiLU được đề xuất, so sánh đối chiếu với SiLU chuẩn trên kiến trúc YOLOv11n. Quá trình đánh giá bao phủ một dải rộng các giá trị α (từ 0,5 đến 2,0), cung cấp cái nhìn chi tiết về cách thức điều chỉnh tham số ảnh hưởng đến hiệu năng nhận diện trong các điều kiện vận hành khác nhau.

Với $\alpha = 1,05$, mô hình đạt được hiệu năng cân bằng nhất, với F1-score đạt 89,70%, mAP@50 đạt 92,40%, và mAP@50–95 đạt 82,00%, tất cả đều vượt trội so với chuẩn SiLU ($\alpha = 1,0$) với biên độ cải thiện đáng kể. Kết quả này cho thấy việc tăng nhẹ độ dốc của hàm kích hoạt giúp cải thiện luồng gradient và tăng cường tính ổn định trong quá trình hội tụ, đặc biệt trong các kiến trúc sâu nơi hiện tượng mất dần gradient thường xảy ra rõ rệt.

Đáng chú ý, cấu hình với $\alpha = 0,9$ đạt được mAP@50–95 cao nhất là 82,20%, cho thấy việc giảm nhẹ độ cong của hàm kích hoạt xuống thấp hơn so với SiLU có thể nâng cao khả năng khái quát hóa của mô hình dưới các ngưỡng định vị nghiêm ngặt hơn. Kết quả định này, dù mang tính đơn lẻ, nhấn mạnh sự nhạy cảm của các bài

toán nhận diện chi tiết – chẳng hạn như phân loại bệnh trên cây trồng – đối với những thay đổi nhỏ trong động học của hàm kích hoạt. Tuy nhiên, $\alpha = 0,9$ chỉ mang lại cải thiện hạn chế về F1-score so với $\alpha = 1,05$, và không duy trì được ưu thế ổn định trên tất cả các chỉ số hiệu năng.

Bảng 3.5: Phân tích hiệu suất của YOLOv11n với các giá trị α khác nhau trên bộ dữ liệu bệnh dưa chuột

Mô hình	Hàm kích hoạt	α	P (%)	R (%)	F1-score (%)	mAP@50 (%)	mAP@50-95 (%)
YOLOv11n	α SiLU	0,5	87,40	87,50	87,45	94,20	80,70
	α SiLU	0,7	87,40	87,10	87,25	94,30	80,90
	α SiLU	0,85	87,10	87,30	87,20	94,10	80,60
	α SiLU	0,9	87,60	86,30	86,95	94,00	80,50
	α SiLU	0,95	89,10	85,90	87,47	94,20	80,70
	SiLU	1	87,80	87,00	87,40	94,10	80,80
	α SiLU	1,025	88,00	86,00	86,99	94,10	80,60
	α SiLU	1,05	87,80	87,60	87,70	94,30	81,00
	α SiLU	1,06	88,00	87,30	87,65	94,20	80,80
	α SiLU	1,08	89,60	85,60	87,55	94,30	80,70
	α SiLU	1,1	88,40	86,30	87,34	94,20	80,70
	α SiLU	1,5	88,10	87,90	88,00	94,20	80,90
	α SiLU	1,8	86,60	88,10	87,34	93,90	80,80
	α SiLU	2	87,80	86,70	87,25	94,10	80,80

Bảng 3.5 trình bày kết quả đánh giá thực nghiệm của hàm kích hoạt α SiLU trên bộ dữ liệu bệnh lá dưa chuột; đây là bộ dữ liệu cân bằng hơn so với bộ dữ liệu bệnh cà chua. Tính cân bằng này mang lại một góc nhìn rõ ràng hơn trong việc phân tích tác động chức năng của các giá trị α khác nhau, đồng thời giúp tách biệt ảnh hưởng của động học hàm kích hoạt khỏi các yếu tố nhiễu do mất cân bằng lớp.

Kết quả cho thấy hiệu năng tương đối ổn định trong một dải rộng các giá trị α . Cấu hình $\alpha = 1,05$ đạt mAP@50–95 cao nhất (81,00%) cùng với F1-score = 87,70%, phản ánh sự cân bằng hợp lý giữa độ chính xác định vị và độ tin cậy phân loại. Mặc dù mức cải thiện so với SiLU chuẩn còn khiêm tốn (mAP@50–95 = 80,80%), kết quả này tiếp tục củng cố phát hiện trước đó trên bộ dữ liệu cà chua, qua đó xác nhận $\alpha = 1,05$ là một cấu hình ổn định và có khả năng khái quát tốt.

Đáng chú ý, một số giá trị α khác (ví dụ: $\alpha = 1,5$ với F1 = 88%, và $\alpha = 0,95$ với F1 = 87,47%) cũng cho thấy kết quả cạnh tranh, cho thấy tính cân bằng của bộ dữ liệu khiến mô hình ít nhạy cảm hơn với các biến thiên nhỏ trong độ dốc của hàm kích hoạt. Sự ổn định hiệu năng này gợi ý rằng, đối với các bộ dữ liệu có tính đồng nhất thống kê cao, α SiLU duy trì được hành vi tin cậy trong một phổ tham số rộng hơn.

Các tác giả trong nghiên cứu [104] đã huấn luyện trên mô hình YOLOv4 trên bộ dữ liệu bệnh cây dưa chuột mà luận án đã sử dụng để huấn luyện. So với kết quả huấn luyện của nghiên cứu [104] thì kết quả huấn luyện trên mô hình YOLOv11 với hàm kích hoạt α SiLU mà luận án đề xuất vượt trội hơn (Bảng 3.6).

Bảng 3.6: So sánh kết quả huấn luyện YOLO trên cùng bộ dữ liệu

Mô hình	Chỉ số đánh giá	
	F1-score (%)	mAP@50 (%)
Trong [104]	74	80,76
Luận án đề xuất	88	94,3

Ngoài ra, ưu điểm nổi bật của α SiLU so với SiLU chuẩn, đặc biệt ở chỉ số mAP@50–95 đã nhấn mạnh khả năng cải thiện hiệu quả định vị chi tiết. Chỉ số này đặc biệt quan trọng trong chẩn đoán hình ảnh nông nghiệp, nơi các dấu hiệu bệnh lý như tổn thương, biến đổi màu sắc hoặc vết bệnh thường rất tinh vi hoặc có ranh giới không rõ ràng.

