

ĐẠI HỌC ĐÀ NẴNG
TRƯỜNG ĐẠI HỌC BÁCH KHOA
KHOA QUẢN LÝ DỰ ÁN

ĐỒ ÁN TỐT NGHIỆP
NGÀNH: QUẢN LÝ CÔNG NGHIỆP

ĐỀ TÀI:
**ỨNG DỤNG KỸ THUẬT HỌC SÂU
TRONG DỰ BÁO TIÊU THỤ NĂNG LƯỢNG
TẠI NHÀ MÁY SẢN XUẤT THÔNG MINH**

Người hướng dẫn: **TS. NGUYỄN THỊ PHƯƠNG QUYÊN**

Sinh viên thực hiện: **NGUYỄN THỊ MỸ HẠ**

Số thẻ sinh viên: **118210012**

Lớp: **21QLCN1**

Đà Nẵng, tháng 6 năm 2025.

ĐẠI HỌC ĐÀ NẴNG
TRƯỜNG ĐẠI HỌC BÁCH KHOA
KHOA QUẢN LÝ DỰ ÁN

ĐỒ ÁN TỐT NGHIỆP
NGÀNH: QUẢN LÝ CÔNG NGHIỆP

ĐỀ TÀI:
ỨNG DỤNG KỸ THUẬT HỌC SÂU
TRONG DỰ BÁO TIÊU THỤ NĂNG LƯỢNG
TẠI NHÀ MÁY SẢN XUẤT THÔNG MINH

Người hướng dẫn: **TS. NGUYỄN THỊ PHƯƠNG QUYÊN**

Sinh viên thực hiện: **NGUYỄN THỊ MỸ HẠ**

Số thẻ sinh viên: **118210012**

Lớp: **21QLCN1**

Đà Nẵng, tháng 6 năm 2025.

NHẬN XÉT ĐỒ ÁN TỐT NGHIỆP

I. Thông tin chung:

1. Họ và tên sinh viên: Nguyễn Thị Mỹ Hạ
2. Lớp: 21QLCN1 Số thẻ SV: 118210012
3. Tên đề tài: Ứng dụng kỹ thuật học sâu trong dự báo tiêu thụ năng lượng tại nhà máy sản xuất thông minh
4. Người hướng dẫn: Nguyễn Thị Phương Quyên Học hàm/ học vị: Tiến Sĩ

II. Nhận xét, đánh giá đồ án tốt nghiệp:

1. Về tính cấp thiết, tính mới, khả năng ứng dụng của đề tài: (điểm tối đa là 1đ)
.....
.....
2. Về kết quả giải quyết các nội dung nhiệm vụ yêu cầu của đồ án: (điểm tối đa là 4đ)
.....
.....
3. Về hình thức, cấu trúc, bố cục của đồ án tốt nghiệp: (điểm tối đa là 2đ)
.....
.....
4. Đề tài có giá trị khoa học/ có bài báo/ giải quyết vấn đề đặt ra của doanh nghiệp hoặc nhà trường: (điểm tối đa là 1đ)
.....
.....
5. Các tồn tại, thiếu sót cần bổ sung, chỉnh sửa:
.....
.....

III. Tinh thần, thái độ làm việc của sinh viên: (điểm tối đa 2đ)
.....

IV. Đánh giá:

1. Điểm đánh giá:/10 (lấy đến 1 số lẻ thập phân)
2. Đề nghị: ☐ Được bảo vệ đồ án ☐ Bổ sung để bảo vệ ☐ Không được bảo vệ

Đà Nẵng, ngày tháng 6 năm 2025

Người hướng dẫn

NHẬN XÉT PHẢN BIỆN ĐỒ ÁN TỐT NGHIỆP

I. Thông tin chung:

- Họ và tên sinh viên: Nguyễn Thị Mỹ Hà
- Lớp: 21QLCN1 Số thẻ SV: 118210012
- Tên đề tài: Ứng dụng kỹ thuật học sâu trong dự báo tiêu thụ năng lượng tại nhà máy sản xuất thông minh
- Người phản biện: Học hàm/ học vị:.....

II. Nhận xét, đánh giá đồ án tốt nghiệp:

- Về tính cấp thiết, tính mới, khả năng ứng dụng của đề tài:

.....
.....

- Về kết quả giải quyết các nội dung nhiệm vụ yêu cầu của đồ án:

.....
.....

- Về hình thức, cấu trúc, bố cục của đồ án tốt nghiệp:

.....
.....

- Đề tài có giá trị khoa học/ có bài báo/ giải quyết vấn đề đặt ra của doanh nghiệp hoặc nhà trường:

.....
.....

- Các tồn tại, thiếu sót cần bổ sung, chỉnh sửa:

.....
.....

TT	Các tiêu chí đánh giá	Điểm tối đa	Điểm đánh giá
1	Sinh viên có phương pháp nghiên cứu phù hợp, giải quyết đủ nhiệm vụ đề án được giao	70	
1a	- Tính mới (nội dung chính của ĐATN có những phần mới so với các ĐATN trước đây). - Đề tài có giá trị khoa học, công nghệ; có tiềm năng ứng dụng thực tiễn.	10	
1b	- Kỹ năng giải quyết vấn đề; hiểu, vận dụng được kiến thức cơ bản, cơ sở chuyên ngành trong vận hành đề tài. - Chất lượng nội dung ĐATN (thuyết minh, bản vẽ, sơ đồ, chương trình, mô hình...).	50	
1c	- Có kỹ năng vận dụng thành thạo phần mềm ứng dụng trong quá trình nghiên cứu (thể hiện qua kết quả tính toán hoặc mô phỏng). - Có kỹ năng sử dụng thiết bị thí nghiệm. - Có kỹ năng làm việc nhóm (đánh giá đối với đề tài có nhóm SV thực hiện).	10	
2	Kỹ năng viết	30	
2a	- Bố cục hợp lý, lập luận rõ ràng, chặt chẽ, lời văn súc tích.	10	
2b	- Trình bày hình thức đúng bố cục, có lời cảm ơn, tên đề tài, ảnh, danh mục tài liệu tham khảo.	10	
2c	- Trình bày đẹp, hình ảnh rõ nét, có chú thích.	10	
3	Tổng điểm đánh giá theo thang 100:		
	Quy về thang 10 (lấy đến 1 số lẻ)		

- Câu hỏi đề nghị sinh viên trả lời trong buổi bảo vệ:

.....

.....

.....

.....

- Đề nghị: ☐ Được bảo vệ đề án ☐ Bổ sung để bảo vệ ☐ Không được bảo vệ

Đà Nẵng, ngày tháng 12 năm 2023

Người phản biện

TÓM TẮT

Mục tiêu của đề án là xây dựng mô hình dự báo mức tiêu thụ năng lượng trong nhà máy sản xuất thép thông minh dựa trên các kỹ thuật học sâu. Có các kỹ thuật học sâu như là CNN, DRNN, LSTM được xem xét để xây dựng mô hình. Kết quả thực nghiệm từ các mô hình trên cho thấy mô hình học sâu CNN cho kết quả dự báo vượt trội hơn có độ chính xác cao hơn so với các mô hình DRNN, LSTM. Tuy nhiên kết quả dự báo còn bị ảnh hưởng tham số huấn luyện đầu vào do đó nghiên cứu này tiếp tục kết hợp CNN với các thuật toán tối ưu lấy cảm hứng từ tự nhiên như WaOA, COA và AVOA nhằm tối ưu hóa các siêu tham số huấn luyện nâng cao hiệu quả dự báo.

Kết quả đạt được sau khi thực hiện:

- Mô hình CNN cho độ chính xác cao nhất với MAPE trung bình trên tập kiểm tra là 10.91% thấp hơn đáng kể so với DRNN là 19.77% và LSTM là 28.78%. Ngoài ra các mô hình cũng được đánh giá trên các chỉ số RMSE và MAE đều cho thấy mô hình CNN tốt hơn đáng kể so với hai mô hình còn lại.
- Việc kết hợp CNN với các thuật toán tối ưu giúp cải thiện đáng kể hiệu quả dự báo so với các mô hình đơn lẻ, khẳng định hiệu quả của tối ưu hóa trong việc tinh chỉnh mô hình học sâu.
- Mô hình kết hợp CNN-COA cho độ chính xác cao nhất, với MAPE trung bình trên tập kiểm tra đạt 6.01%, thấp hơn so với 2 mô hình CNN-WaOA với 8.04% và CNN-AVOA là 7.64%. Ngoài ra các mô hình cũng được đánh giá trên các chỉ số RMSE và MAE đều cho thấy mô hình CNN - COA tốt hơn so với hai mô hình còn lại.
- Gợi mở tiềm năng ứng dụng trong dự báo năng lượng cho các hệ thống sản xuất thông minh, đặc biệt trong ngành luyện thép.

NHIỆM VỤ ĐỒ ÁN TỐT NGHIỆP

Họ tên sinh viên: Nguyễn Thị Mỹ Hạ

Số thẻ sinh viên: 118210012

Lớp: 21QLCN1

Khoa: Quản lý dự án

Ngành: Quản lý công nghiệp

1. *Tên đề tài đồ án:* Ứng dụng kỹ thuật học sâu trong dự báo mức tiêu thụ năng lượng tại nhà máy sản xuất thông minh

2. *Đề tài thuộc diện:* ☐ Có ký kết thỏa thuận sở hữu trí tuệ đối với kết quả thực hiện

3. *Các số liệu và dữ liệu ban đầu:*

- Quy trình sản xuất thép
- Bộ dữ liệu về mức sử dụng năng lượng trong nhà máy thép
- Các tài liệu về học máy, học sâu, các phương pháp chuẩn hóa dữ liệu, các mô hình CNN, DRNN, LSTM, các thuật toán tối ưu hóa COA, WaOA, AVOA, các nghiên cứu liên quan, ...

4. *Nội dung các phần thuyết minh và tính toán:*

Chương 1: Tổng quan

Chương 2: Các nghiên cứu liên quan

Chương 3: Phân tích quy trình vận hành trong nhà máy thông minh

Chương 4: Ứng dụng học sâu để dự báo mức tiêu thụ năng lượng trong nhà máy thông minh

Chương 5: Kết luận và kiến nghị

5. *Họ tên người hướng dẫn:* TS. Nguyễn Thị Phương Quyên

6. *Ngày giao nhiệm vụ đồ án:*/...../2025.....

7. *Ngày hoàn thành đồ án:*/...../2025.....

Đà Nẵng, ngày tháng năm 2025

Trưởng Bộ môn Quản lý Công nghiệp

Người hướng dẫn

TS. Huỳnh Nhật Tố

TS. Nguyễn Thị Phương Quyên

LỜI NÓI ĐẦU

Trong kỷ nguyên công nghiệp 4.0, ngành sản xuất thép đang có những chuyển mình mạnh mẽ để đáp ứng yêu cầu phát triển bền vững, hiện đại và tối ưu hóa quy trình vận hành. Tuy nhiên, đây cũng là ngành tiêu thụ năng lượng lớn, đòi hỏi sự quản lý chặt chẽ nhằm tiết kiệm chi phí và giảm thiểu tác động môi trường. Một trong những giải pháp quan trọng là dự báo chính xác mức tiêu thụ năng lượng, từ đó hỗ trợ việc lập kế hoạch sản xuất hiệu quả và chủ động trong việc phân bổ tài nguyên.

Trước bối cảnh đó, đề tài “*Ứng dụng kỹ thuật học sâu trong dự báo mức tiêu thụ năng lượng tại nhà máy sản xuất thép thông minh*” được thực hiện nhằm nghiên cứu hiệu quả dự báo của các mô hình học sâu, đặc biệt là mô hình CNN khi kết hợp với các thuật toán tối ưu sinh học như WaOA, COA và AVOA. Mục tiêu chính là nâng cao độ chính xác trong việc dự báo mức tiêu thụ năng lượng tại nhà máy thép Daewoo, thông qua việc tìm kiếm bộ tham số huấn luyện tối ưu cho mô hình bằng phương pháp kết hợp này.

Em xin chân thành cảm ơn quý thầy cô Khoa Quản lý Dự án, ngành Quản lý Công nghiệp, Trường Đại học Bách Khoa, Đại học Đà Nẵng đã tận tình giảng dạy và truyền đạt cho em những kiến thức chuyên môn và kỹ năng quý báu trong suốt quá trình học tập. Đặc biệt, em xin gửi lời cảm ơn sâu sắc đến TS. Nguyễn Thị Phương Quyên người đã trực tiếp hướng dẫn, hỗ trợ và đồng hành cùng em trong suốt quá trình thực hiện đề tài. Sự giúp đỡ tận tình của cô là nguồn động lực lớn để em hoàn thành tốt đồ án này.

Mặc dù đã cố gắng hết mình trong quá trình nghiên cứu và viết báo cáo, nhưng do hạn chế về thời gian và kinh nghiệm nên vẫn còn những thiếu sót không thể tránh khỏi mong quý thầy cô thông cảm, em rất mong nhận được sự góp ý của quý thầy cô để hoàn thiện đề tài tốt hơn.

Đà Nẵng, ngày tháng 6 năm 2025

Sinh viên thực hiện

Nguyễn Thị Mỹ Hạ

LỜI CAM ĐOAN

Em tên là Nguyễn Thị Mỹ Hạ sinh viên lớp 21QLCN1 xin cam đoan:

- Đồ án tốt nghiệp là thành quả của quá trình nghiên cứu học hỏi dựa trên cơ sở lý thuyết, số liệu thực tế tại Công ty thu thập được, thực hiện theo sự hướng dẫn của giảng viên hướng dẫn.
- Đồ án được thực hiện hoàn toàn mới, là kết quả công sức của cá nhân tôi.
- Mọi sự tham khảo trong đồ án được trích nguồn và nằm trong danh mục tài liệu tham khảo.
- Mọi sao chép không hợp lệ, vi phạm quy chế nhà trường, tôi xin hoàn toàn chịu trách nhiệm.