Đáng lưu ý, khoảng $\alpha \in [0,95; 1,1]$ một lần nữa nổi lên như vùng tối ưu thực tiễn, đạt được sự cân bằng giữa khả năng biểu đạt và dòng chảy gradient. Sự hội tụ của F1-score cao và mAP đạt đỉnh trong khoảng này cho thấy α SiLU có khả năng mang lại tính linh hoạt thích ứng theo tác vụ mà không cần thay đổi kiến trúc là một lợi thế quan trọng đối với các mô hình thời gian thực triển khai trên thiết bị biên (edge devices).

b) So sánh thực nghiệm giữa các phiên bản YOLO

Để tiếp tục kiểm chứng khả năng khái quát hóa của hàm kích hoạt α SiLU được đề xuất, luận án đã mở rộng phạm vi thí nghiệm sang các biến thể YOLO khác, cụ thể là YOLOv5n, YOLOv8n và YOLOv10n. Quá trình đánh giá được thực hiện trên hai bộ dữ liệu bệnh cây khác nhau: dưa chuột (cân bằng) và cà chua (mất cân bằng), nhằm khảo sát tính bền vững của α SiLU trong các phân bố dữ liệu và cấu hình mô hình đa dạng.

Trên bộ dữ liệu dưa chuột (Bảng 3.7), việc tích hợp α SiLU ($\alpha = 1,05$) đã nhất quán mang lại cải thiện hiệu năng trên tất cả các mô hình được đánh giá. YOLOv10n đạt mức tăng +0,5% ở mAP@50 và +0,4% ở mAP@50–95, trong khi YOLOv11n đạt độ chính xác nhận diện cao nhất, với 94,3% mAP@50 và 81,0% mAP@50–95 – vượt trội hơn phiên bản sử dụng SiLU chuẩn ở cả hai chỉ số với mức tăng +0,2%. Những cải thiện này nhấn mạnh tính hiệu quả của α SiLU trong việc nâng cao độ chính xác định vị và khả năng phân biệt ngữ nghĩa, ngay cả trong các kiến trúc phát hiện nhẹ.

Bảng 3.7: Đánh giá hiệu năng các kiến trúc YOLO trên bộ dữ liệu bệnh cây dừa chuột

Mô hình	Precision	Recall	F1-score	mAP@50	mAP@50-95
YOLOv5n (SiLU)	88,10%	84,50%	86,26%	93,50%	79,30%
YOLOv5n ($\alpha = 1.05$)	88,40%	85,00%	86,67%	93,60%	79,30%
YOLOv8n (SiLU)	85,70%	87,00%	86,35%	93,40%	79,70%
YOLOv8n ($\alpha = 1.05$)	86,50%	87,20%	86,85%	93,50%	79,80%
YOLOv10n (SiLU)	88,80%	84,60%	86,65%	93,50%	79,40%
YOLOv10n ($\alpha = 1.05$)	89,70%	84,90%	87,23%	94,00%	79,80%
YOLOv11n(SiLU)	87,80%	87,00%	87,40%	94,10%	80,80%
YOLOv11n ($\alpha = 1.05$)	87,80%	87,60%	87,70%	94,30%	81,00%

Ngược lại, kết quả trên bộ dữ liệu cà chua (Bảng 3.8) được đặc trưng bởi hiện tượng mất cân bằng lớp rõ rệt cho thấy α SiLU vẫn duy trì được hiệu quả tích cực, đặc biệt trên YOLOv10n và YOLOv11n. Cấu hình $\alpha = 1,05$ đã cải thiện mAP@50 thêm 1,1% và mAP@50–95 thêm 0,7%, đồng thời đi kèm với các mức tăng ổn định ở F1-score và Precision. Trong khi đó, YOLOv5n và YOLOv8n với α SiLU ghi nhận mức giảm nhẹ ở các chỉ số liên quan đến Recall, nhưng sự đánh đổi tổng thể vẫn ở mức chấp nhận được, qua đó khẳng định tính tương thích của α SiLU với nhiều kiến trúc mạng nền khác nhau.

Bảng 3.8: Đánh giá hiệu năng các kiến trúc YOLO trên bộ dữ liệu bệnh cây cà chua

Mô hình	Precision	Recall	F1-score	mAP@50	mAP@50-95
YOLOv5n (SiLU)	88,10%	84,50%	86,26%	93,50%	79,30%
YOLOv5n ($\alpha = 1,05$)	88,40%	85,00%	86,67%	93,60%	79,30%
YOLOv8n (SiLU)	85,70%	87,00%	86,35%	93,40%	79,70%
YOLOv8n ($\alpha = 1,05$)	86,50%	87,20%	86,85%	93,50%	79,80%
YOLOv10n (SiLU)	88,80%	84,60%	86,65%	93,50%	79,40%
YOLOv10n ($\alpha = 1,05$)	89,70%	84,90%	87,23%	94,00%	79,80%
YOLOv11n(SiLU)	87,80%	87,00%	87,40%	94,10%	80,80%
YOLOv11n ($\alpha = 1,05$)	87,80%	87,60%	87,70%	94,30%	81,00%

Từ các kết quả thu được, α SiLU như một hàm kích hoạt thay thế trực tiếp, không đòi hỏi bất kỳ điều chỉnh kiến trúc nào nhưng vẫn mang lại các cải thiện hiệu năng có thể đo lường được. Khả năng mở rộng qua nhiều thể hệ kiến trúc YOLO định vị α SiLU như một chiến lược nâng cấp linh hoạt cho các pipeline phát hiện đối tượng, đặc biệt trong những lĩnh vực đòi hỏi đồng thời cả độ chính xác và hiệu quả tính toán.

c) So sánh thực nghiệm giữa các hàm kích hoạt

Để có cái nhìn sâu hơn về tác động chức năng của α SiLU, NCS đã tiến hành so sánh với một số hàm kích hoạt phổ biến khác, bao gồm LeakyReLU, ReLU, Mish, GELU, ELU và SiLU mặc định. Phân tích so sánh được thực hiện trên kiến trúc YOLOv11n với hai bộ dữ liệu bệnh cây cà chua và dưa chuột, khác biệt về độ phân giải ảnh, mức độ cân bằng nhãn và độ phức tạp thị giác. Các chỉ số đánh giá bao gồm mAP@50, mAP@50–95 và độ trễ suy luận trên mỗi ảnh, được tóm tắt trong Bảng 3.9 và Bảng 3.10.

Bảng 3.9: Đánh giá các hàm kích hoạt thay thế trên dữ liệu bệnh cây cà chua

Mô hình	Hàm kích hoạt	mAP@50 (%)	mAP@50-95 (%)	Thời gian suy luận (ms)
YOLOv11n	LeakyReLU	91,00	80,60	5,9
YOLOv11n	ReLU	91,20	80,80	5,8
YOLOv11n	Mish	91,20	81,30	5,9
YOLOv11n	GELU	91,40	81,30	5,9
YOLOv11n	ELU	91,70	81,60	5,9
YOLOv11n	SiLU	91,30	81,30	6,1
YOLOv11n	CAReLU	91,50	80,90	12,1
YOLOv11n ($\alpha = 1,05$)	α SiLU	92,40	82,00	6,6

Bảng 3.10: Đánh giá các hàm kích hoạt thay thế trên dữ liệu bệnh cây dưa chuột

Mô hình	Hàm kích hoạt	mAP@50 (%)	mAP@50-95 (%)	Thời gian suy luận (ms)
YOLOv11n	LeakyReLU	94,00	80,10	6,4
YOLOv11n	ReLU	94,20	80,20	6,3
YOLOv11n	Mish	94,10	80,80	6,2
YOLOv11n	GELU	94,20	80,70	6,4
YOLOv11n	ELU	94,10	80,60	6,3
YOLOv11n	SiLU	94,10	80,80	6,6
YOLOv11n	CAReLU	93,80	80,10	12,4
YOLOv11n ($\alpha = 1,05$)	α SiLU	94,30	81,00	7,0

Trên bộ dữ liệu bệnh cây cà chua, vốn có độ phân giải ảnh tương đối thấp và sự mất cân bằng lớp rõ rệt, α SiLU ($\alpha = 1,05$) cho thấy độ chính xác nhận diện cao nhất, đạt 92,40% mAP@50 và 82,00% mAP@50–95. Các kết quả này thể hiện mức cải thiện đáng kể lần lượt +1,1% và +0,7% so với SiLU chuẩn. Mặc dù Mish, GELU và ELU cũng đạt hiệu năng cạnh tranh ở chỉ số mAP@50–95 (dao động từ 81,3% đến 81,6%), nhưng chúng không có cơ chế điều chỉnh thích ứng

(adaptive scaling) như trong α SiLU. Chính khả năng thích ứng này giúp cải thiện dòng gradient và tạo ra biểu diễn đặc trưng tinh vi hơn, đặc biệt hữu ích trong các kịch bản có biến thiên triệu chứng tinh subtle và mất cân bằng lớp, vốn thường gặp ở hình ảnh bệnh lá cà chua.

Hàm kích hoạt CArReLU mới được giới thiệu cũng được đưa vào đánh giá nhằm mở rộng phạm vi so sánh. Trên bộ dữ liệu cà chua, CArReLU đạt 91,50% mAP@50 và 80,90% mAP@50–95, kết quả tương đương với các hàm kích hoạt truyền thống nhưng vẫn thấp hơn α SiLU ở cả hai chỉ số. Đáng chú ý, CArReLU ghi nhận độ trễ suy luận cao nhất là 12,1 ms, gần gấp đôi so với các hàm khác, do cấu trúc phức tạp với nhiều tham số học được và cơ chế điều biến theo ngữ cảnh. Độ trễ này có thể trở thành rào cản khi triển khai trong các ứng dụng phát hiện đối tượng thời gian thực, chẳng hạn như giám sát bệnh cây trồng nông nghiệp.

Ngược lại, trên bộ dữ liệu dưa chuột, CArReLU cho kết quả thấp hơn một chút với 93,80% mAP@50 và 80,10% mAP@50–95, đồng thời ghi nhận độ trễ cao nhất (12,4 ms). Điều này càng nhấn mạnh sự đánh đổi giữa tính thích ứng và hiệu quả tính toán. Mặc dù thiết kế nhảy theo ngữ cảnh của CArReLU có thể mang lại lợi ích cho một số tác vụ phân loại chuyên biệt, nhưng tính chất tiêu tốn tài nguyên khiến nó khó ứng dụng thực tiễn trong các hệ thống triển khai trên thiết bị biên hoặc yêu cầu độ trễ thấp.

Ở góc độ hệ thống, mức đánh đổi vừa phải về thời gian suy luận này vẫn được xem là chấp nhận được, đặc biệt trong các ứng dụng đòi hỏi độ chính xác cao như nông nghiệp chính xác, nơi ngay cả những cải thiện nhỏ trong độ tin cậy phát hiện cũng có thể mang lại tác động đáng kể trong thực tiễn. Với sự phát triển liên tục của phần cứng tính toán biên (ví dụ: NVIDIA Jetson, Coral TPU), việc triển khai α SiLU trong các hệ thống giám sát bệnh cây theo thời gian thực ngày càng trở nên khả thi.

Qua phân tích trên, α SiLU vượt trội hơn CArReLU về độ chính xác nhận diện trên cả hai bộ dữ liệu, đồng thời duy trì chi phí tính toán thấp hơn đáng kể. Những phát hiện này một lần nữa khẳng định tính hiệu quả của α SiLU, không chỉ như một thay thế trực tiếp cho SiLU, mà còn như một giải pháp thực tiễn và hiệu quả so với các hàm kích hoạt phức tạp hơn như Mish, GELU và CArReLU.

Với những kết quả trên, đề xuất cải tiến mô hình YOLO nhằm nâng cao hiệu quả phát hiện sâu bệnh cây trồng trong nhà kính, phục vụ trực tiếp nhiệm vụ giám sát môi trường và sự phát triển của cây trồng của robot di động. Thông qua dữ liệu hình ảnh thu thập có định hướng bởi robot di động từ các camera cố định, mô hình YOLO cải tiến giúp robot di động tham gia vào quá trình đánh giá chính xác tình trạng sức khỏe cây trồng, phát hiện sớm các dấu hiệu bất thường, từ đó nâng cao chất lượng giám sát và hỗ trợ vận hành nông nghiệp thông minh.

3.4 Kết luận chương 3

Chương 3 đã thực hiện được một số nội dung chính để đạt được mục tiêu của luận án như sau:

- Nghiên cứu và đề xuất phương pháp khử nhiễu cho bộ dữ liệu hình ảnh cây trồng do robot di động thu thập từ cảm biến hình ảnh tại một số vị trí trong khu vực giám sát được gửi về trung tâm điều khiển để phục vụ cho việc phân tích dữ liệu và điều khiển giám sát sự phát triển của cây trồng, trong đó ưu tiên phát hiện sâu bệnh trên cây trồng.

- Đề xuất cải tiến mô hình YOLO phát hiện sâu bệnh cây trồng bằng cách hiệu chỉnh hàm kích hoạt SiLU theo hệ số tỷ lệ α . Hàm kích hoạt α SiLU giúp mô hình tăng khả năng biểu diễn phi tuyến, cải thiện tốc độ hội tụ trong quá trình huấn luyện và nâng cao độ chính xác nhận diện so với một số hàm kích hoạt khác. Kết quả thử nghiệm bước đầu cho thấy mô hình cải tiến có khả năng phát hiện sâu bệnh tốt hơn, đáp ứng yêu cầu ứng dụng thực tiễn trong điều kiện nhà kính.