Đà Nẵng, ngày tháng 6 năm 2025
Sinh viên thực hiện

Nguyễn Thị Mỹ Hạ

MỤC LỤC

TÓM TẮT.....	
LỜI NÓI ĐẦU.....	i
LỜI CAM ĐOAN	ii
MỤC LỤC	iii
DANH MỤC HÌNH ẢNH.....	vi
DANH MỤC BẢNG BIỂU.....	vii
DANH SÁCH CÁC KÝ HIỆU, CHỮ VIẾT TẮT.....	viii
CHƯƠNG 1: TỔNG QUAN	1
1.1. Bối cảnh nghiên cứu.....	1
1.2. Vấn đề đặt ra.....	2
1.3. Mục tiêu nghiên cứu	2
1.4. Phạm vi nghiên cứu	3
1.5. Phương pháp nghiên cứu	3
CHƯƠNG 2: CÁC NGHIÊN CỨU LIÊN QUAN.....	4
2.1. Nghiên cứu trong và ngoài nước về dự báo năng lượng	4
2.1.1. Nghiên cứu trong nước.....	4
2.1.2. Nghiên cứu ngoài nước	5
2.2. Một số cơ sở lý thuyết liên quan	7
2.2.1. Dự báo chuỗi thời gian	7
2.2.2. Học máy và học sâu.....	8
2.2.3. Một số phương pháp chuẩn hóa dữ liệu	9
2.3.3.1. Chuẩn hóa min max.....	10
2.3.3.2. Chuẩn hóa trung bình	10

2.2.3.3. Chuẩn hóa điểm Z	11
2.2.4. Quy trình dự báo.....	11
2.2.5. Đánh giá mô hình MAPE, RMSE, MAE	12
2.3. Các mô hình học máy trong dự báo.....	13
2.3.1. Mô hình CNN	13
2.3.2. Mô hình LSTM.....	15
2.3.3. Mô hình DRNN	17
2.4. Các thuật toán tối ưu hóa thuộc nhóm sinh học	19
2.4.1. Thuật toán tối ưu hải mã - WaOA	20
2.4.2. Thuật toán tối ưu gấu mèo mũi nhọn - COA.....	20
2.4.3. Thuật toán tối ưu kền kền châu Phi - AVOA.....	21
CHƯƠNG 3: PHÂN TÍCH QUY TRÌNH VẬN HÀNH TRONG NHÀ MÁY THÔNG MINH.....	22
3.1. Quy trình sản xuất thép.....	22
3.1.1. Xử lý nguyên liệu thô	22
3.1.2. Sản xuất gang	23
3.1.3. Luyện thép	23
3.1.4. Đúc.....	24
3.1.5. Cán thép.....	24
3.2. Đặc điểm của nhà máy truyền thống	24
3.3. Nhà máy thông minh và khả năng thu thập dữ liệu thời gian thực	25
3.4. So sánh giữa nhà máy truyền thống và nhà máy thông minh trong bối cảnh dự báo mức tiêu thụ năng lượng	26
CHƯƠNG 4: ỨNG DỤNG HỌC SÂU ĐỂ DỰ BÁO MỨC TIÊU THỤ NĂNG LƯỢNG TRONG NHÀ MÁY THÔNG MINH.....	29
4.1. Thu thập dữ liệu.....	29
4.1.1. Thông tin dữ liệu	29
4.1.2. Phân tích dữ liệu khám phá	31

4.1.2.2. Phân tích phân bố và đặc điểm của các thuộc tính trong tập dữ liệu ...	31
4.1.2.1. Ma trận hệ số tương quan	34
4.2. Thiết kế mô hình học sâu.....	35
4.2.1. Kiến trúc và mô tả các mô hình học sâu.....	35
4.2.1.1. Mô hình CNN	35
4.2.1.2. Mô hình DRNN	37
4.2.1.3. Mô hình LSTM.....	38
4.2.1.4. Huấn luyện, kiểm tra và đánh giá mô hình học sâu	39
4.2.2. Mô hình kết hợp học sâu và các thuật toán tối ưu hóa sinh học.....	45
4.2.2.1. Mô hình kết hợp CNN – WaOA.....	46
4.2.2.2. Mô hình kết hợp CNN – COA	51
4.2.2.3. Mô hình kết hợp CNN – AVOA	55
4.3. Phân tích kết quả	60
4.3.1. Kết quả tìm kiếm tham số tối ưu cho CNN bằng các thuật toán tối ưu hóa.....	60
4.3.2. Kết quả dự báo của mô hình CNN kết hợp với thuật toán tối ưu.....	61
4.4. Biểu đồ so sánh dự báo với thực tế	67
4.5. Ứng dụng và triển khai thực tế	68
4.5.1. Các bước triển khai mô hình vào thực tế.....	68
4.5.2. Những lưu ý khi triển khai mô hình	68
CHƯƠNG 5: KẾT LUẬN VÀ KIẾN NGHỊ	69
5.1. Kết luận.....	69
5.2. Kiến nghị	70
TÀI LIỆU THAM KHẢO	

DANH MỤC HÌNH ẢNH

Hình 2.1. Kiến trúc tổng thể của mạng CNN [29].	13
Hình 2.2. Sơ đồ của quá trình tích chập [30].	14
Hình 2.3. Tính toán giá trị đầu ra của hoạt động gộp 3×3 trên đầu vào 5×5 [33].	15
Hình 2.4. Cấu trúc của mạng LSTM [37].	16
Hình 2.5. minh họa cấu trúc của DRNN [38].	18
Hình 3.1. Quy trình sản xuất thép [45].	22
Hình 4.1. Phân bố của thuộc tính mục tiêu.	32
Hình 4.2. Phân bố của các thuộc tính định lượng.	33
Hình 4.3. Phân bố của các thuộc tính định tính.	33
Hình 4.4. Ma trận hệ số tương quan giữa các thuộc tính	34
Hình 4.5. Kiến trúc mô hình CNN	36
Hình 4.6. Kiến trúc mô hình DRNN.	37
Hình 4.7. Kiến trúc mô hình LSTM	38
Hình 4.8. Giá trị MAPE trung bình trên tập kiểm tra của các mô hình	41
Hình 4.9. Giá trị RMSE trung bình trên tập kiểm tra của các mô hình.	42
Hình 4.10. Giá trị MAE trung bình trên tập kiểm tra của các mô hình.	44
Hình 4.11. Kiến trúc của phương pháp đề xuất.	46
Hình 4.12. Giá trị MAPE trung bình trên tập kiểm tra của các mô hình kết hợp	63
Hình 4.13. Giá trị RMSE trung bình trên tập kiểm tra của các mô hình kết hợp.	64
Hình 4.14. Giá trị MAE trung bình trên tập kiểm tra của các mô hình kết hợp.	66
Hình 4.15. Biểu đồ so sánh dự báo với thực tế của CNN-COA trên tập kiểm tra	67

DANH MỤC BẢNG BIỂU

Bảng 2.1. Các giá trị MAPE	12
Bảng 3.1. So sánh nhà máy thông minh và nhà máy truyền thống	27
Bảng 4.1. Các thuộc tính trong bộ dữ liệu.....	30
Bảng 4.2. Thông tin thống kê mô tả các thuộc tính.....	30
Bảng 4.3. Kết quả dự báo MAPE trên tập huấn luyện cho các mô hình.....	40
Bảng 4.4. Kết quả dự báo MAPE trên tập kiểm tra cho các mô hình	40
Bảng 4.5. Kết quả dự báo RMSE trên tập huấn luyện cho các mô hình	41
Bảng 4.6. Kết quả dự báo RMSE trên tập kiểm tra cho các mô hình	42
Bảng 4.7. Kết quả dự báo MAE trên tập huấn luyện cho các mô hình	43
Bảng 4.8. Kết quả dự báo MAE trên tập kiểm tra cho các mô hình	43
Bảng 4.9. Thời gian huấn luyện trung bình của các mô hình học sâu	44
Bảng 4.10. Các tham số huấn luyện tối ưu cho mô hình CNN kết hợp	60
Bảng 4.11. Kết quả dự báo MAPE trên tập huấn luyện cho các mô hình kết hợp.....	62
Bảng 4.12. Kết quả dự báo MAPE trên tập kiểm tra cho các mô hình kết hợp	62
Bảng 4.13. Kết quả dự báo RMSE trên tập huấn luyện cho các mô hình kết hợp	63
Bảng 4.14. Kết quả dự báo RMSE trên tập kiểm tra cho các mô hình kết hợp	64
Bảng 4.15. Kết quả dự báo MAE trên tập huấn luyện cho các mô hình kết hợp	65
Bảng 4.16. Kết quả dự báo MAE trên tập kiểm tra cho các mô hình kết hợp	65

DANH SÁCH CÁC KÝ HIỆU, CHỮ VIẾT TẮT

KÝ HIỆU:

Ký hiệu	Tên gọi	Diễn giải
x	Biến đầu vào	Tập các đặc trưng của dữ liệu đầu vào
y_t	Biến đầu ra	Giá trị đầu ra mục tiêu trong bài toán dự báo
$\hat{y}_t$	Giá trị dự đoán	Kết quả dự đoán từ các mô hình học sâu và kết hợp
n	Số lượng mẫu	Tổng số mẫu trong tập huấn luyện hoặc kiểm tra

CHỮ VIẾT TẮT:

Ký hiệu	Tên gọi
ĐATN	Đồ án tốt nghiệp
MAE	Sai số trung bình tuyệt đối
RMSE	Căn bậc hai sai số trung bình
MAPE	Phần trăm sai số trung bình tuyệt đối
CNN	Mạng nơ-ron tích chập
LSTM	Mạng bộ nhớ dài hạn ngắn
DRNN	Mạng nơ-ron hồi quy sâu
COA	Thuật toán tối ưu gấu mèo mũi nhọn
WaOA	Thuật toán tối ưu hải mã
AVOA	Thuật toán tối ưu kền kền châu Phi
CNN-COA	Mạng nơ-ron tích chập tối ưu bằng thuật toán COA
CNN-AVOA	Mạng nơ-ron tích chập tối ưu bằng thuật toán AVOA
CNN-WaOA	Mạng nơ-ron tích chập tối ưu bằng thuật toán WaOA
ARIMA	Mô hình trung bình động tích hợp hồi quy tự động
ANN	Mạng nơ-ron nhân tạo
SVR	Hồi quy vector hỗ trợ
SVM	Máy vector hỗ trợ
RF	Hồi quy rừng ngẫu nhiên
KNN	Hồi quy k-láng giềng gần nhất
RNN	Mạng nơ-ron hồi quy đơn giản
GRU	Đơn vị hồi quy có cổng
GBM	Mô hình tăng cường độ dốc

CHƯƠNG 1: TỔNG QUAN

1.1. Bối cảnh nghiên cứu

Theo thông tin Năng lượng Hoa Kỳ tại triển vọng năng lượng quốc tế 2021 (IEO2021) mức tiêu thụ năng lượng của thế giới được dự báo sẽ tăng hơn 50% trong 30 năm tới tức là đến năm 2051 [1]. Trong đó, năm 2022 mức tiêu thụ năng lượng ngành công nghiệp chiếm 37% mức sử dụng năng lượng toàn cầu [2]. Việc tăng trưởng nhanh chóng trong sản xuất công nghiệp đã làm tăng mức tiêu thụ năng lượng và điện năng toàn cầu. Trong khi đó, điện năng là một trong những yếu tố quan trọng nhất trong hệ thống năng lượng góp phần cho sự phát triển kinh tế và không thể thiếu trong cuộc sống hàng ngày của con người [3]. Điện năng được sử dụng trong nhiều lĩnh vực sản xuất khác nhau, trong khai thác mỏ và cả trong nông nghiệp và xây dựng. Với sự gia tăng đáng kể của chi phí điện năng trong sản xuất công nghiệp, các doanh nghiệp cần phải thực hiện các chiến lược quản lý năng lượng điện năng nhằm tối ưu hóa việc sử dụng nguồn năng lượng và giảm thiểu chi phí trong quá trình sản xuất công nghiệp. Để thực hiện các chiến lược “quản trị năng lượng thông minh” như vậy, cần có sự am hiểu về nhu cầu sử dụng và xu hướng tiêu thụ năng lượng điện năng trong quá khứ và tương lai, cũng như sự hiểu biết về mối liên hệ và tương tác giữa tất cả các dòng năng lượng tiêu thụ trong các nhà máy sản xuất công nghiệp này.

Hiện nay, cùng với sự phát triển của cuộc cách mạng công nghiệp 4.0, mô hình nhà máy thông minh đã không ngừng phát triển trong lĩnh vực sản xuất công nghiệp dựa trên sự phát triển nhanh chóng của Internet vạn vật công nghiệp. Nhà máy thông minh xem quy trình sản xuất là một mạng công nghệ thông minh và tích hợp hoàn toàn tiên tiến, cho phép các cơ sở hạ tầng, các loại thiết bị và các chuỗi quy trình hoạt động vận hành mà không cần sự can thiệp của con người. Nhìn chung, khái niệm nhà máy sản xuất thông minh sẽ xoay quanh sơ đồ các quy trình tự động hóa, với khả năng quản lý tự động các hoạt động trong sản xuất công nghiệp bằng cách sử dụng phối hợp các quy trình bảng điều khiển và bộ vi điều khiển trong các kết nối chung. Tuy nhiên, thực tế cho thấy rằng các nhà máy sản xuất thông minh đòi hỏi tiêu tốn một lượng lớn năng lượng điện năng cho quy trình sản xuất và vận hành hệ thống [4]. Trong bối cảnh đó, việc quản lý và tối ưu hóa năng lượng không chỉ là yêu cầu bắt buộc đối với các doanh nghiệp mà còn góp phần đảm bảo an ninh năng lượng quốc gia [5].

1.2. Vấn đề đặt ra

Mặc dù các nhà máy thông minh đã mở ra nhiều cơ hội trong việc nâng cao năng suất và chất lượng sản phẩm, nhưng đồng thời cũng làm phức tạp hóa bài toán quản lý năng lượng. Mô hình nhà máy thông minh này đặt ra thách thức lớn về vấn đề tiêu thụ điện năng do mức độ tích hợp công nghệ cao và các hệ thống điều khiển tự động hoạt động liên tục [4]. Sự gia tăng chi phí năng lượng không chỉ ảnh hưởng đến lợi nhuận của doanh nghiệp mà còn tạo áp lực lớn lên hạ tầng năng lượng quốc gia. Thực tế cho thấy mức tiêu thụ điện trong các nhà máy thông minh thường biến động không cố định theo thời gian và phụ thuộc rất nhiều yếu tố phức tạp [5], phi tuyến và chịu ảnh hưởng của nhiều yếu tố như số lượng máy móc hoạt động, lịch sản xuất,... Điều này khiến cho việc dự báo chính xác nhu cầu năng lượng trở nên khó khăn nhưng lại vô cùng quan trọng trong quản lý năng lượng hiệu quả.

Trong những năm gần đây, đã có nhiều nghiên cứu ứng dụng kỹ thuật học máy trong bài toán dự báo tiêu thụ năng lượng. Tuy nhiên, phần lớn các công bố hiện nay chủ yếu tập trung vào lĩnh vực tòa nhà thông minh, khu dân cư, hoặc hệ thống điều hòa năng lượng cho môi trường sống [6–9]. Chỉ một số ít nghiên cứu tiếp cận vấn đề trong lĩnh vực sản xuất công nghiệp [10–15]. Đặc biệt, các nghiên cứu chuyên sâu về dự báo mức tiêu thụ năng lượng trong môi trường nhà máy thông minh nơi có tính phức tạp cao và dữ liệu lớn vẫn còn tương đối hạn chế. Đây chính là khoảng trống nghiên cứu cần được tiếp tục khai thác. Các mô hình dự báo truyền thống như ARIMA, hồi quy tuyến tính hoặc mô hình mạng nơ-ron đơn giản thường không đủ linh hoạt để xử lý các tình huống dữ liệu phức tạp, nhiễu nhiễu và phi tuyến. Điều đó dẫn đến sai số dự báo cao, ảnh hưởng đến việc lập kế hoạch sản xuất, điều phối nguồn lực và tối ưu chi phí.