Nội dung của chương 3 được công bố trong công trình CT5, CT6 và CT7:

[CT5] N. T. Duyen, B.Đ.Thanh, N.M.Tien, N.Q.Uoc, “Improving YOLO-based Plant Disease Detection using α SILU: a Novel Activation Function for Smart Agriculture” *AgriEngineering* 2025, 7(9), 271,

<https://doi.org/10.3390/agriengineering7090271>

JCR - Q2 (Agricultural Engineering) / CiteScore - Q1 (Horticulture)- 4.7.

[CT6] N. T. Duyen, N.M.Tien, Đ.Q.Vuong, N.Q.Uoc, Đ.Q.Hiep, “Appication of Fast Segment Anything Model (FASTSAM) for autonomous robot indentifying plant diease” *Thanh Dong University Journal of Sciences and Technology*, 2023 Sep, pp.50, ISSN 2734-9500.

[CT7] N. T. Duyen, N.M.Tiến, P.X.Minh, N.Q.Ước, Đ.Q.Vượng, “Xây dựng hệ điều hướng cho Robot tự hành giám sát sâu bệnh trên cây trồng trong nhà lưới dựa trên hệ điều hành ROS”, *Proceedings the 7th Vietnam International Conference and Exhibition on Control and Automation VCCA-2024*, ISBN 978-604-937-357-2.

KẾT LUẬN VÀ KIẾN NGHỊ

Robot di động đã và đang được ứng dụng rộng rãi và có tiềm năng lớn trong sản xuất nông nghiệp thông minh, đặc biệt trong các nhà kính nông nghiệp hiện đại. Với xu hướng phát triển của IoT, mạng cảm biến không dây và trí tuệ nhân tạo, robot di động hoạt động trong các nhà kính nông nghiệp ngày được quan tâm nhiều hơn. Luận án đã tập trung nghiên cứu và đề xuất phương pháp, mô hình cải tiến để giải quyết vấn đề đặt ra và đạt được kết quả quan trọng.

1. Các kết quả đạt được của Luận án

Luận án đã đạt được mục tiêu đề ra là: Điều hướng Robot di động trong nhà kính nông nghiệp đảm bảo thu thập đầy đủ dữ liệu đo từ các nút cảm biến đầu cụm trong phạm vi thời gian cho phép xác định trước, ưu tiên giảm tiêu hao năng lượng cho các cụm cảm biến. Giám sát sự phát triển của cây trồng trong nhà kính nông nghiệp, phát hiện sâu bệnh kịp thời để có biện pháp phòng chống sâu bệnh nhằm nâng cao sản lượng thu hoạch trong nhà kính nông nghiệp. Ngoài ra, luận án đã mô phỏng và đánh giá thuật toán cho phương pháp đề xuất, mô hình cải tiến. Luận án đề xuất những đóng góp chính như sau:

➤ **Đề xuất giải pháp điều hướng cho robot di động thu thập đầy đủ dữ liệu từ mạng cảm biến không dây trong thời gian cho phép xác định trước.** Đường đi của robot di động để đến các nút cảm biến đầu cụm được xây dựng dựa trên giải pháp hình học heuristic nhằm tìm quãng đường đi của robot di động ngắn thông qua việc giải quyết bài toán định tuyến phương tiện. Giải pháp được đề xuất được thiết kế để đáp ứng các yêu cầu sau: Giảm thiểu tổng chiều dài quãng đường di chuyển của robot di động. Mỗi nút cảm biến đầu cụm phải được robot di động đi đến trong khoảng thời gian báo cáo giới hạn ξ_0 , điều này đảm bảo không xảy ra hiện tượng tràn dữ liệu tại bất kỳ nút cảm biến đầu cụm nào. Robot di động hoàn thành quỹ đạo di chuyển riêng của mình trong khoảng thời gian báo cáo ξ_0 đã quy định. Giải pháp đề xuất phục vụ việc giám sát môi trường và sự phát triển của cây trồng trong nông nghiệp.

➤ **Đề xuất cải tiến mô hình YOLO nhằm nâng cao chất lượng phát hiện sâu bệnh cây trồng trong nhà kính nông nghiệp.** Mô hình YOLO cải tiến dựa trên việc đề xuất hàm kích hoạt α SiLU. Hàm kích hoạt này có khả năng cải thiện mAP@50–95, vốn là chỉ số đặc biệt quan trọng trong chẩn đoán hình ảnh nông nghiệp có các dấu hiệu bệnh thường rất đa dạng và khó nhận diện. Tìm ra khoảng α thuộc vùng tối ưu, cân bằng giữa tính biểu đạt và luồng gradient, đồng thời duy trì các chỉ số mAP và F1 ở mức cao. Sự hội tụ này cho thấy α SiLU mang lại sự linh hoạt trong thích ứng với nhiệm vụ mà không cần thay đổi kiến trúc. Đề xuất này nâng cao chất lượng giám sát sự phát triển của cây trồng trong nông nghiệp.

Ngoài ra, trong quá trình thực hiện luận án, các nghiên cứu đã được công bố ở các hội nghị khoa học và các tạp chí có uy tín trong nước.

2. Hướng phát triển của Luận án

Những nghiên cứu gần đây đã chứng minh rằng việc sử dụng robot di động đi thu thập dữ liệu trong mạng cảm biến không dây môi trường nhà kính nông nghiệp có nhiều hữu ích. Đồng thời, robot nông nghiệp làm nhiệm vụ giám sát tình trạng cây trồng cũng rất cần thiết. Vì vậy, định hướng nghiên cứu trong tương lai của NCS bao gồm:

- Nghiên cứu phương pháp điều hướng cho hệ đa robot di động thu thập dữ liệu cảm biến của mạng cảm biến không dây trong nhà kính nông nghiệp thực tế để đánh giá khả năng ứng dụng thực tiễn.
- Nghiên cứu, đánh giá hiệu suất của hàm kích hoạt SiLU cải tiến trên các mô hình trí tuệ nhân tạo có phiên bản mới nhất và trên các bộ dữ liệu sâu bệnh cây trồng khác nhau.