Chính vì vậy, nhu cầu phát triển các phương pháp dự báo tiên tiến, có khả năng học từ dữ liệu quá khứ và thích nghi với môi trường thay đổi trở nên cấp thiết. Đặc biệt, việc kết hợp giữa học sâu với các thuật toán tối ưu được xem là hướng đi triển vọng nhằm nâng cao hiệu quả và độ chính xác của các hệ thống dự báo tiêu thụ điện năng trong bối cảnh nhà máy thông minh.

1.3. Mục tiêu nghiên cứu

Nghiên cứu này nhằm hướng đến việc xây dựng một mô hình dự báo mức tiêu thụ điện năng hiệu quả trong môi trường nhà máy sản xuất thông minh. Để đạt được điều đó, trước hết cần phân tích đặc điểm tiêu thụ năng lượng và xác định các yếu tố ảnh hưởng đến nhu cầu điện năng theo thời gian. Trên cơ sở đó, mô hình dự báo được phát

triển không chỉ hỗ trợ doanh nghiệp quản lý năng lượng hiệu quả, mà còn góp phần giảm chi phí vận hành và nâng cao hiệu suất sản xuất.

1.4. Phạm vi nghiên cứu

Nghiên cứu tập trung vào việc phân tích và dự báo mức tiêu thụ điện năng tại một nhà máy sản xuất thông minh, sử dụng dữ liệu thực tế thu thập từ Công ty TNHH Thép Daewoo tại Gwangyang, Hàn Quốc. Dữ liệu được ghi nhận theo chu kỳ 15 phút và bao gồm các đặc trưng phản ánh tình trạng vận hành của hệ thống sản xuất như năng lượng tiêu thụ (Usage), công suất phản kháng (Lagging/Leading CrpC), hệ số công suất (CPF), chỉ số khí thải (CO₂), số giây kể từ nửa đêm (NSM), cùng với các yếu tố lịch làm việc như trạng thái ngày trong tuần (Week Status), thứ trong tuần (Day of Week) và loại tải (Load Type).

1.5. Phương pháp nghiên cứu

Để thực hiện mục tiêu nghiên cứu, mô hình học sâu được lựa chọn nhằm khai thác khả năng nhận diện các quy luật phức tạp trong tiêu thụ năng lượng. Bên cạnh đó, các thuật toán tối ưu metaheuristic được kết hợp để điều chỉnh các tham số huấn luyện, từ đó nâng cao độ chính xác của mô hình. Hiệu quả dự báo sẽ được đánh giá thông qua các chỉ số phổ biến như MAE, RMSE, MAPE.

CHƯƠNG 2: CÁC NGHIÊN CỨU LIÊN QUAN

2.1. Nghiên cứu trong và ngoài nước về dự báo năng lượng

2.1.1. Nghiên cứu trong nước

Sự hình thành và phát triển của mô hình nhà máy sản xuất thông minh đang mở ra một chương mới đầy hứa hẹn cho ngành công nghiệp sản xuất toàn cầu và Việt Nam không nằm ngoài xu hướng này. Nhận thức được tầm quan trọng của chuyển đổi số trong sản xuất không chỉ là xu hướng tất yếu mà còn là động lực quan trọng để nâng cao năng lực cạnh tranh quốc gia. Do đó, Chính phủ và các Bộ, ngành đã chủ động ban hành nhiều chính sách hỗ trợ doanh nghiệp trong việc chuyển đổi mô hình sản xuất, hướng tới phát triển bền vững [16]. Tiêu biểu là dự án hợp tác giữa Bộ Công Thương và Tập đoàn Samsung Việt Nam vào tháng 2/2022, với mục tiêu hỗ trợ 50 doanh nghiệp trên cả nước chuyển đổi sang mô hình nhà máy thông minh. Dự án này đã đạt được những kết quả tích cực, như hỗ trợ tư vấn phát triển mô hình nhà máy thông minh cho 26 doanh nghiệp trên cả nước giúp họ cải thiện hiệu quả sản xuất và quản lý đây là một bước đi chiến lược, cho thấy quyết tâm mạnh mẽ từ cả phía nhà nước và doanh nghiệp trong tiến trình đổi mới [16].

Một số doanh nghiệp tại Việt Nam đã tiên phong trong việc triển khai mô hình nhà máy thông minh và đạt được những thành tựu đáng kể. Nhà máy GE Hải Phòng thuộc Tập đoàn General Electric, với vốn đầu tư hơn 111 triệu USD, đã trở thành một trong năm nhà máy thông minh đầu tiên của GE trên toàn thế giới. Việc áp dụng công nghệ tiên tiến đã giúp nhà máy này tối ưu hóa sản xuất, tiết kiệm tới 50% thời gian hoàn tất đơn hàng, giảm lượng hàng tồn kho 20% và nâng cao năng suất thêm 20% . Tương tự, nhà máy sản xuất sữa Vinamilk tại Bình Dương và tổ hợp sản xuất xe VinFast tại Khu kinh tế Cát Hải - Hải Phòng cũng là những ví dụ điển hình về việc áp dụng thành công mô hình nhà máy thông minh tại Việt Nam [16].

Mặc dù được coi là một trong những công xưởng của khu vực Đông Nam Á, các doanh nghiệp sản xuất Việt Nam đã sớm bắt kịp với xu hướng chuyển đổi sang sản xuất thông minh. Tuy nhiên hiện nay nhiều doanh nghiệp áp dụng mô hình nhà máy thông minh đã và đang gặp phải nhiều khó khăn, thách thức. Ông Phạm Thành Đại Lĩnh, Giám đốc tư vấn Chuyển đổi số FPT Digital cho biết: " Một trong những trở ngại khiến các doanh nghiệp Việt Nam gặp khó khăn trong quá trình triển khai nhà máy thông minh là

tâm lý còn dựa khá nhiều vào lượng nhân công dồi dào với chi phí không quá cao. Mục tiêu của nhà máy thông minh là xây dựng môi trường làm việc hài hòa giữa con người và máy móc, nhất là những khâu mà con người có thể tránh được những công việc vất vả, nặng nhọc và nguy hiểm...[17].

Để làm rõ hơn mức độ quan tâm ngày càng gia tăng đối với vấn đề này, theo khảo sát của Cục phát triển doanh nghiệp, đa số doanh nghiệp nhỏ và vừa gặp nhiều khó khăn trong chuyển đổi số. Cụ thể, 60,1% doanh nghiệp khó khăn về chi phí đầu tư, ứng dụng công nghệ số; 52,3% khó khăn trong thay đổi thói quen, tập quán kinh doanh cũng như thiếu nhân lực nội bộ để ứng dụng công nghệ số; 45,4% thiếu cơ sở hạ tầng công nghệ số; 40,4% thiếu thông tin về công nghệ số; 38,5% khó khăn trong tích hợp các giải pháp công nghệ số; trên 32% thiếu sự cam kết, hiểu biết của ban lãnh đạo, quản lý doanh nghiệp... [18]. Đồng thời, theo McKinsey năm 2024 cũng nhấn mạnh rằng các công ty có thể tiết kiệm được 15 đến 30 phần trăm chi phí năng lượng bằng cách sử dụng phương pháp tiếp cận toàn diện kết hợp các giải pháp công nghệ với tối ưu hóa trang web và thiết bị để tạo ra sự thay đổi đáng kể và bền vững. [19].

Đáng chú ý, các nghiên cứu hiện nay tại Việt Nam chủ yếu tập trung vào việc phát triển và chuyển đổi sang mô hình nhà máy thông minh, trong khi các mô hình phân tích dữ liệu, đặc biệt là dữ liệu tiêu thụ năng lượng công nghiệp trong các nhà máy thông minh, vẫn chưa được quan tâm đúng mức. Điều này mở ra cơ hội lớn cho các nghiên cứu chuyên sâu nhằm tối ưu hóa hiệu quả năng lượng và nâng cao tính bền vững của các nhà máy thông minh trong tương lai.

2.1.2. Nghiên cứu ngoài nước

Các nghiên cứu về việc dự báo mức tiêu thụ năng lượng dựa trên các kỹ thuật học máy được thực hiện khá nhiều trong các năm gần đây. Phần lớn các công bố tập trung nhiều vào việc dự báo mức tiêu thụ năng lượng trong các tòa nhà [6 - 9], các phương pháp bao gồm ANN, SVR, LR, LSTM, RF, KNN và ARIMA,... được sử dụng trong các nghiên cứu này. Ngoài ra, một số ít công bố tập trung vào dự báo mức tiêu thụ năng lượng trong sản xuất [10 - 15], các mô hình học như RNN, DRNN, LSTM, GRU và hai mô hình máy học SVR và RF, ngoài ra còn có phần mềm thống kê R, ANN, SVM,... đã được dùng trong các bài toán này.

Trong đó, các nghiên cứu dự báo mức tiêu thụ năng lượng trong nhà máy thông minh vẫn còn khá nhiều hạn chế. Sathishkumar và cộng sự đã phát triển mô hình dự báo mức tiêu thụ năng lượng cho nhà máy thông minh nhằm cải thiện tỉ lệ sử dụng năng lượng cho doanh nghiệp [20]. Trong nghiên cứu này, các kỹ thuật dự báo dựa trên học

máy được sử dụng như LR, SVM, GBM, và RF. Kết quả mô hình dự báo được thực hiện trên bộ dữ liệu tại nhà máy thông minh sản xuất thép tự động tại Hàn Quốc khá chính xác với sai số dự báo RMSE của mô hình RF là 7.3. Ngoài ra, nghiên cứu của Abdoos, Mahmood và các cộng sự chỉ ra rằng CNN đặc biệt hữu ích khi xử lý dữ liệu chuỗi thời gian đa biến, trong đó tồn tại các mối quan hệ phức tạp giữa các biến. CNN có xu hướng có ít tham số hơn LSTM hoặc RNN do chia sẻ trọng số, giúp chúng hiệu quả về mặt tính toán. Dự báo năng lượng mặt trời liên quan đến các tập dữ liệu lớn trong thời gian dài (ví dụ: từ năm 2010 đến năm 2022) và CNN có thể quản lý sự phức tạp này hiệu quả hơn mà không cần nhiều bộ nhớ như LSTM hoặc RNN. Không giống như LSTM và RNN, xử lý dữ liệu theo trình tự làm chúng chậm hơn, CNN xử lý dữ liệu song song. Sự song song này cho phép CNN xử lý dữ liệu chuỗi thời gian một cách nhanh chóng và có lợi cho việc dự báo năng lượng theo thời gian thực, khi cần có những dự đoán nhanh chóng [21]. Dự đoán công suất sử dụng năng lượng nhằm mục đích phát hiện các trường hợp công suất sử dụng vượt quá hoặc bất thường. Việc dự báo chính xác có thể giúp ngăn ngừa hư hỏng máy móc hoặc việc máy móc tạm thời ngừng hoạt động, điều này có tác động trực tiếp đến tính liên tục của sản xuất. Bên cạnh đó, Yusuf và các cộng sự (2021) đã tiến hành một nghiên cứu tổng quan toàn diện nhằm làm rõ mối liên hệ giữa hiệu suất của máy công cụ và mức tiêu thụ năng lượng trong quá trình sản xuất [22]. Nghiên cứu nhấn mạnh rằng việc giám sát liên tục và tối ưu hóa hoạt động của các máy công cụ không chỉ giúp nâng cao hiệu quả vận hành mà còn đóng vai trò quan trọng trong việc phát hiện sớm các điểm bất thường hoặc các điều kiện hoạt động kém hiệu quả. Thông qua việc tích hợp các công nghệ tiên tiến và chiến lược giảm thiểu năng lượng, các nhà máy sản xuất có thể cải thiện đáng kể khả năng kiểm soát năng lượng, từ đó hướng đến mục tiêu phát triển bền vững trong bối cảnh sản xuất công nghiệp thông minh. Từ đó, các nhà quản lý có thể xác định các máy móc hoặc quy trình gây ra tình trạng kém hiệu quả về năng lượng trong hệ thống sản xuất và cho phép tiết kiệm đáng kể mức tiêu thụ năng lượng bằng cách tác động vào các yếu tố này.

Nhìn chung, quản lý nguồn năng lượng là một trong những yếu tố không thể thiếu trong việc quản lý quy trình sản xuất và có tác động mạnh mẽ đến việc tổ chức công việc, vận hành máy móc và sản xuất. Việc dự báo mức tiêu thụ năng lượng trong các nhà máy sản xuất thông minh là rất quan trọng để triển khai các hệ thống quản lý tiết kiệm năng lượng nhằm tối ưu hóa nhu cầu và chi phí năng lượng để tối đa hóa hiệu quả sử dụng năng lượng của nhà máy. Tuy nhiên, các công trình nghiên cứu về dự báo mức tiêu thụ năng lượng trong nhà máy thông minh còn hạn chế. Phần lớn các nhà máy thông minh trên nền tảng Công nghiệp 4.0 đều dựa vào khái niệm hệ thống sản xuất thực ảo

(CPPS) cho phép kết nối giữa các thiết lập vật lý và kỹ thuật số để tích hợp chúng trong mọi giai đoạn phát triển sản phẩm. Do đó, hầu hết các nhà nghiên cứu và các nhà quản lý tập trung vào việc phát triển các mô hình dựa trên trí tuệ nhân tạo để trang bị cho các CPPS. Ngoài ra, các bộ dữ liệu về mức tiêu thụ năng lượng trong công nghiệp sản xuất thông minh còn chưa được công khai ở dạng dữ liệu mở cũng gây không ít khó khăn cho các nhà nghiên cứu trong việc đánh giá so sánh hiệu quả của các mô hình dự báo. Bên cạnh việc xây dựng mô hình dự báo đạt được độ chính xác dự báo cao, một thách thức lớn đối với nhà máy sản xuất thông minh là dự báo mức tiêu thụ năng lượng theo thời gian thực hoặc khai thác các bộ dữ liệu tiêu thụ năng lượng theo chuỗi thời gian đo lường từ các máy cảm biến.