DANH MỤC CÔNG TRÌNH KHOA HỌC ĐÃ ĐƯỢC CÔNG BỐ CỦA TÁC GIẢ

[CT1] **N. T. Duyên**, N.M.Tiến, Đ.Q.Hiệp, Đ.M. Đông, “Xây dựng hệ định vị, bản đồ hóa cho robot tự hành trong nhà kính nông nghiệp dựa trên hệ điều hành lập trình cho robot” *Tạp chí KH&CN quân sự, Số Đặc san Hội thảo Quốc gia FEE*, 10/2021, tr.168-175, ISSN: 1859-1043

[CT2] **N. T. Duyên**, N.M.Tiến, Đ.Q.Hiệp, Đ.M. Đông, B.V.Tuấn, “Xây dựng hệ điều hướng trên bản đồ, định vị SLAM cho Robot tự hành trong nhà kính nông nghiệp dựa trên hệ điều hành ROS” Proceedings the 6th Vietnam International Conference and Exhibition on Control and Automation VCCA-2021, ISBN 978-604-73-5569-3.

[CT3] **N. T. Duyên**, N.M.Tiến, N.N.Minh, H. T. K. Duyên, “Lập quỹ đạo cục bộ dựa trên bản đồ đồng thời SLAM cho Robot tự hành trong nhà kính nông nghiệp trên nền tảng hệ điều hành ROS” Hội thảo quốc gia lần thứ XXIV: Một số vấn đề chọn lọc của công nghệ thông tin và truyền thông- Thái Nguyên, 13-14/12/2021.

[CT4] **N. T. Duyen**, P.X.Minh, N.M.Tien, N.Q.Uoc, N.T.Hoc “Enhancing network lifetime and data integrity in WSNs via optimized mobile robot trajectories” *Journal of Robotics and Control (JRC)*, 2025, 6(5), pp. 2260-2271,
<https://doi.org/10.18196/jrc.v6i5.26489>, Scopus indexed (Q2).

[CT5] **N. T. Duyen**, B.Đ.Thanh, N.M.Tien, N.Q.Uoc, “Improving YOLO-based Plant Disease Detection using α SILU: a Novel Activation Function for Smart Agriculture” *AgriEngineering* 2025, 7(9), 271,
<https://doi.org/10.3390/agriengineering7090271>
JCR - Q2 (Agricultural Engineering) / CiteScore - Q1 (Horticulture)- 4.7.

[CT6] **N. T. Duyen**, N.M.Tien, N.T.Hiep, Đ.Q.Vuong, N.Q.Uoc, Đ.Q.Hiep, “Appication of Fast Segment Anything Model (FASTSAM) for autonomous robot indentifying plant diease” Thanh Dong University Journal of Sciences and Technology, 2023 Sep, pp.50, ISSN 2734-9500.

[CT7] **N. T. Duyên**, N.M.Tiến, P.X.Minh, N.Q.Ước, Đ.Q.Vượng, H.Đ.Hoàn, “Xây dựng hệ điều hướng cho Robot tự hành giám sát sâu bệnh trên cây trồng trong nhà lưới dựa trên hệ điều hành ROS”, Proceedings the 7th Vietnam International Conference and Exhibition on Control and Automation VCCA-2024, ISBN 978-604-937-357-2.

TÀI LIỆU THAM KHẢO

1. Diginsa, M. U., Shafie, N., Yusuf, N., & Suleiman, S. U. U., 2023, Issues and challenges of simultaneous localization and mapping (SLAM) technology in autonomous robot, *International Journal of Innovative Computing*, 13(2), pp. 59–63.
2. Agunbiade, O., 2018, A review: simultaneous localization and mapping in application to autonomous robot, *Agunbiade OY and Zuva T.*, May.
3. Liu, L., Wang, X., Yang, X., Liu, H., Li, J., & Wang, P., 2023, Path planning techniques for mobile robots: review and prospect, *Expert Systems with Applications*, 227, pp. 120254.
4. Siciliano, B., & Khatib, O. (Eds.), 2016, *Springer Handbook of Robotics*, Springer.
5. Tôn Thất Trường Nam và cs., 2023, Chế tạo thiết bị IoT giám sát tự động vi khí hậu nhà màng, *Tạp chí Khoa học Đại học Tây Nguyên*, (59).
6. Ngô Trí Dương, Nguyễn Văn Điều, 2016, Thiết kế và chế tạo hệ thống thu thập dữ liệu các thông số ảnh hưởng đến quá trình sinh trưởng và phát triển cây hoa đồng tiền trong nhà lưới, *Tạp chí Khoa học Nông nghiệp Việt Nam*, 14(3), tr. 477-490.
7. Lê Trường Giang, Nguyễn Duy Trinh, 2019, Thiết kế hệ thống thu thập dữ liệu môi trường trong nhà màng sử dụng các cảm biến và máy tính Raspberry Pi, *Tạp chí Khoa học & Công nghệ - NTTU*, (6), tr. 1-6.
8. Phạm Thị Lan Hương, Nguyễn Thị Duyên, 2023, Xây dựng quỹ đạo cục bộ cho robot tự hành trong nhà lưới nông nghiệp trên nền tảng ROS, *Tạp chí Khoa học Nông nghiệp Việt Nam*, 21(10).
9. Thiên, H., Thúy, B. T., Thơm, P. V., 2022, Điều khiển bám quỹ đạo dẫn đường canh tác của rôbốt nông nghiệp bằng bộ điều khiển phản hồi trạng thái tuyến tính, *Hội nghị Khoa học toàn quốc lần thứ hai về Động lực học và Điều khiển*, tr. 58-65.
10. Canh, T. N., Do, D. M., HoangVan, X., 2024, Development of an indoor localization and navigation system based on monocular SLAM for mobile robots, *arXiv preprint*, arXiv:2411.05337.
11. Ngô Quang Ước, Ngô Trí Dương, Bùi Đăng Thành, 2021, Cải tiến thuật toán YOLO v4 ứng dụng cho hệ thống giám sát bệnh phấn trắng và bệnh sương mai trên cây dưa chuột, *Measurement, Control, and Automation*, 2(2), tr. 60-68.
12. Zhao, J. C., Zhang, J. F., Feng, Y., Guo, J. X., 2010, The study and application of the IoT technology in agriculture, *Proceedings of the 3rd International Conference on Computer Science and Information Technology*, 2, pp. 462-465, IEEE

13. Park, D. H., Park, J. W., 2011, Wireless sensor network-based greenhouse environment monitoring and automatic control system for dew condensation prevention, *Sensors*, 11(4), pp. 3640-3651.
14. Ting, L., Man, Z., Yuhua, J., Sha, S., Yiqiong, J., Minzan, L., 2015, Management of CO₂ in a tomato greenhouse using WSN and BPNN techniques, *International Journal of Agricultural and Biological Engineering*, 8(4), pp. 43-51.
15. Mancuso, M., Bustaffa, F., 2006, A wireless sensors network for monitoring environmental variables in a tomato greenhouse, *Proceedings of the IEEE International Workshop on Factory Communication Systems*, 10.
16. Ahonen, T., Virrankoski, R., Elmusrati, M., 2008, Greenhouse monitoring with wireless sensor network, *Proceedings of the IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications*, pp. 403-408, IEEE.
17. Singh, R. K., Aernouts, M., De Meyer, M., Weyn, M., Berkvens, R., 2020, Leveraging LoRaWAN technology for precision agriculture in greenhouses, *Sensors*, 20(7), pp. 1827.
18. van Tuijl, B., van Os, E., van Henten, E., 2007, Wireless sensor networks: state of the art and future perspective, *Proceedings of the International Symposium on High Technology for Greenhouse System Management (Greensys 2007)*, 801, pp. 547-554.
19. Balendonck, J., van Os, E., van der Schoor, R., van Tuijl, B., Keizer, L. C. P., 2010, Monitoring spatial and temporal distribution of temperature and relative humidity in greenhouses based on wireless sensor technology.
20. Chen, T. C., Chen, T. S., & Wu, P. W., 2011, On data collection using mobile robot in wireless sensor networks, *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41(6), pp. 1213-1224.
21. Bhadre, R., & Yeole, P., 2022, Deployment of AGRI-BOT in Greenhouse Administration, *arXiv preprint arXiv:2206.07266*.
22. Gupta, A., Gupta, H. P., Kumari, P., Mishra, R., Saraswat, S., Dutta, T., 2018, A real-time precision agriculture monitoring system using mobile sink in WSNs, *Proceedings of the IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS)*, pp. 1-5.
23. Li, X., Ma, Z., Chu, X., Liu, Y., 2019, A cloud-assisted region monitoring strategy of mobile robot in smart greenhouse, *Mobile Information Systems*, 2019(1), pp. 5846232.
24. Rosero-Montalvo, P. D., Gordillo-Gordillo, C. A., Hernandez, W., 2023, Smart farming robot for detecting environmental conditions in a greenhouse, *IEEE Access*, 11, pp. 57843-57853.

25. Iida, K., Kumamoto, H., Nakamura, S., Ueda, E., 2020, Mobile robot for environmental measurement in greenhouse, *Journal of the Institute of Industrial Applications Engineers*, 8(1), pp. 33-38.
26. Thanet Earth, 2023, *Wikipedia*, truy cập từ: https://en.wikipedia.org/wiki/Thanet_Earth
27. Barbedo, J. G. A., 2019, Detection of nutrition deficiencies in plants using proximal and remote sensing - A review, *Computers and Electronics in Agriculture*, 162, pp. 482–495.
28. Xu, Z., Li, S., Zhou, J., Zhang, C., 2020, Using deep convolutional neural networks for image-based diagnosis of nutrient deficiencies in rice, *Plant Methods*, 16(1), pp. 1-12.
29. Mahlein, A.-K., 2020, A review of imaging techniques for plant disease detection, *Computers and Electronics in Agriculture*, 172, pp. 105-114.
30. Singh, V., Misra, A. K., 2023, A review of plant disease detection systems for farming applications, *Applied Sciences*, 13(10), pp. 5982.
31. Kumar, V., Vani, K., 2018, Agricultural robot: leaf disease detection and monitoring the field condition using machine learning and image processing, *International Journal of Computational Intelligence Research*, 14(7), pp. 551-561.
32. Rizk, H., Habib, M. K., 2018, Robotized early plant health monitoring system, *Proceedings of the IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, pp. 3795-3800, IEEE.
33. Ouyang, C., Hatsugai, E., Shimizu, I., 2022, Tomato disease monitoring system using modular extendable mobile robot for greenhouses: automatically reporting locations of diseased tomatoes, *Agronomy*, 12(12), pp. 3160.
34. Seo, D., Cho, B. H., Kim, K. C., 2021, Development of monitoring robot system for tomato fruits in hydroponic greenhouses, *Agronomy*, 11, pp. 2211.
35. Zhou, X., Wang, P., Dai, G., Yan, J., Yang, Z., 2021, Tomato fruit maturity detection method based on YOLOv4 and statistical color model, *Proceedings of the 2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*, Jiaxing, China, IEEE, pp. 904-908.
36. Fonteijn, H., Afonso, M., Lensink, D., Mooij, M., Faber, N., Vroegop, A., Polder, G., Wehrens, R., 2021, Automatic phenotyping of tomatoes in production greenhouses using robotics and computer vision: from theory to practice, *Agronomy*, 11, pp. 1599.
37. Wang, Y., Fu, C., Huang, R., Tong, K., He, Y., Xu, L., 2024, Path planning for mobile robots in greenhouse orchards based on improved A* and fuzzy DWA algorithms, *Computers and Electronics in Agriculture*, 227, pp. 109598.

38. Zhang, X., Duan, Y., Li, X., Yang, J., Li, D., Zhao, R., Yang, W., 2025, Path planning for greenhouse robots using a hybrid Dung Beetle algorithm, *Intelligent Service Robotics*, pp. 1-25.
39. Pawlowski, A., Guzman, J. L., Rodríguez, F., Berenguel, M., Sánchez, J., Dormido, S., 2009, Simulation of greenhouse climate monitoring and control with wireless sensor network and event-based control, *Sensors*, 9(1), pp. 232-252.
40. Kiran, M., Kamal, K., Gupta, N., 2011, Study of data fusion in wireless sensor network, *Proceedings of the International Conference on Advanced Computing and Communication Technologies (ACCT 2011)*, pp. 535-539.
41. Yassue, R. M., Galli, G., Borsato Jr, R., Cheng, H., Morota, G., & Fritsche-Neto, R., 2022, A low-cost greenhouse-based high-throughput phenotyping platform for genetic studies: a case study in maize under inoculation with plant growth-promoting bacteria, *The Plant Phenome Journal*, 5(1), pp. 20043.
42. Yépez-Ponce, D. F., Salcedo, J. V., Rosero-Montalvo, P. D., Sanchis, J., 2023, Mobile robotics in smart farming: current trends and applications, *Frontiers in Artificial Intelligence*, 6, pp. 1213330.
43. Min, X., Wei-Ren, S., Chang-Jiang, J., Ying, Z., 2010, Energy efficient clustering algorithm for maximizing lifetime of wireless sensor networks, *AEU - International Journal of Electronics and Communications*, 64(4), pp. 289-298.
44. Wang, Y.-H., & Su, W.-H., 2022, Convolutional neural networks in computer vision for grain crop phenotyping: a review, *Agronomy*, 12(11), pp. 2659.
45. Upadhyay, A., Chandel, N. S., Singh, K. P., et al., 2025, Deep learning and computer vision in plant disease detection: a comprehensive review of techniques, models, and trends in precision agriculture, *Artificial Intelligence Review*, 58, pp. 92.
46. Ngô Quang Ước, 2023, Luận án tiến sỹ, Đại học Bách Khoa Hà Nội.
47. Ram, B. G., Oduor, P., Igathinathane, C., Howatt, K., Sun, X., 2024, A systematic review of hyperspectral imaging in precision agriculture: analysis of its current state and future prospects, *Computers and Electronics in Agriculture*, 222, pp. 109037.
48. Vidal, D., Pitarma, R., 2019, Infrared thermography applied to tree health assessment: a review, *Agriculture*, 9(7), pp. 156.
49. Balafas, V., Karantoumanis, E., Louta, M., & Ploskas, N., 2023, Machine learning and deep learning for plant disease classification and detection, *IEEE Access*, 11, pp. 114352-114377.
50. Hari Baksh, A., Thottempudi, K., Khatal, M. M., Sujatha, G. S., Das, N., Alam, M. A., Karanwal, R., & Priya, P., 2024, Advancing agriculture through artificial intelligence: Plant disease detection methods, applications, and limitations, *Journal of Advances in Biology & Biotechnology*, 27(8), pp. 730-739.