Do đó, nghiên cứu này tập trung vào việc phát triển mô hình dự báo mức tiêu thụ năng lượng công nghiệp hiệu quả cho nhà máy sản xuất thông minh điển hình. Các mô hình dự báo được phát triển dựa trên kỹ thuật học sâu có thể được xem xét đến như DRNN, LSTM, CNN. Bên cạnh đó, nghiên cứu này còn tích hợp các giải thuật tối ưu với các kỹ thuật dự báo dựa trên học sâu nhằm tối ưu hóa các thông số của mô hình để đạt được kết quả dự báo với độ chính xác cao. Bên cạnh các thuật toán phổ biến như GA, PSO và SCA, thuật toán tối ưu thuộc nhóm thuật toán được xây dựng dựa trên mô phỏng hành vi của sinh vật trong tự nhiên như COA, WaOA, AVOA được sử dụng trong việc phát triển mô hình dự báo tích hợp. Kết quả nghiên cứu được kỳ vọng là một mô hình dự báo mức tiêu thụ năng lượng theo thời gian thực trong các nhà máy sản xuất thông minh với độ chính xác cao.

2.2. Một số cơ sở lý thuyết liên quan

2.2.1. Dự báo chuỗi thời gian

Chuỗi thời gian là một dãy các giá trị được ghi nhận theo trình tự thời gian tại những khoảng cách đều nhau, chẳng hạn như theo năm, quý, tháng, ngày hoặc giờ. Một số ví dụ tiêu biểu của chuỗi thời gian bao gồm: độ cao thủy triều đo được theo giờ, lưu lượng dòng chảy hàng tháng tại một trạm thủy văn, hay doanh số bán hàng quý của một doanh nghiệp. Về cơ bản, một chuỗi thời gian thường bao gồm bốn thành phần chính: xu hướng thể hiện sự thay đổi dài hạn của dữ liệu; mùa vụ mô tả các biến động có tính chu kỳ ngắn hạn; chu kỳ những biến động có chu kỳ dài hơn không cố định rõ ràng như mùa vụ; và thành phần ngẫu nhiên, tức những dao động không tuân theo quy luật cụ thể [23].

Dự báo chuỗi thời gian là quá trình dự đoán các giá trị trong tương lai của một hiện tượng dựa trên các quan sát trong quá khứ. Quá trình này bắt đầu từ việc thu thập dữ liệu lịch sử, sau đó áp dụng các kỹ thuật thống kê, học máy, hoặc học sâu nhằm nhận

diện các mẫu trong dữ liệu và từ đó dự báo các giá trị tiếp theo. Dự báo chuỗi thời gian được chia thành hai loại chính:

- *Dự báo đơn biến* là dạng dự báo mà trong đó chỉ có một biến duy nhất được phân tích theo thời gian [23]. Ví dụ, nếu dữ liệu ghi nhận mức tiêu thụ điện năng theo giờ tại một nhà máy và mục tiêu là dự đoán giá trị tiêu thụ điện trong tương lai chỉ dựa trên dữ liệu này, thì đây là một bài toán dự báo chuỗi thời gian đơn biến.
- *Dự báo đa biến* là dạng dự báo trong đó có nhiều biến cùng được theo dõi theo thời gian. Các biến này không chỉ phụ thuộc vào giá trị quá khứ của riêng chúng mà còn ảnh hưởng lẫn nhau [23]. Chẳng hạn, tiếp tục ví dụ về dự báo tiêu thụ điện năng, nếu dữ liệu còn bao gồm các yếu tố khác như nồng độ CO₂, ngày trong tuần, trạng thái tuần, loại hoạt động, hệ số công suất,... thì các yếu tố này sẽ được đưa vào mô hình để hỗ trợ dự báo chính xác hơn. Đây chính là bài toán dự báo chuỗi thời gian đa biến, nơi mối quan hệ giữa nhiều yếu tố được khai thác để nâng cao hiệu quả dự đoán.

2.2.2. Học máy và học sâu

Học máy là một nhánh của trí tuệ nhân tạo, tập trung vào việc phát triển các thuật toán cho phép máy tính học từ dữ liệu và cải thiện hiệu suất theo thời gian mà không cần sự can thiệp nhiều của con người. Học máy gồm nhiều loại khác nhau, thường bao gồm học có giám sát như hồi quy và phân loại, học không giám sát như phân cụm và giảm số chiều dữ liệu, học bán giám sát, học tăng cường, học truyền dẫn, và học theo nhóm. Các mô hình học máy được xây dựng dựa trên dữ liệu huấn luyện, từ đó học cách nhận diện mẫu, khám phá các quy luật tiềm ẩn trong dữ liệu, và đưa ra dự đoán cho dữ liệu mới. Hiện nay, học máy đã được ứng dụng rộng rãi trong nhiều lĩnh vực như: xử lý ngôn ngữ tự nhiên, thị giác máy tính, tài chính, y học, và đặc biệt là trong các bài toán dự báo chuỗi thời gian nơi yêu cầu phát hiện và khai thác các mối quan hệ theo thời gian để dự đoán tương lai [24].

Học sâu là một nhánh của học máy, sử dụng các mạng nơ-ron nhân tạo nhiều lớp để mô hình hóa các mối quan hệ phức tạp trong dữ liệu [24]. Nhờ khả năng tự động trích xuất đặc trưng từ dữ liệu đầu vào mà không cần can thiệp thủ công, học sâu đã chứng minh hiệu quả vượt trội trong việc xử lý dữ liệu phi cấu trúc như hình ảnh, âm thanh, văn bản, và cả chuỗi thời gian. Trong dự báo chuỗi thời gian, các kiến trúc mạng như RNN, LSTM, CNN,... đã được ứng dụng thành công để nắm bắt các mối quan hệ phụ thuộc dài hạn trong dữ liệu.

Ưu điểm của học sâu trong dự báo chuỗi thời gian

Theo Kong và cộng sự, so với các phương pháp học máy truyền thống, học sâu mang lại nhiều ưu điểm nổi bật trong các bài toán dự báo chuỗi thời gian, đặc biệt trong bối cảnh dữ liệu sản xuất phức tạp, có tính biến động cao và nhiều yếu tố ảnh hưởng. Học sâu có khả năng tự động trích xuất các đặc trưng thời gian phức tạp và mô hình hóa các quan hệ phức tạp, từ đó giúp nâng cao độ chính xác của dự báo [25].

Thứ nhất, *khả năng tự động trích xuất đặc trưng* là một ưu điểm quan trọng của học sâu. Trong khi các mô hình học máy yêu cầu kỹ sư dữ liệu phải thực hiện quá trình chọn lọc đặc trưng đầu vào thủ công, thì các mạng học sâu có thể học trực tiếp từ dữ liệu thô và tự động phát hiện ra các đặc trưng tiềm ẩn. Điều này không chỉ tiết kiệm thời gian xử lý dữ liệu mà còn giúp mô hình phát hiện được các mối quan hệ phi tuyến mà con người có thể bỏ sót.

Thứ hai, học sâu *xử lý tốt các mối quan hệ phức tạp phi tuyến và phụ thuộc thời gian dài*. Các kiến trúc như LSTM và GRU được thiết kế để ghi nhớ thông tin theo thời gian và có khả năng học được các quy luật biến động phức tạp trong chuỗi dữ liệu. Điều này giúp tăng độ chính xác trong các bài toán dự báo trung và dài hạn.

Thứ ba, học sâu thường *cho hiệu suất cao hơn* so với các mô hình truyền thống trong các môi trường dữ liệu thực tế vốn có nhiều nhiễu, biến đổi theo mùa hoặc xu hướng không ổn định. Khả năng học biểu diễn sâu giúp mô hình học sâu thích nghi tốt với nhiều loại biến động khác nhau, từ đó cải thiện chất lượng dự báo.

2.2.3. Một số phương pháp chuẩn hóa dữ liệu

Mục tiêu chính của chuẩn hóa dữ liệu là đảm bảo chất lượng dữ liệu trước khi đưa vào bất kỳ thuật toán học máy nào. Có nhiều phương pháp chuẩn hóa khác nhau, trong đó phổ biến nhất là chuẩn hóa theo min-max, Z-score, tỷ lệ thập phân hoặc chuẩn hóa theo trung vị. Việc chuẩn hóa giúp đưa các đặc trưng đầu vào về cùng một phạm vi giá trị, từ đó giảm thiểu độ lệch giữa các đặc trưng và ngăn chặn tình trạng một đặc trưng chi phối quá trình học của mô hình, đặc biệt là trong mạng nơ-ron. Ngoài ra, chuẩn hóa còn giúp tăng tốc độ huấn luyện bằng cách khởi đầu quá trình học với các đầu vào có tỷ lệ tương đương nhau. Điều này đặc biệt hữu ích trong các bài toán mô hình hóa, nơi mà dữ liệu đầu vào thường có đơn vị và phạm vi giá trị khác nhau [26]. Thật vậy, tầm quan trọng của việc chuẩn hóa dữ liệu trong việc xây dựng các mô hình dự đoán chính xác đã được kiểm tra rộng rãi trên nhiều thuật toán học máy khác nhau. Chuẩn hóa dữ liệu đóng vai trò quan trọng trong việc chuẩn bị dữ liệu đầu vào để lập mô hình, vì nó giúp giảm thiểu tác động của các thang đo và phân phối các tính năng khác nhau.

Ba lược đồ chuẩn hóa khác nhau được sử dụng rộng rãi được đề xuất nhằm cải thiện hiệu suất dự báo của mô hình. Các phương pháp chuẩn hóa này được thiết kế để xử lý trước dữ liệu đầu vào, đầu ra và nâng cao hiệu suất và hiệu quả của các mô hình. Mỗi lược đồ chuẩn hóa được thiết kế để giải quyết các đặc trưng cụ thể của dữ liệu và điều chỉnh các tính năng đầu vào để phù hợp hơn với kiến trúc mạng nơ-ron. Ba lược đồ chuẩn hóa bao gồm các kỹ thuật như: tỷ lệ Min-Max, chuẩn hóa trung bình, chuẩn hóa điểm Z.

2.3.3.1. Chuẩn hóa min max

Min-Max Scaling điều chỉnh các giá trị đặc trưng về trong phạm vi $[0,1]$ và $[-1,1]$ hoặc phạm vi bất kỳ được chỉ định để bảo toàn mối quan hệ tương đối giữa các giá trị đặc trưng [27].

Công thức được định nghĩa như sau:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.1)$$

Trong đó:

- x là giá trị gốc
- x' là giá trị sau chuẩn hóa,
- $x_{\min}, x_{\max}$ là giá trị nhỏ nhất và lớn nhất của đặc trưng.

Kỹ thuật này bảo toàn mối quan hệ tương đối giữa các giá trị, đồng thời giúp cân bằng trọng số giữa các đặc trưng trong huấn luyện.

2.3.3.2. Chuẩn hóa trung bình

Chuẩn hóa trung bình là một kỹ thuật chuẩn hóa dữ liệu thường được áp dụng trong các lĩnh vực học máy và phân tích dữ liệu. Nó liên quan đến việc chia tỷ lệ dữ liệu sao cho giá trị trung bình của đối tượng trở thành số 0. Quá trình này tập trung dữ liệu xung quanh giá trị trung bình, loại bỏ hiệu quả mọi sai lệch trong các giá trị đối tượng, thích hợp khi các đặc trưng không phân bố quá rộng và không có nhiều ngoại lệ [28].

Công thức chuẩn hóa trung bình cho một đặc điểm x' như sau:

$$x' = \frac{x}{\text{mean}(x) \cdot (a_i)} \quad (2.2)$$

Trong đó: $\text{mean}(x)$ là giá trị trung bình của đặc trưng x

a_i là một hệ số điều chỉnh tùy thuộc vào mẫu

2.2.3.3. Chuẩn hóa điểm Z

Chuẩn hóa điểm Z là một kỹ thuật chuẩn hóa dữ liệu được sử dụng rộng rãi trong học máy và phân tích thống kê. Nó bao gồm việc biến đổi dữ liệu về phân phối chuẩn hóa có trung bình 0 và độ lệch chuẩn trở thành 1 [28]. Quá trình này tập trung dữ liệu xung quanh 0 và chia tỷ lệ để có độ lệch chuẩn đơn vị.

Công thức chuẩn hóa điểm z cho tính năng x' như sau:

$$x' = \frac{x - \text{mean}(x)}{\text{std}(x)} \quad (2.3)$$

Trong đó: $\text{std}(x)$ là độ lệch chuẩn của đặc trưng x

Một trong những lợi thế đáng kể của chuẩn hóa điểm z là tính mạnh mẽ của nó đối với các giá trị ngoại lệ và phù hợp cho dữ liệu phân bố chuẩn so với các phương pháp chuẩn hóa khác. Giá trị ngoại lệ là các giá trị cực trị khác biệt đáng kể so với phần lớn các điểm dữ liệu và có thể làm sai lệch các thuộc tính thống kê của tập dữ liệu.

Trong báo cáo này sử dụng phương pháp Min-Max Scaling để chuẩn hóa cả đầu vào và đầu ra. Phương pháp này đưa toàn bộ giá trị của mỗi đặc trưng về khoảng $[0, 1]$, giúp đảm bảo sự đồng nhất về thang đo giữa các thuộc tính và hạn chế ảnh hưởng của các giá trị tuyệt đối quá lớn hoặc quá nhỏ. Lý do chọn Min-Max Scaling là vì bộ dữ liệu chứa nhiều đặc trưng đầu vào có thang đo khác nhau như tải, nhiệt độ, thời gian, loại ngày,... Nếu không chuẩn hóa, các đặc trưng có giá trị lớn hơn sẽ gây ảnh hưởng không cân xứng đến trọng số và độ hội tụ của mô hình. Trong khi đó các mô hình học sâu như CNN, LSTM và DRNN rất nhạy cảm với quy mô dữ liệu. Nếu không chuẩn hóa, các thuộc tính có giá trị lớn sẽ chi phối quá trình huấn luyện, khiến mô hình khó hội tụ hoặc hội tụ sai lệch [26]. Bên cạnh đó, các mô hình hồi tiếp như LSTM và DRNN sử dụng các hàm kích hoạt như sigmoid hoặc tanh vốn chỉ hoạt động tối ưu khi đầu vào nằm trong một phạm vi giới hạn ví dụ như sigmoid hoạt động tốt nhất trong khoảng $[0, 1]$, tanh trong khoảng $[-1, 1]$. Min-Max Scaling giúp đưa dữ liệu đầu vào vào vùng hoạt động hiệu quả của các hàm kích hoạt như sigmoid hoặc tanh, từ đó tăng tốc độ huấn luyện và nâng cao độ chính xác.

2.2.4. Quy trình dự báo

Tương tự như các phương pháp phân tích dự báo khác, quá trình dự báo chuỗi thời gian thường bao gồm các bước cơ bản sau [24]:

Bước 1. Chuẩn bị dữ liệu: Dữ liệu sau khi thu thập cần được xử lý để đảm bảo chất lượng và độ tin cậy. Các công việc thường bao gồm: làm sạch dữ liệu, mã hóa các biến

phân loại, chuẩn hóa hoặc biến đổi giá trị, tạo đặc trưng mới và phân chia dữ liệu thành tập huấn luyện và kiểm tra. Trong thực tế, tập kiểm tra thường chiếm khoảng 20–30% tổng dữ liệu để đảm bảo mô hình được đánh giá khách quan về mặt hiệu suất.