51. Saleem, M. H., Potgieter, J., & Arif, K. M., 2019, Plant disease detection and classification by deep learning, *Plants*, 8(11), pp. 468.
52. Shrestha, G., Das, M., & Dey, N., 2020, October, Plant disease detection using CNN, in *2020 IEEE Applied Signal Processing Conference (ASPCON)*, pp. 109-113.
53. Shelar, N., Shinde, S., Sawant, S., Dhumal, S., & Fakir, K., 2022, Plant disease detection using CNN, in *ITM Web of Conferences*, 44, p. 03049.
54. Sun, X., Li, G., Qu, P., Xie, X., Pan, X., & Zhang, W., 2022, Research on plant disease identification based on CNN, *Cognitive Robotics*, 2, pp. 155-163.
55. Phunopas, A., & Inoue, S., 2018, Motion improvement of four-wheeled omnidirectional mobile robots for indoor terrain, *Journal of Robotics, Networking and Artificial Life*, 4(4), pp. 275-282.
56. Nguyen Minh Dong., 2024, Luận án Tiến sỹ, Học viện Khoa học Công nghệ, viện Hàn lâm Khoa học và công nghệ Việt Nam.
57. Song, J. B., & Byun, K. S., 2006, Design and control of an omnidirectional mobile robot with steerable omnidirectional wheels, in *Mobile Robotics, Moving Intelligence*, IntechOpen.
58. Chen, Y., Wang, X., Hong, S., Zhong, X., & Zou, C., 2017, Motion planning implemented in ROS for mobile robot, *Proceedings of the 29th Chinese Control and Decision Conference (CCDC)*, pp. 7149-7154.
59. Rösmann, C., Hoffmann, F., & Bertram, T., 2017, Online trajectory planning in ROS under kinodynamic constraints with timed-elastic-bands, *Robot Operating System (ROS) – The Complete Reference, Volume 2*, pp. 231-261.
60. Yick, J., Mukherjee, B., Ghosal, D., 2008, Wireless sensor network survey, *Computer Networks*, 52(12), pp. 2292-2330.
61. Kumar, P., Reddy, S. R. N., 2020, Wireless sensor networks: a review of motes, wireless technologies, routing algorithms and static deployment strategies for agriculture applications, *CSI Transactions on ICT*, 8(3), pp. 331-345.
62. Nguyen, H. T., Van Nguyen, L., Le, H. X., 2017, Efficient approach for maximizing lifespan in wireless sensor networks by using mobile sinks, *ETRI Journal*, 39(3), pp. 353-363.
63. Farooq, M. S., Riaz, S., Helou, M. A., Khan, F. S., Abid, A., Alvi, A., 2022, Internet of things in greenhouse agriculture: a survey on enabling technologies, applications, and protocols, *IEEE Access*, 10, pp. 53374-53397.
64. Abd Ellatief, W., Younes, O., Ahmed, H., Hadhoud, M., 2016, Energy efficient density-based clustering technique for wireless sensor network, *Proceedings of the 2016 8th International Conference on Knowledge and Smart Technology (KST)*, pp. 196-200, IEEE.

65. del Castillo, J. M., 1999, A heuristic for the traveling salesman problem based on a continuous approximation, *Transportation Research Part B: Methodological*, 33(2), pp. 123-152.
66. Wang, J., Li, B., Xia, F., Kim, C. S., Kim, J. U., 2014, An energy efficient distance-aware routing algorithm with multiple mobile sinks for wireless sensor networks, *Sensors*, 14(8), pp. 15163-15178.
67. Okyere, F. G., Cudjoe, D., Sadeghi-Tehran, P., Virlet, N., Riche, A. B., Castle, M., Greche, L., Mohareb, F., Simms, D., Mhada, M., Hawkesford, M. J., 2023, Machine learning methods for automatic segmentation of images of field and glasshouse-based plants for high-throughput phenotyping, *Plants (Basel)*, 12(10).
68. Gonzales, R. C., Woods, R. E., 2018, *Digital Image Processing*, 4th edition.
69. Tiwari, S., Singh, A. K., Shukla, V. P., 2011, Statistical moments based noise classification using feed forward back propagation neural network, *International Journal of Computer Applications*, 18(2), pp. 36-40.
70. Mallat, S. G., 1989, A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11, pp. 674-693.
71. Donoho, D. L., 2002, De-noising by soft-thresholding, *IEEE Transactions on Information Theory*, 41(3), pp. 613-627.
72. Wei, D., Rajashekar, U., Bovik, A. C., 2005, Wavelet denoising for image enhancement, *Handbook of Image and Video Processing*, 2nd ed., Bovik, A. (Ed.), pp. 157-165.
73. Govindan, S. M., Duraisamy, P., Yuan, X., 2014, Adaptive wavelet shrinkage for noise robust speaker recognition, *Digital Signal Processing*, 33, pp. 180-190.
74. Chang, S.G., Yu, B. and Vetterli, M., 2000, Adaptive wavelet thresholding for image denoising and compression, *IEEE transactions on image processing*, 9(9), pp.1532-1546.
75. Banham, M.R. and Katsaggelos, A.K., 2002, Digital image restoration, *IEEE signal processing magazine*, 14(2), pp.24-41.
76. Gu, H., Wang, Y., Hong, S., Gui, G., 2019, Blind channel identification aided generalized automatic modulation recognition based on deep learning, *IEEE Access*, 7, pp. 110722-110729.
77. Shetty, A. K., Saha, I., Sanghvi, R. M., Save, S. A., Patel, Y. J., 2021, A review: object detection models, *Proceedings of the 2021 6th International Conference for Convergence in Technology (I2CT)*, IEEE, pp. 1-8.
78. Hasan, R. H., Hassoo, R. M., & Aboud, I. S., 2023, Yolo Versions Architecture, *International Journal of Advances in Scientific Research and Engineering*, 9(11), pp. 73.