Bước 2. Huấn luyện mô hình: Sử dụng tập huấn luyện để xây dựng và huấn luyện các mô hình dự báo. Có thể sử dụng nhiều mô hình khác nhau tùy thuộc vào đặc điểm dữ liệu và mục tiêu dự báo, chẳng hạn như các mô hình thống kê ARIMA, học máy RF, ANN, SVM, hoặc học sâu LSTM, CNN.

Bước 3. Kiểm tra và so sánh mô hình: Sau khi huấn luyện, các mô hình sẽ được đánh giá trên tập kiểm tra dựa trên các tiêu chí như MAE, RMSE, hoặc MAPE. Việc so sánh các chỉ số này giúp xác định mô hình nào có độ chính xác tốt nhất.

Bước 4. Cải thiện hiệu suất mô hình: Các mô hình tiềm năng sẽ được tinh chỉnh tham số bằng cách sử dụng các thuật toán tối ưu hóa và được huấn luyện lại để tối ưu hóa hiệu suất.

Bước 5. Dự báo: Sau khi chọn được mô hình và tham số tối ưu, mô hình này sẽ được áp dụng cho chuỗi dữ liệu ban đầu để thực hiện dự báo cho các bước thời gian tiếp theo.

2.2.5. Đánh giá mô hình MAPE, RMSE, MAE

Gọi $\{y_t, t = 1, 2, \dots, T\}$ là một chuỗi thời gian và $\hat{y}_t$ là giá trị dự báo tương ứng. Gọi $n (n \leq T)$ là cỡ mẫu của tập dữ liệu xem xét, chẳng hạn như tập huấn luyện hoặc tập kiểm tra được tách ra từ chuỗi $\{Y_t\}$. Để so sánh hiệu quả giữa các mô hình, một số phép đo lường hoặc chấm điểm sai số sau thường được sử dụng:

Thước đo được sử dụng rộng rãi nhất trong việc ước tính sai số dự báo, trung bình tuyệt đối của sai số phần trăm MAPE [24]. Đây là trung bình của giá trị tuyệt đối phần trăm sai số giữa giá trị thực tế và giá trị dự đoán.

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t} * 100 \quad (2.4)$$

Khi đánh giá hiệu suất của mô hình, dựa vào giá trị MAPE trong bảng 2.1 để đánh giá độ chính xác của mô hình dự báo. Các giá trị MAPE được thể hiện trong bảng 2.1.

Bảng 2.1. Các giá trị MAPE

STT	MAPE	Kết quả dự báo
1	<10	Dự báo chính xác cao
2	10 – 20	Dự báo tốt
3	20 – 50	Dự báo hợp lý
4	>50	Dự báo không chính xác

Ngoài ra, có thể sử dụng căn bậc hai của trung bình bình phương sai số RMSE để đánh giá độ chính xác của mô hình dự báo [24]. RMSE là một phép đo được sử dụng để đánh giá chất lượng của mô hình dự đoán trong phân tích dữ liệu. Nó đo lường độ chính xác của mô hình bằng cách tính căn bậc hai của trung bình cộng bình phương sai số giữa giá trị dự đoán và giá trị thực tế. Giá trị RMSE càng nhỏ thì mô hình càng tốt.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (2.5)$$

Bên cạnh đó cũng có thể đo lường bằng chỉ số trung bình tuyệt đối sai số MAE đây là trung bình của giá trị tuyệt đối sai số giữa giá trị thực tế và giá trị dự đoán [24].


$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (2.6)$$

Phần tiếp theo trình bày tóm tắt một số phương pháp dự báo phổ biến bằng kỹ thuật học máy cho dữ liệu chuỗi thời gian.

2.3. Các mô hình học máy trong dự báo


2.3.1. Mô hình CNN

CNN là một loại mạng nơ-ron sâu nổi bật nhờ khả năng tự động học và trích xuất các đặc trưng quan trọng từ dữ liệu đầu vào. Mặc dù CNN ban đầu được thiết kế để xử lý ảnh, thị giác máy tính, phát hiện đối tượng, nhận dạng giọng nói nhưng gần đây đã được ứng dụng rộng rãi và thành công trong bài toán dự báo chuỗi thời gian. Các thành phần chính của CNN bao gồm lớp tích chập, lớp gộp và lớp kết nối đầy đủ. Hình 2.1 minh họa kiến trúc tổng thể của mạng CNN, thể hiện rõ vai trò của từng lớp trong việc xử lý và biến đổi dữ liệu đầu vào một cách hiệu quả xuyên suốt toàn bộ quá trình [29].




Hình 2.1. Kiến trúc tổng thể của mạng CNN [29].

Lớp tích chập là thành phần cốt lõi trong kiến trúc của mạng CNN, đóng vai trò quan trọng trong việc học các đặc trưng từ dữ liệu đầu vào. Thông qua việc sử dụng nhiều lớp tích chập liên tiếp, mô hình có thể trích xuất các đặc trưng khác nhau ở nhiều cấp độ. Cụ thể, trong các bài toán xử lý ảnh, các lớp ở tầng dưới thường phát hiện những đặc trưng cơ bản như cạnh, đường thẳng hoặc kết cấu, trong khi các lớp ở tầng sâu hơn sẽ học được các đặc trưng phức tạp và trừu tượng hơn. Mỗi lớp tích chập sử dụng các bộ lọc học được có dạng ma trận trọng số, thường có kích thước lẻ như 3×3 , 5×5 hoặc 7×7 . Các bộ lọc này di chuyển trên bản đồ đặc trưng đầu vào để thực hiện phép tích chập tại từng vùng, qua đó làm nổi bật những thông tin quan trọng của dữ liệu. Hình 2.2 mô tả sơ đồ hoạt động của quá trình tích chập [34].



Hình 2.2. Sơ đồ của quá trình tích chập [30].

Lớp gộp thường được tích hợp ngay sau lớp tích chập nhằm mục đích giảm chiều dữ liệu (số chiều không gian) và giảm số lượng tham số trong mô hình, từ đó góp phần làm giảm chi phí tính toán cũng như hạn chế hiện tượng quá khớp [31, 32]. Một số phương pháp gộp phổ biến bao gồm: Max Pooling, Average Pooling, Spatial Pyramid Pooling, Mixed Pooling, Multi-Scale Order-Less và Stochastic Pooling [33]. Hình 2.3 trình bày ví dụ về Max Pooling, trong đó một cửa sổ trượt được áp dụng trên dữ liệu đầu vào và áp dụng hàm gộp tương ứng [33].




Hình 2.3. Tính toán giá trị đầu ra của hoạt động gộp 3×3 trên đầu vào 5×5 [33].

Lớp kết nối đầy đủ thường được bố trí ở phần cuối của mạng CNN, đóng vai trò như bộ phân loại chính trong toàn bộ mô hình. Ở lớp này, tất cả các nơ-ron được liên kết với toàn bộ nơ-ron ở lớp trước đó, tương tự như kiến trúc của mạng nơ-ron nhiều lớp truyền thống. Các đặc trưng được tạo ra từ lớp gộp hoặc tích chập cuối cùng sẽ được làm phẳng thành một vector và truyền đến lớp kết nối đầy đủ để thực hiện dự đoán đầu ra [34].

2.3.2. Mô hình LSTM

Mô hình LSTM lần đầu tiên được đề xuất bởi Schmidhuber và cộng sự vào năm 1997 [35] và sau đó được cải tiến vào năm 2013 bởi Graves [36], giúp LSTM trở nên phổ biến rộng rãi trong cộng đồng học sâu, nhằm giải quyết các hạn chế của mạng nơ-ron hồi tiếp RNN truyền thống trong việc ghi nhớ thông tin dài hạn và vấn đề tiêu biến gradient trong quá trình huấn luyện. LSTM được thiết kế với cơ chế cổng điều khiển nhằm kiểm soát dòng thông tin ra vào, từ đó quyết định phân thông tin nào cần được lưu giữ hay loại bỏ tại mỗi bước thời gian.

Mỗi đơn vị LSTM trạng thái ẩn h_t , trạng thái tế bào C_t , và ba cổng điều khiển gồm: cổng quên f_t , cổng vào i_t , và cổng đầu ra o_t để lưu giữ thông tin qua nhiều bước thời gian. Các cổng này có vai trò kiểm soát luồng thông tin được ghi nhớ hay loại bỏ tại mỗi bước thời gian [37], hình 2.4 minh họa các cổng này lần lượt thực hiện các chức năng sau:



Hình 2.4. Cấu trúc của mạng LSTM [37]

Cổng vào: Xác định thông tin mới nào từ đầu vào hiện tại x_t và trạng thái ẩn trước đó h_{t-1} sẽ được thêm vào bộ nhớ tế bào C_t . Hàm sigmoid được sử dụng để điều khiển mức độ cho phép:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.7)$$

Cổng quên: Xác định phần nào của thông tin từ trạng thái tế bào cũ C_{t-1} sẽ được giữ lại hoặc loại bỏ cho trạng thái mới. Đây là cơ chế cốt lõi giúp LSTM tránh tình trạng ghi nhớ quá nhiều hoặc quên hoàn toàn dữ liệu cũ.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.8)$$

Cổng đầu ra: Xác định phần nào của trạng thái tế bào hiện tại sẽ được sử dụng làm đầu ra h_t . Cổng này cho phép LSTM kiểm soát lượng thông tin được hiển thị ra bên ngoài, đóng vai trò như bộ lọc thông tin tạm thời.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.9)$$

Trạng thái tế bào ứng viên: Tạo ra giá trị ứng viên cập nhật cho bộ nhớ. Đây là thông tin mới có thể được thêm vào trạng thái tế bào. Hàm tanh giới hạn giá trị trong khoảng $(-1, 1)$, giúp dữ liệu không quá lớn gây mất ổn định mô hình.

$$u_t = \tanh(W_u \cdot [h_{t-1}, x_t] + b_u) \quad (2.10)$$

Cập nhật trạng thái tế bào: Trạng thái tế bào tại thời điểm hiện tại C_t được tính bằng cách kết hợp phần trạng thái cũ (sau khi qua cổng quên) và phần ứng viên cập nhật (qua cổng vào):

$$C_t = f_t * C_{t-1} + i_t * u_t \quad (2.11)$$

- Loại bỏ một phần thông tin cũ (theo cổng quên $f_t * C_{t-1}$).
- Thêm mới thông tin quan trọng từ đầu vào hiện tại (theo $i_t * u_t$).
- Dấu *: phép nhân từng phần tử, đảm bảo từng phần tử trong vector được kiểm soát độc lập.

Trạng thái ẩn: Xác định trạng thái ẩn đầu ra tại thời điểm t bằng cách lọc trạng thái tế bào thông qua hàm tanh rồi nhân với cổng đầu ra. h_t là thông tin được xuất ra từ đơn vị LSTM, và cũng là thông tin truyền cho bước tiếp theo trong chuỗi.

$$h_t = o_t * \tanh(C_t) \quad (2.12)$$

Đầu ra mô hình: Biến đổi trạng thái ẩn h_t thành đầu ra cuối cùng (ví dụ: giá trị dự đoán năng lượng tiêu thụ tại thời điểm t).

$$y_t = W_y \cdot h_t + b_y \quad (2.13)$$


Trong đó:

- Các ma trận trọng số của từng lớp là W_i, W_f, W_o và W_c
- Các giá trị f_t, i_t, o_t nằm trong khoảng $(0,1)$, nếu giá trị gần 0 thông tin bị loại bỏ hoàn toàn, ngược lại nếu giá trị gần 1 thông tin được giữ lại đầy đủ
- Các độ lệch tương ứng của các cổng là b_f, b_i, b_o và độ lệch đầu ra là b_y
- Các hàm σ là hàm sigmoid và $\tanh$ là hàm hyperbolic tangent
- h_{t-1} và h_t lần lượt là các trạng thái của lớp ẩn tại các thời điểm $t - 1$ và t
- C_{t-1} và C_t là trạng thái của tế bào tương ứng ở thời điểm $t - 1$ và t

2.3.3. Mô hình DRNN

DRNN được xây dựng dựa trên nền tảng của các mạng RNN, là một phương pháp phù hợp cho các bài toán dự đoán theo chuỗi thời gian hoặc xử lý ngôn ngữ tự nhiên, nhờ khả năng ghi nhớ các mối quan hệ phụ thuộc theo thời gian. Với cấu trúc nhiều lớp ẩn cùng các kết nối hồi tiếp, DRNN có khả năng mô hình hóa các phụ thuộc dài hạn cũng như các mẫu dữ liệu ẩn mà các mô hình mạng nơ-ron truyền thẳng (FNN) thường khó khai thác. Khác với các mô hình truyền thống, DRNN có khả năng ghi nhớ thông tin từ các bước thời gian trước đó, từ đó cho phép mô hình xử lý tốt hơn các chuỗi có độ dài thay đổi và động lực học phức tạp. Nhờ vào đặc điểm này, DRNN thường vượt trội hơn các mô hình nông trong các tác vụ như nhận dạng giọng nói, phát hiện bất thường và dự đoán theo chuỗi. [38].

Sự khác biệt chính giữa RNN và mạng DRNN là ở mạng DRNN, nhiều lớp mạng hồi quy riêng lẻ được xếp chồng lên nhau. Ý tưởng cho việc triển khai này xuất phát từ vấn đề là, trong khi RNN có độ sâu, thì khái niệm về độ sâu này không có khả năng liên quan đến việc diễn giải dữ liệu theo thứ bậc. Bằng cách áp dụng cùng một phép tính đệ quy để tính toán sự đóng góp của các nút con cho các nút cha mẹ của chúng và cùng một phép tính để tạo ra phản hồi đầu ra, mọi nút đều được biểu diễn trong cùng một không gian. Kỹ thuật này khác với việc xếp chồng các mô hình học sâu thông thường, trong đó lợi ích quan trọng của độ sâu là thứ bậc giữa các biểu diễn ẩn: về mặt khái niệm, mọi lớp ẩn nằm trong một không gian biểu diễn khác nhau và có khả năng là một biểu diễn trừu tượng hơn của đầu vào so với lớp trước đó [39]. Hình 2.5 minh họa cấu trúc của DRNN.



Hình 2.5. minh họa cấu trúc của DRNN [38].

Hình 2.5 minh họa kiến trúc tổng thể của một mô hình DRNN. Mô hình này được thiết kế để học các phụ thuộc dài hạn trong chuỗi dữ liệu thông qua việc kết nối lặp lại các đơn vị mạng theo thời gian và tầng sâu. Cấu trúc được chia thành nhiều tầng và nhiều bước thời gian:

- Trục ngang biểu diễn chuỗi dữ liệu đầu vào theo từng thời điểm t (từ x đến x_t), phản ánh dòng thời gian.
- Trục dọc biểu diễn các tầng sâu của mạng, từ tầng đầu tiên h_1, h_{11} đến tầng cao hơn h_2, h_{21} thể hiện đặc trưng của mô hình "deep" nhiều lớp ẩn.

Các thành phần chính:

Khối đầu vào: Là các phần tử đầu vào theo thứ tự thời gian. Mỗi phần tử x_t tại thời điểm t sẽ được đưa vào mạng tại bước tương ứng.

x_t : Dữ liệu đầu vào tại thời điểm t được đưa vào tầng ẩn đầu tiên để trích xuất đặc trưng sơ cấp.

Tầng ẩn: Mỗi tầng bao gồm nhiều đơn vị RNN được kết nối lặp theo cả chiều thời gian và chiều sâu.

- Kết nối theo thời gian từ $h_1 \rightarrow h_{1t}$ thể hiện việc truyền thông tin giữa các bước thời gian.
- Kết nối theo chiều sâu từ $h_1 \rightarrow h_2$ tức là đầu ra của tầng thấp hơn trở thành đầu vào cho tầng cao hơn, giúp mô hình học các biểu diễn trừu tượng hơn.

Đầu ra: Mỗi thời điểm có thể tạo ra một đầu ra tương ứng ví dụ tầng ẩn cuối cùng h_{mt} tại mỗi thời điểm t sẽ sinh ra đầu ra tương ứng y_t , hoặc chỉ tạo một đầu ra duy nhất y ở bước cuối tùy theo mục tiêu bài toán.

2.4. Các thuật toán tối ưu hóa thuộc nhóm sinh học

Để tối ưu hóa các tham số đầu vào của mô hình học sâu, sử dụng các thuật toán tối ưu metaheuristic. Cụ thể, các thuật toán được áp dụng đều thuộc nhóm thuật toán được xây dựng dựa trên mô phỏng hành vi của sinh vật trong tự nhiên. Trong các thuật toán tối ưu, quá trình tìm kiếm nghiệm tốt nhất diễn ra thông qua hai giai đoạn chính. Một thuật toán tối ưu hiệu quả là thuật toán biết cân bằng tốt giữa khai phá và khai thác, không quá mạo hiểm (nhiều khai phá) cũng không quá sớm hội tụ (nhiều khai thác) [40].

- Khai phá: Đây là giai đoạn giúp thuật toán tìm kiếm trên phạm vi rộng trong toàn bộ không gian nghiệm. Mục tiêu là tránh bị mắc kẹt tại cực trị cục bộ và tăng khả năng tìm ra nghiệm tối ưu toàn cục [40]. Khai phá thường được thực hiện bằng cách di chuyển đến các vị trí ngẫu nhiên, thử nghiệm nhiều vùng khác nhau để “quét” không gian tìm kiếm.
- Khai thác: Sau khi xác định được các vùng có tiềm năng, thuật toán chuyển sang khai thác tức là tìm kiếm chi tiết xung quanh các nghiệm tốt đã có để cải thiện kết quả [40]. Giai đoạn này giúp thuật toán tinh chỉnh nghiệm, hội tụ nhanh đến nghiệm tốt nhất.

2.4.1. Thuật toán tối ưu hải mã - WaOA

WaOA là một thuật toán tối ưu hóa mới được đề xuất bởi Pavel Trojovský và Mohammad Dehghani vào năm 2022. Thuật toán này được lấy cảm hứng từ hành vi thông minh của loài hải mã trong tự nhiên, đặc biệt là ba chiến lược chính [41]:

- **Tìm kiếm thức ăn:** Các cá thể theo sự dẫn dắt của con hải mã mạnh nhất, mô phỏng khả năng khám phá.
- **Di cư:** Mô phỏng hành vi di chuyển đến vùng mới, giúp tăng khả năng khám phá các vùng nghiệm tiềm năng.
- **Chạy trốn và chiến đấu:** Mô phỏng phản ứng khi gặp kẻ thù như gấu trắng hoặc cá voi sát thủ, thể hiện khả năng khai thác cục bộ để tinh chỉnh nghiệm.

WaOA là thuật toán tối ưu hóa dựa trên quần thể, trong đó mỗi "hải mã" đại diện cho một nghiệm ứng viên. Các nghiệm này được cải thiện theo từng vòng lặp nhờ sự kết hợp giữa khai phá và khai thác.

So sánh với các thuật toán metaheuristic phổ biến như thuật toán di truyền GA, thuật toán bầy đàn hạt PSO, thuật toán tối ưu bầy sói xám GWO, WaOA cho thấy hiệu suất vượt trội trong nhiều hàm kiểm chuẩn nhờ khả năng cân bằng tốt giữa khai phá và khai thác [41].

2.4.2. Thuật toán tối ưu gấu mèo mũi nhọn - COA

COA là một thuật toán tối ưu hóa metaheuristic mới được đề xuất bởi Dehghani et al. (2023), lấy cảm hứng từ hành vi thông minh của loài gấu mèo mũi nhọn. Cụ thể, COA mô phỏng hai hành vi chính [42]:

- **Chiến lược tấn công và săn mồi** đại diện cho giai đoạn khai phá.
- **Chiến lược chạy trốn** khỏi kẻ săn mồi đại diện cho giai đoạn khai thác.

Trong giai đoạn khai phá, một nửa số cá thể gấu mèo "leo cây" để dọa kỳ nhông rơi xuống đất, trong khi nửa còn lại chờ dưới đất để tấn công. Vị trí của con mồi đại diện cho nghiệm tốt nhất tại thời điểm hiện tại, qua đó giúp các cá thể khám phá nhiều khu vực trong không gian tìm kiếm.

Trong giai đoạn khai thác, mỗi coati khi bị đe dọa sẽ di chuyển đến vị trí gần hiện tại nhưng an toàn hơn mô phỏng việc tìm kiếm nghiệm tốt hơn trong vùng lân cận.

Một điểm nổi bật của COA là không sử dụng bất kỳ tham số điều khiển nào, giúp giảm thiểu công đoạn tinh chỉnh và dễ triển khai. Bên cạnh đó, COA thể hiện khả năng

cân bằng giữa khai phá và khai thác rất tốt, qua đó đạt hiệu suất cao trên cả các hàm benchmark (CEC-2017 và CEC-2011) và bài toán tối ưu thực tế [42].

2.4.3. Thuật toán tối ưu kền kền châu Phi - AVOA

AVOA là một thuật toán tối ưu hóa metaheuristic mới được đề xuất bởi Abdollahzadeh et al. vào năm 2021. Thuật toán này lấy cảm hứng từ hành vi kiếm ăn và điều hướng của loài kền kền châu Phi trong tự nhiên. AVOA mô phỏng hai hành vi chính của kền kền [43]:


- Hành vi kiếm ăn: Kền kền tìm kiếm thức ăn bằng cách bay lượn và quan sát môi trường xung quanh để phát hiện xác động vật. Trong thuật toán, hành vi này được mô phỏng để thực hiện quá trình khai phá trong không gian tìm kiếm.
- Hành vi điều hướng: Kền kền sử dụng khả năng điều hướng để di chuyển đến vị trí có thức ăn hiệu quả nhất. Trong thuật toán, hành vi này được mô phỏng để thực hiện quá trình khai thác nhằm cải thiện nghiệm hiện tại.

AVOA đã được kiểm nghiệm trên 36 hàm benchmark chuẩn và cho thấy hiệu suất vượt trội so với nhiều thuật toán metaheuristic khác.

CHƯƠNG 3: PHÂN TÍCH QUY TRÌNH VẬN HÀNH TRONG NHÀ MÁY THÔNG MINH

3.1. Quy trình sản xuất thép

Quy trình sản xuất thép bao gồm các công đoạn liên tiếp, từ nguyên liệu đầu vào cho đến sản phẩm cuối cùng. Quy trình này không chỉ thể hiện các công đoạn sản xuất mà còn ảnh hưởng trực tiếp đến mức tiêu thụ năng lượng trong suốt quá trình. Nội dung sẽ trình bày chi tiết các bước chính trong quy trình sản xuất thép, từ việc luyện gang, tinh luyện thép cho đến các công đoạn hoàn thiện sản phẩm [44].



Hình 3.1. Quy trình sản xuất thép [45].

3.1.1. Xử lý nguyên liệu thô

Quy trình sản xuất thép bắt đầu với việc xử lý nguyên liệu thô, chủ yếu là quặng sắt và các vật liệu sắt tái chế. Quặng sắt là các khoáng vật chứa sắt có thể được khai thác và chế biến thành sắt kim loại. Quặng có thể ở dạng Fe_2O_3 hoặc Fe_3O_4 , với hàm lượng sắt từ 25% đến 65%. Quá trình xử lý quặng bắt đầu bằng việc loại bỏ đất và xay nhỏ quặng thành các viên có kích thước từ 0.5 đến 1.5 inch. Quặng có hàm lượng sắt cao có thể được nạp trực tiếp vào lò cao mà không cần xử lý thêm. Quặng sắt có hàm lượng thấp cần được xử lý để tăng hàm lượng sắt, thường bằng cách luyện thiêu kết hoặc tạo viên [44].

- Luyện thiêu kết: Là quá trình nung nóng quặng mịn và vật liệu phế liệu để tạo thành sản phẩm thiêu kết có cấu trúc xốp. Quá trình này giúp cải thiện tính thấm khí của hỗn hợp trong lò cao và làm dễ dàng quá trình khử quặng sắt.
- Tạo viên: Quá trình tạo viên, trong đó quặng sắt được nghiền nhỏ và trộn với các phụ gia để tạo thành những viên quặng nhỏ, có kích thước từ 10-16 mm, sau đó được nung trong lò quay để tạo thành viên quặng có hàm lượng sắt 60-65%.

3.1.2. Sản xuất gang

Trong lò cao BF, các oxit sắt được khử và nung chảy để tạo thành gang. Nguyên liệu đầu vào gồm quặng sắt, viên nén hoặc sản phẩm thiêu kết quặng sắt tùy thuộc vào từng nhà máy sẽ pha trộn khác nhau. Sản phẩm của lò cao là gang lỏng, chứa khoảng 3–4% carbon và một số tạp chất.

Cấu tạo lò cao gồm 3 bộ phận chính [44]:

- Máy thổi gió lạnh: Nén không khí lạnh trước khi đưa qua lò gia nhiệt. Gió nóng không chỉ giúp tăng nhiệt cho nguyên liệu trong lò mà còn cung cấp oxy cho quá trình đốt than cốc.
- Lò gia nhiệt gió nóng: Làm nhiệm vụ đốt nóng gạch chịu lửa, sau đó dùng gạch này truyền nhiệt cho không khí lạnh, tạo ra gió nóng đưa vào lò cao. Quá trình này diễn ra theo chu kỳ.
- Lò cao: Là nơi chính diễn ra phản ứng khử oxit sắt. Nguyên liệu gồm quặng, than cốc và đá vôi được nạp từ trên đỉnh lò. Gió nóng và nhiên liệu phụ than mịn, dầu, khí được đưa vào từ dưới. Tại đây, than cốc cháy sinh nhiệt và khí CO để khử oxit sắt. Gang lỏng chảy xuống đáy, xỉ nổi phía trên. Khí lò cao sinh ra sẽ được thu hồi, làm sạch để tái sử dụng làm nhiên liệu đốt.

3.1.3. Luyện thép

Sau khi quặng sắt được xử lý, quá trình tiếp theo là luyện thép. Sau khi sản xuất gang quy trình luyện thép bắt đầu với việc gang lỏng được đưa vào lò oxy cơ bản BOF, nơi oxy được thổi vào để giảm hàm lượng carbon trong gang, tạo ra thép. Quá trình này giúp loại bỏ các tạp chất và điều chỉnh thành phần hóa học của thép, mang lại chất lượng sản phẩm thép theo yêu cầu. Quá trình này cũng có thể bao gồm việc bổ sung các hợp chất để điều chỉnh hàm lượng carbon, lưu huỳnh, và các tạp chất khác trong thép [44].

Thay vì sử dụng quặng sắt, lò hồ quang điện EAF chủ yếu sử dụng thép phế liệu làm nguyên liệu chính. Đây là một phương pháp phổ biến trong các nhà máy sản xuất thép

tái chế, nơi thép phế liệu được nấu chảy trong môi trường nhiệt độ cao do dòng điện tạo ra từ các điện cực than chì. Lò EAF cho phép kiểm soát chính xác hơn về thành phần hóa học của thép, giảm lượng carbon trong thép và sản xuất thép có chất lượng cao [44].

3.1.4. Đúc

Sau khi thép được luyện trong lò, thép lỏng sẽ được đưa đến công đoạn đúc, nơi thép được rót vào khuôn để tạo thành các hình dạng bán thành phẩm như phôi thép, tấm thép, hoặc thanh thép. Tại đây sử dụng phương pháp đúc liên tục một phương pháp phổ biến để tạo ra các sản phẩm thép có hình dạng nhất định như tấm, thanh, hoặc cuộn [44]. Thép lỏng được rót vào khuôn hình thù cụ thể, rồi dần dần làm mát và cứng lại khi đi qua các hệ thống làm mát bên ngoài. Công nghệ đúc liên tục giúp sản xuất thép nhanh chóng và tiết kiệm chi phí.

3.1.5. Cán thép

Sau khi thép được đúc thành phôi sẽ được đưa vào công đoạn cán để tạo ra các sản phẩm thép có hình dạng và kích thước theo yêu cầu. Quá trình cán giúp giảm độ dày, cải thiện bề mặt và tăng độ bền cơ học cho thép. Có hai phương pháp cán chính là cán nóng và cán nguội [44].

- Cán nóng là quá trình thép được nung đến nhiệt độ cao (thường trên 1.000°C) rồi đưa qua các trục cán. Khi ở nhiệt độ này, thép trở nên mềm và dễ biến dạng, giúp dễ dàng tạo thành các hình dạng như tấm, cuộn, thanh hoặc dầm thép. Sản phẩm sau cán nóng có bề mặt thô hơn, ít chính xác về kích thước hơn so với cán nguội, nhưng phù hợp cho các ứng dụng không yêu cầu độ chính xác cao như xây dựng, kết cấu thép, đường ray,... Cán nóng cũng giúp tiết kiệm chi phí sản xuất do năng suất cao và ít yêu cầu về xử lý bề mặt.
- Cán nguội là quá trình cán thép ở nhiệt độ thường. Quá trình này giúp tinh chỉnh độ dày, cải thiện độ nhẵn bóng và nâng cao độ chính xác kích thước của sản phẩm. Do được cán ở trạng thái nguội nên thép có độ cứng cao hơn, bề mặt mịn, đẹp và đáp ứng tốt hơn trong các ứng dụng yêu cầu tính thẩm mỹ và kỹ thuật cao như sản xuất ô tô, đồ gia dụng, thiết bị điện,... Tuy nhiên, quá trình cán nguội tiêu tốn nhiều năng lượng hơn và chi phí cao hơn cán nóng.