79. Mao, M., & Hong, M., 2025, YOLO Object Detection for Real-Time Fabric Defect Inspection in the Textile Industry: A Review of YOLOv1 to YOLOv11, *Sensors*, 25, pp. 2270.
80. El Sakka, M., Ivanovici, M., Chaari, L., Mothe, J., 2025, A review of CNN applications in smart agriculture using multimodal data, *Sensors*, 25, pp. 472.
81. Lee, Y. S., Patil, M. P., Kim, J. G., Seo, Y. B., Ahn, D. H., Kim, G. D., 2025, Hyperparameter optimization for tomato leaf disease recognition based on YOLOv11m, *Plants*, 14, pp. 653.
82. Sangaiah, A. K., Yu, F. N., Lin, Y. B., Shen, W. C., Sharma, A., 2024, UAV T-YOLO-rice: an enhanced tiny YOLO networks for rice leaves diseases detection in paddy agronomy, *IEEE Transactions on Network Science and Engineering*, 11, pp. 5201-5216.
83. Kumar, D., Malhotra, A., 2024, Fast and precise: YOLO-based wheat spot blotch recognition, *Proceedings of the 2024 5th IEEE Global Conference for Advancement in Technology (GCAT)*, Bangalore, India, 4-6 October 2024, pp. 1-5.
84. Xie, J., Xie, X., Xie, W., Xie, Q., 2025, An improved YOLOv8-based method for detecting pests and diseases on cucumber leaves in natural backgrounds, *Sensors*, 25, pp. 1551.
85. Mamun, S. B., Payel, I. J., Ahad, M. T., Atkins, A. S., Song, B., Li, Y., 2025, Grape Guard: a YOLO-based mobile application for detecting grape leaf diseases, *Journal of Electronic Science and Technology*, 23, pp. 100300.
86. Singh, Y., Shukla, S., Mohan, N., Parameswaran, S. E., Trivedi, G., 2023, Real-time plant disease detection: a comparative study, *International Conference on Agriculture-Centric Computation*, Springer Nature, Cham, Switzerland, pp. 210-224.
87. Lou, Y., Hu, Z., Li, M., Li, H., Yang, X., Liu, X., Liu, F., 2021, Real-time detection of cucumber leaf diseases based on convolution neural network, *Proceedings of the 2021 IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, Xi'an, China, 15-17 October 2021, Vol. 5, pp. 1040-1046.
88. Li, Y., et al., 2022, Attention-enhanced YOLOv7 for tomato disease classification, *Expert Systems with Applications*, 198, pp. 116805.
89. Zhang, T., et al., 2023, Multi-scale feature aggregation for cucumber disease detection using YOLOv8, *Biosystems Engineering*, 225, pp. 101-113.
90. Abulizi, A., Ye, J., Abudukelimu, H., Guo, W., 2025, DM-YOLO: improved YOLOv9 model for tomato leaf disease detection, *Frontiers in Plant Science*, 15, pp. 1473928.
91. He, Z., Tong, M., 2025, LT-YOLO: a lightweight network for detecting tomato leaf diseases, *Computers, Materials & Continua*, 82, pp. 3.

92. Rajamohan, R., Latha, B. C., 2023, An optimized YOLO v5 model for tomato leaf disease classification with field dataset, *Engineering, Technology & Applied Science Research*, 13, pp. 120330-2038.
93. Liu, Z., Guo, X., Zhao, T., Liang, S., 2025, YOLO-BSMamba: a YOLOv8s-based model for tomato leaf disease detection in complex backgrounds, *Agronomy*, 15, pp. 870.
94. Tian, Y., Ye, Q., Doermann, D., 2025, Yolov12: attention-centric real-time object detectors, *arXiv preprint*, arXiv:2502.12524.
95. Li, Y., Yan, H., Li, D., Wang, H., 2024, Robust miner detection in challenging underground environments: an improved YOLOv11 approach, *Applied Sciences*, 14, pp. 11700.
96. Cheng, S., Han, Y., Wang, Z., Liu, S., Yang, B., Li, J., 2025, An underwater object recognition system based on improved YOLOv11, *Electronics*, 14, pp. 201.
97. Ye, T., Huang, S., Qin, W., Tu, H., Zhang, P., Wang, Y., Gao, C., Gong, Y., 2025, YOLO-FIX: improved YOLOv11 with attention and multi-scale feature fusion for detecting glue line defects on mobile phone frames, *Electronics*, 14, pp. 927.
98. Liao, Y., Li, L., Xiao, H., Xu, F., Shan, B., Yin, H., 2025, YOLO-MECD: citrus detection algorithm based on YOLOv11, *Agronomy*, 15, pp. 687.
99. Khanam, R., Hussain, M., 2024, Yolov11: an overview of the key architectural enhancements, *arXiv preprint*, arXiv:2410.17725.
100. Shrestha, G., Das, M., & Dey, N., 2020, October, Plant disease detection using CNN, *In 2020 IEEE applied signal processing conference (ASPCON)*, pp. 109-113.
101. Elfving, S., Uchibe, E., Doya, K., 2018, Sigmoid-weighted linear units for neural network function approximation in reinforcement learning, *Neural Networks*, 107, pp. 3-11.
102. Mohanty, S. P., Hughes, D. P., Salathé, M., 2016, Using deep learning for image-based plant disease detection, *Frontiers in Plant Science*, 7, pp. 1419.
103. Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., Batra, N., 2020, PlantDoc: a dataset for visual plant disease detection, *Proceedings of the 7th ACM IKDD CoDS and 25th COMAD*, Hyderabad, India, 5-7 January 2020, pp. 249-253.
104. Uoc, N. Q., Duong, N. T., Son, L. A., Thanh, B. D., 2022, A novel automatic detecting system for cucumber disease based on the convolution neural network algorithm, *GMSARN International Journal*, 16, pp. 295-301.