3.2. Đặc điểm của nhà máy truyền thống

Nhà máy thép truyền thống thường gặp phải nhiều thách thức trong việc tối ưu hóa hiệu quả năng lượng và giảm chi phí vận hành, đặc biệt là khi so với các nhà máy thông minh.

- Sử dụng lò cao BF và lò BOF: được sử dụng trong quá trình luyện thép sử dụng than cốc làm nguyên liệu bơm một lượng lớn khí vào khí quyển phương pháp này thải ra 2 tấn CO_2 cho mỗi tấn thép được sản xuất [46].

- Mức độ tự động hóa thấp: Các nhà máy truyền thống chủ yếu hoạt động với mức độ tự động hóa thấp, nhiều công đoạn vẫn cần đến sự can thiệp của công nhân. Điều này dẫn đến hiệu suất thấp và chi phí vận hành cao [44].
- Quản lý năng lượng kém: Dữ liệu vận hành chủ yếu được ghi chép thủ công, khiến cho việc giám sát và điều chỉnh năng lượng trong quá trình sản xuất trở nên khó khăn. Thiết bị cũ không có khả năng thu hồi nhiệt, làm tăng lượng năng lượng tiêu thụ [44].
- Thiết bị cũ và thất thoát nhiệt: Các nhà máy truyền thống thường sử dụng các thiết bị đã cũ, dẫn đến tổn thất nhiệt lớn trong suốt quy trình sản xuất. Điều này không chỉ làm tăng chi phí năng lượng mà còn gây ảnh hưởng đến hiệu quả sản xuất [44].

3.3. Nhà máy thông minh và khả năng thu thập dữ liệu thời gian thực

Nhà máy thông minh áp dụng các công nghệ mới như Internet vạn vật IoT, trí tuệ nhân tạo AI, và hệ thống điều khiển tích hợp để cải thiện quy trình sản xuất và tiết kiệm năng lượng. Các đặc điểm nổi bật bao gồm:

- Sử dụng lò hồ quang điện EAF: nhỏ hơn nhiều và linh hoạt hơn so với lò cao được sử dụng trong sản xuất thép truyền thống. Chúng cũng rẻ hơn nhiều để xây dựng. Vì chúng sử dụng điện để nấu chảy phế liệu, nên sản xuất thép bằng EAF có thể giảm 75-80 phần trăm lượng khí thải so với lò cao [46].
- Với sự tích hợp của trí tuệ nhân tạo AI, máy học và Internet vạn vật IoT, các nhà máy thép thông minh có thể theo dõi và điều chỉnh mức tiêu thụ năng lượng cũng như hiệu suất hoạt động theo thời gian thực. Hệ thống cảm biến IoT được gắn trên thiết bị và máy móc trong nhà máy để ghi nhận liên tục các thông số như nhiệt độ, áp suất, điện năng,... Dữ liệu thu được sẽ được chuyển về hệ thống điều khiển trung tâm để phân tích và đưa ra các quyết định tối ưu nhằm giảm chi phí và nâng cao chất lượng sản phẩm [47]. Tuy nhiên, việc triển khai hệ thống này đòi hỏi đầu tư lớn vào phần cứng và phần mềm.
- Kết nối MES/ERP: Các hệ thống thực thi sản xuất MES và hoạch định nguồn lực doanh nghiệp ERP được tích hợp để đồng bộ hóa thông tin và các hoạt động giữa các bộ phận trong nhà máy. Điều này giúp tối ưu hóa toàn bộ quy trình và nâng cao hiệu quả sản xuất [48].
- Hệ thống thu hồi nhiệt thải và tích hợp nhiệt : Các hệ thống này thu và tái sử dụng nhiệt từ khí thải hoặc các sản phẩm phụ nóng, giúp giảm nhu cầu năng lượng

tổng thể. Sau đó, tích hợp các hệ thống thu hồi nhiệt trong các quy trình có thể giảm thiểu tổn thất năng lượng. Ví dụ, việc lắp đặt nồi hơi thu hồi nhiệt thải có thể chuyển đổi nhiệt thải thành điện hoặc nhiệt hữu ích để làm nóng trước nguyên liệu thô hoặc nước có thể giảm nhu cầu năng lượng tổng thể [49].

- Ứng dụng hệ thống quản lý năng lượng EnMS : Việc triển khai EnMS, chẳng hạn như ISO 50001, cung cấp một phương pháp tiếp cận có cấu trúc đối với quản lý năng lượng, đảm bảo cải tiến liên tục và tuân thủ các tiêu chuẩn về hiệu quả năng lượng [49].

Mặc dù các công nghệ hiện đại mở ra nhiều cơ hội tiết kiệm năng lượng, nhưng quá trình triển khai lại đi kèm với chi phí đầu tư và vận hành không nhỏ. Bên cạnh đó, chính các hệ thống công nghệ này cũng góp phần làm tăng mức tiêu thụ điện năng [50], chủ yếu do những yếu tố sau đây:

- Cảm biến IoT hoạt động liên tục: Các cảm biến IoT được lắp đặt trên khắp dây chuyền sản xuất từ khu vực luyện thép, cán, làm nguội cho đến kho vận luôn trong trạng thái hoạt động 24/7 để thu thập dữ liệu theo thời gian thực. Mặc dù kích thước nhỏ và công suất tiêu thụ của từng cảm biến là không đáng kể, nhưng khi triển khai với số lượng lớn trên quy mô nhà máy, tổng điện năng tiêu thụ của hệ thống cảm biến có thể trở nên đáng kể.
- Máy chủ và hệ thống xử lý dữ liệu: Dữ liệu thu thập từ hàng nghìn cảm biến cần được xử lý, lưu trữ và phân tích liên tục. Điều này đòi hỏi một hệ thống máy chủ có cấu hình mạnh, khả năng lưu trữ lớn và tốc độ xử lý cao. Các trung tâm dữ liệu không chỉ tiêu tốn điện cho hoạt động của máy chủ mà còn cần hệ thống làm mát, bộ lưu điện, ...
- Hạ tầng mạng và hệ thống truyền tải dữ liệu: Để đảm bảo hệ thống IoT vận hành ổn định, mạng truyền thông công nghiệp như mạng Ethernet công nghiệp, mạng 5G, LPWAN hoặc mạng không dây nội bộ phải duy trì kết nối liên tục giữa các cảm biến, thiết bị, hệ thống điều khiển và máy chủ trung tâm. Hơn nữa, việc truyền tải dữ liệu dung lượng lớn liên tục trong thời gian thực cũng góp phần khiến nhu cầu sử dụng điện của nhà máy tăng lên một cách âm thầm nhưng bền vững theo thời gian.

3.4. So sánh giữa nhà máy truyền thống và nhà máy thông minh trong bối cảnh dự báo mức tiêu thụ năng lượng

Trong thời đại công nghiệp 4.0 nhà máy thông minh đang dần thay thế các nhà máy truyền thống nhờ vào ứng dụng công nghệ cao bảng 3.1 so sánh giúp hiểu rõ những sự khác biệt và lợi ích nổi bật của hai mô hình này.

Bảng 3.1. So sánh nhà máy thông minh và nhà máy truyền thống

Tiêu chí	Nhà máy truyền thống	Nhà máy thông minh
Công nghệ và tự động hóa	Dựa chủ yếu vào các quy trình thủ công và tự động hóa giới hạn trong một số bước nhất định của sản xuất. Các công việc như giám sát, điều khiển và bảo trì chủ yếu được thực hiện bằng tay, với sự can thiệp của con người trong hầu hết các bước.	Ứng dụng Công nghiệp 4.0, sử dụng các công nghệ tiên tiến như IoT, robot và hệ thống tự động hóa thông minh để giám sát và điều khiển mọi quy trình sản xuất. Sử dụng các công cụ như Trợ lý vận hành OA, chỉ số hiệu suất nhà máy PPI để nâng cao sự tự động hóa và giảm thiểu sự can thiệp của con người.
Quản lý và thu thập dữ liệu	Quá trình thu thập và xử lý dữ liệu còn hạn chế, thông tin thường được ghi chép thủ công hoặc chỉ được thu thập ở một số điểm trong dây chuyền sản xuất.	Tận dụng dữ liệu lớn và phân tích dữ liệu để giám sát toàn bộ quy trình sản xuất theo thời gian thực, giúp phát hiện và khắc phục sự cố ngay lập tức.
Bảo trì và dự báo	Theo lịch cố định hoặc khi máy hỏng hóc.	Dùng dữ liệu lớn & AI dùng để phân tích trạng thái thiết bị nhằm bảo trì dự đoán.
Mức sử dụng điện năng	Điện chỉ là một phần trong hệ thống, mức sử dụng điện năng nhỏ.	Quá trình chuyển đổi số làm tăng mức độ sử dụng điện năng do các cảm biến, thiết bị kết nối và xử lý dữ liệu 24/7. Đồng thời thúc đẩy nhu cầu kiểm soát và tối ưu hóa điện năng.
Hiệu suất năng lượng	Không tối ưu, nhiều hao phí do vận hành kém hiệu quả.	Giám sát và điều chỉnh theo thời gian thực giúp tiết kiệm điện năng nhờ tối ưu hóa quy trình sản xuất, giảm thời gian ngừng máy nhờ hệ thống tự động và sử dụng năng lượng hiệu quả.
Tính linh hoạt	Khó khăn trong việc thay đổi quy trình và công nghệ do cần thay đổi lớn khi áp dụng công nghệ mới.	Linh hoạt trong việc thay đổi quy trình sản xuất, dễ dàng tích hợp công nghệ mới mà không cần thay đổi toàn hệ thống.
Chi phí vận hành	Cao, mất nhiệt, tốn nhân công.	Giảm nhờ tự động hóa và tối ưu.

Chính vì những phân tích ở trên, cần thiết phải xây dựng mô hình dự báo năng lượng, chủ yếu là điện năng, để giúp các nhà máy thông minh theo dõi, tối ưu hóa việc sử dụng điện trong thời gian thực, giảm lãng phí và định hướng chiến lược vận hành hiệu quả hơn. Mô hình dự báo còn hỗ trợ nhà máy đưa ra các quyết định chủ động trong bảo trì thiết bị, phân bổ nguồn lực hợp lý, từ đó nâng cao hiệu suất năng lượng, tiết kiệm chi phí và góp phần phát triển bền vững.

CHƯƠNG 4: ỨNG DỤNG HỌC SÂU ĐỂ DỰ BÁO MỨC TIÊU THỤ NĂNG LƯỢNG TRONG NHÀ MÁY THÔNG MINH

Trong chương này, các nghiên cứu áp dụng mô hình học sâu để dự báo mức tiêu thụ năng lượng sẽ được trình bày chi tiết. Dữ liệu thu thập tại nhà máy sản xuất sẽ được sử dụng để xây dựng và huấn luyện các mô hình dự báo. Đặc biệt, các mô hình CNN, DRNN, LSTM sẽ được ứng dụng để dự báo mức tiêu thụ năng lượng, nhờ vào khả năng học được các đặc trưng quan trọng từ dữ liệu chuỗi thời gian. Ngoài ra, sau khi áp dụng các mô hình học sâu, nghiên cứu này còn tập trung vào việc nâng cao hiệu quả dự báo bằng cách tối ưu hóa các tham số huấn luyện đầu vào của mô hình. Để đạt được mục tiêu này, các thuật toán tối ưu hóa sinh học sẽ được sử dụng, giúp cải thiện độ chính xác của các dự báo năng lượng.

4.1. Thu thập dữ liệu

4.1.1. Thông tin dữ liệu

Bộ dữ liệu được sử dụng trong nghiên cứu được thu thập từ Công ty TNHH Thép Daewoo, tọa lạc tại Gwangyang, Hàn Quốc – một doanh nghiệp chuyên sản xuất các sản phẩm thép như cuộn, tấm và tôn. Dữ liệu liên quan đến mức tiêu thụ điện năng được lưu trữ thông qua hệ thống điện toán đám mây của công ty. Ngoài ra, thông tin tham chiếu về mức tiêu thụ năng lượng ngành cũng được tổng hợp từ trang web chính thức của Tổng công ty Điện lực Hàn Quốc (KEPCO) tại địa chỉ (pccs.kepco.go.kr).

Bộ dữ liệu này thuộc kho lưu trữ công khai tại UCI Machine Learning Repository và được tổ chức dưới dạng dữ liệu chuỗi thời gian, với chu kỳ lấy mẫu 15 phút/lần với 35.039 điểm dữ liệu được thu thập. Mỗi bản ghi thể hiện đặc trưng tiêu thụ năng lượng tại một thời điểm cụ thể trong ngày đầu tiên của mỗi tháng. Bảng 4.1 mô tả các thuộc tính chính trong bộ dữ liệu:

Bảng 4.1 trình bày danh sách các thuộc tính có trong bộ dữ liệu được sử dụng trong nghiên cứu, bao gồm tên gọi của từng thuộc tính, kèm theo phân mô tả về đặc điểm. Các thuộc tính này bao phủ nhiều khía cạnh liên quan đến tiêu thụ năng lượng, đặc tính kỹ thuật của hệ thống điện, yếu tố thời gian và điều kiện vận hành theo ngày trong tuần. Việc hiểu rõ vai trò và bản chất của từng thuộc tính là cơ sở quan trọng để tiến hành các bước tiền xử lý dữ liệu, xây dựng mô hình dự báo cũng như phân tích kết quả một cách chính xác và có ý nghĩa thực tiễn.

Bảng 4.1. Các thuộc tính trong bộ dữ liệu

Thuộc tính	Mô tả
Date	Ngày thu thập dữ liệu (chuỗi thời gian, định kỳ 15 phút)
Usage (kWh)	Lượng tiêu thụ điện tại thời điểm đó (liên tục, đơn vị kWh)
Lagging CrpC	Dòng điện trễ - Công suất phản kháng (kVarh)
Leading CrpC	Dòng điện dẫn đầu - Công suất phản kháng (kVarh)
CO ₂	Lượng khí CO ₂ phát thải (ppm)
Lagging CPF	Hệ số công suất của dòng trễ (%)
Leading CPF	Hệ số công suất của dòng dẫn đầu (%)
NSM	Số giây kể từ nửa đêm (giá trị liên tục, đơn vị giây)
Week Status	Trạng thái ngày: Cuối tuần (0) hoặc ngày thường (1)
Day of Week	Ngày trong tuần: từ Chủ Nhật (0) đến Thứ Bảy (6)
Load Type	Phân loại tải: tải nhẹ (0), tải trung bình (1), tải cao điểm (2)

Bảng 4.2 trình bày các giá trị thống kê mô tả cơ bản của các thuộc tính này, bao gồm: giá trị trung bình (Mean), độ lệch chuẩn (Std), giá trị nhỏ nhất (Min), các phân vị thứ nhất (25%), trung vị (50%), phân vị thứ ba (75%) và giá trị lớn nhất (Max). Các thông tin này giúp hình dung sơ bộ về phân bố dữ liệu, mức độ biến thiên và sự hiện diện của các giá trị ngoại lệ trong từng thuộc tính.

Bảng 4.2. Thông tin thống kê mô tả các thuộc tính

Thuộc tính	Mean	Std	Min	25%	50%	75%	Max
Date	NaN	NaN	NaN	NaN	NaN	NaN	NaN
Usage	27.39	33.44	2.45	3.2	4.57	51.25	157.18
Lagging CrpC	13.04	16.31	0	2.3	5	22.64	96.91
Leading CrpC	3.87	7.42	0	0	0	2.09	27.76
CO ₂	0.011	0.016	0	0	0	0.02	0.07
lagging CPF	80.58	18.92	36.94	63.32	87.96	99.03	100
Leading CPF	84.37	30.45	12.5	99.7	100	100	100
NSM	42751	24939	0	21600	43200	64350	85500
Week Status	0.72	0.45	0	0	1	1	1
Day of week	2.99	2	0	1	3	5	6
Load Type	0.69	0.79	0	0	0	1	2

Các thuộc tính nêu trên đóng vai trò đầu vào cho quá trình xây dựng mô hình dự báo mức tiêu thụ năng lượng theo thời gian. Những biến mang tính định lượng như Usage, CO₂, Lagging CrpC, Leading CrpC, NSM, Lagging CPF, Leading CPF được xem xét kỹ lưỡng trong quá trình phân tích tương quan và lựa chọn thuộc tính đầu vào, do chúng phản ánh trực tiếp cường độ tiêu thụ và hiệu suất sử dụng năng lượng trong các khoảng thời gian khác nhau.

Bên cạnh đó, các đặc trưng định tính như Week Status, Day of Week và Load Type cũng đóng vai trò quan trọng trong mô hình dự báo. Week Status cho biết liệu thời điểm đo có rơi vào ngày cuối tuần hay không, từ đó phản ánh xu hướng tiêu thụ năng lượng theo lịch làm việc của nhà máy. Day of Week thể hiện ngày cụ thể trong tuần Chủ Nhật đến Thứ Bảy, có thể ảnh hưởng đến cường độ hoạt động sản xuất do lịch làm việc, kế hoạch bảo trì hoặc các hoạt động hành chính. Load Type cho biết mức độ tải điện tại thời điểm tương ứng tải nhẹ, tải trung bình hoặc tải cao điểm, giúp mô hình phân biệt giữa các trạng thái hoạt động của hệ thống sản xuất. Các đặc trưng định tính này thường được mã hóa thành dạng số trước khi đưa vào quá trình huấn luyện mô hình, nhằm đảm bảo tính tương thích với các thuật toán học sâu và tối ưu hóa.


4.1.2. Phân tích dữ liệu khám phá

4.1.2.2. Phân tích phân bố và đặc điểm của các thuộc tính trong tập dữ liệu

Để hiểu rõ hơn về cấu trúc và đặc tính của tập dữ liệu phục vụ cho bài toán dự báo mức tiêu thụ năng lượng, các biểu đồ phân phối và biểu đồ tần suất đã được sử dụng nhằm khảo sát trực quan các biến đầu vào. Qua đó, ta có thể đánh giá được xu hướng phân phối hỗ trợ cho quá trình chọn đặc trưng phù hợp.

Phân bố của thuộc tính mục tiêu – Usage kWh

Biểu đồ phân phối của thuộc tính Usage cho thấy sự phân bố lệch phải, trong đó phần lớn các giá trị tiêu thụ nằm trong khoảng từ 0 đến 20, tập trung mạnh ở mức dưới 10 kWh. Tuy nhiên, vẫn tồn tại các giá trị tiêu thụ cao hơn, kéo dài đến hơn 150 kWh. Điều này cho thấy mức tiêu thụ năng lượng thay đổi mạnh mẽ theo thời điểm và tải tiêu thụ gây ra thách thức lớn cho việc dự báo chính xác.




Hình 4.1. Phân bố của thuộc tính mục tiêu

Phân bố của các biến định lượng

Các biểu đồ phân phối của các biến định lượng như Lagging CrpC, Leading CrpC, CO₂, Lagging CPF, Leading CPF, và NSM phản ánh những đặc điểm sau:

- Lagging CrpC và Leading CrpC: đều có phân bố lệch trái, với nhiều giá trị nhỏ và ít giá trị lớn. Đặc biệt, Lagging CrpC có đuôi kéo dài thể hiện sự bất đối xứng.
- CO₂: Có dạng phân bố đa đỉnh, cho thấy có thể bị ảnh hưởng bởi nhiều yếu tố sản xuất hoặc điều kiện môi trường.
- Lagging CPF và Leading CPF: Cho thấy sự tập trung lệch phải ở các giá trị cao gần 100, phản ánh hiệu suất vận hành cao trong phần lớn thời gian. Điều này cho thấy nhà máy thường hoạt động gần công suất cao.
- NSM: Có phân bố đồng đều từ 0 đến 86400, phản ánh toàn bộ khung thời gian trong ngày.




Hình 4.2. Phân bố của các thuộc tính định lượng

Phân bố của các biến định tính

Các biểu đồ đếm cho thấy đặc điểm phân bố của các thuộc tính định tính như sau:

- Week Status: Bao gồm hai giá trị (0: ngày làm việc, 1: cuối tuần), trong đó ngày làm việc (giá trị 0) chiếm đa số. Điều này phản ánh chu kỳ sản xuất theo lịch làm việc tiêu chuẩn.
- Day of week: Có phân bố tương đối đồng đều qua 7 ngày, không có sự thiên lệch rõ rệt.
- Load Type: Bao gồm ba loại tải khác nhau (0, 1, 2) với sự phân bố không đều, trong đó loại 0 chiếm ưu thế. Đây là một đặc trưng phân loại có giá trị trong việc mô tả loại hoạt động sản xuất, hỗ trợ mô hình nhận diện các mức tiêu thụ đặc trưng.

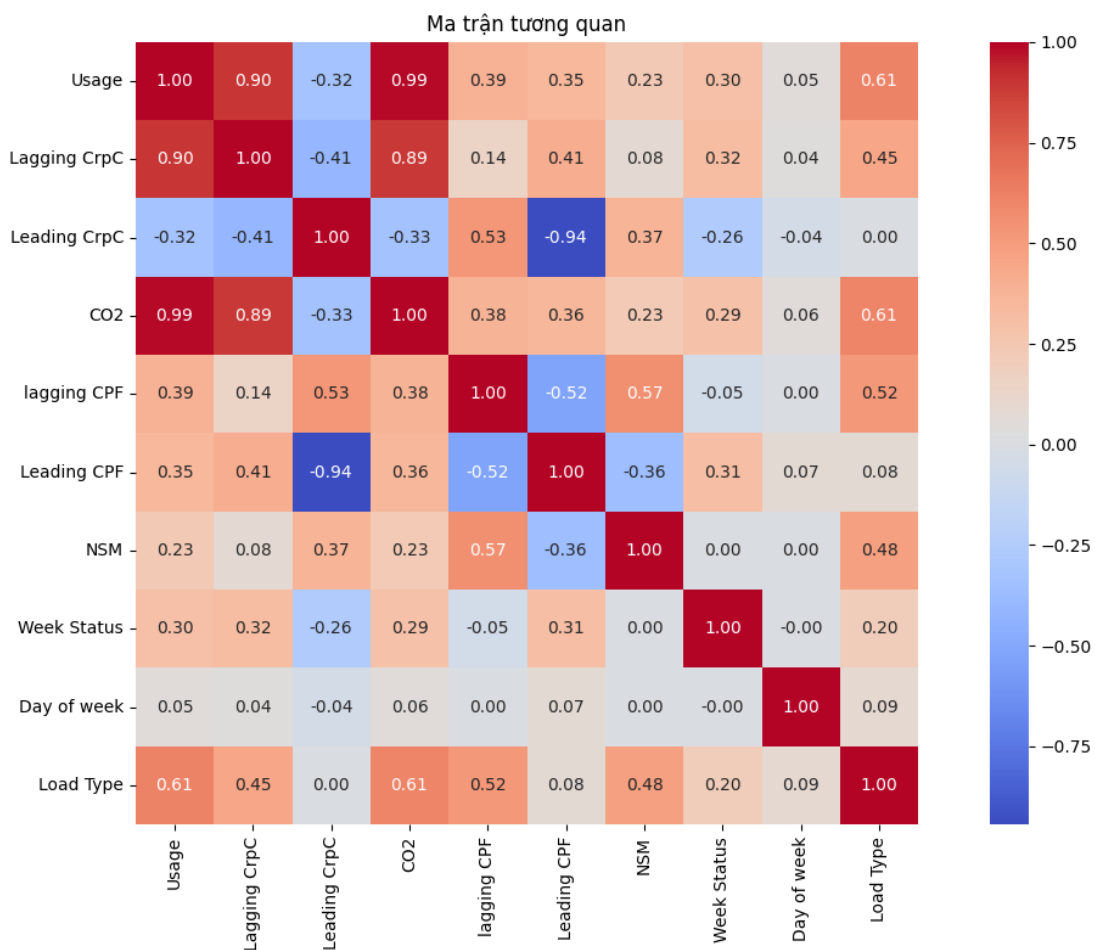


Hình 4.3. Phân bố của các thuộc tính định tính

Như vậy, thông qua việc phân tích trực quan phân bố của các biến định lượng và định tính, có thể nhận thấy rằng tập dữ liệu chứa nhiều đặc trưng không tuân theo phân phối chuẩn, đồng thời tồn tại các xu hướng lệch phải hoặc lệch trái rõ rệt. Điều này phản ánh tính không đồng nhất và phức tạp của các yếu tố ảnh hưởng đến mức tiêu thụ năng lượng trong nhà máy. Việc nhận diện được đặc điểm phân bố này là cơ sở quan trọng để lựa chọn các phương pháp tiền xử lý dữ liệu phù hợp, như chuẩn hóa Z-score, chuẩn hóa theo trung bình hoặc chuẩn hóa min-max, vốn đã được trình bày chi tiết tại Mục 2.2.3. Đây là bước cần thiết nhằm đảm bảo dữ liệu đầu vào phù hợp với yêu cầu của các mô hình học sâu được sử dụng trong bài toán dự báo.

4.1.2.1. Ma trận hệ số tương quan

Ma trận tương quan tại hình 4.4 thể hiện mối quan hệ tuyến tính giữa các thuộc tính đặc trưng trong bộ dữ liệu. Giá trị tương quan dao động từ -1 đến 1, trong đó giá trị gần ± 1 thể hiện mối quan hệ tuyến tính mạnh, còn giá trị gần 0 cho thấy mối quan hệ yếu hoặc không đáng kể.



Hình 4.4. Ma trận hệ số tương quan giữa các thuộc tính

Kết quả phân tích cho thấy rằng hai đặc trưng NSM và Day of Week có hệ số tương quan rất thấp với biến mục tiêu dự báo Usage, lần lượt chỉ đạt 0.23 và 0.05. Điều này cho thấy chúng gần như không ảnh hưởng đáng kể đến biến mục tiêu. Do đó, hai đặc trưng này có thể được loại bỏ khỏi tập dữ liệu đầu vào nhằm giảm độ phức tạp của mô hình mà không làm suy giảm hiệu suất dự báo.

Ngược lại, các đặc trưng còn lại thể hiện mối tương quan đáng kể với mức tiêu thụ năng lượng và sẽ được giữ lại trong quá trình xây dựng mô hình, bao gồm:

- Lagging CrpC (Công suất phản kháng dòng trễ) với hệ số tương quan 0.90.
- CO₂ (nồng độ khí CO₂) với hệ số tương quan rất cao 0.99.
- Leading CPF (hệ số công suất dòng dẫn đầu) có tương quan 0.35.
- Lagging CPF (hệ số công suất dòng trễ) với mức tương quan 0.39.
- Load Type (loại tải) là một đặc trưng định tính nhưng có mức tương quan trung bình 0.61, cho thấy khả năng phân loại mức độ tiêu thụ năng lượng hữu ích.
- Week Status (trạng thái ngày trong tuần) cũng được giữ lại do có thể phản ánh sự khác biệt giữa ngày làm việc và cuối tuần với mức tương quan 0.3.
- Leading CrpC (Công suất phản kháng dòng dẫn đầu) tuy có mức tương quan không cao, nhưng vẫn được duy trì do khả năng bổ sung thông tin về trạng thái tải với mức tương quan -0.32.


Tóm lại, sau quá trình phân tích, tất cả các đặc trưng trong bộ dữ liệu ngoại trừ NSM và Day of Week sẽ được sử dụng để xây dựng mô hình dự báo, nhằm đảm bảo độ chính xác và hiệu quả mô hình ở mức cao nhất.

4.2. Thiết kế mô hình học sâu

4.2.1. Kiến trúc và mô tả các mô hình học sâu

4.2.1.1. Mô hình CNN

Mô hình mạng nơ-ron tích chập một chiều CNN được thiết kế để dự báo mức tiêu thụ năng lượng trong nhà máy thép thông minh, dựa trên 7 đặc trưng đầu vào là dữ liệu chuỗi thời gian đa biến. Hình 4.5 mô tả kiến trúc của mô hình CNN được sử dụng để dự báo có thể được mô tả chi tiết như sau.



Hình 4.5. Kiến trúc mô hình CNN


Cấu trúc mô hình gồm các lớp như sau:

- Lớp đầu vào (Input layer): Dùng để nhận đầu vào là chuỗi thời gian dạng 1 chiều.
- Lớp tích chập 1 chiều (Conv1D): Để mô hình CNN trích xuất các đặc điểm từ bộ dữ liệu thời gian đa biến, lớp tích chập trở thành thành phần quan trọng nhất. Ở đây, conv1D được sử dụng, có các tham số như 32 bộ lọc với kernel size là 3, padding = 'same' giúp giữ nguyên chiều dài chuỗi sau khi tích chập, activation = 'relu' là hàm kích hoạt phi tuyến tính giúp học các đặc trưng hiệu quả hơn.
- Lớp chuẩn hóa (Batch Normalization): được áp dụng sau mỗi lớp tích chập để chuẩn hóa đầu ra của lớp Conv1D giúp mô hình hội tụ nhanh hơn và ổn định hơn khi huấn luyện.
- Lớp lấy mẫu trung bình (AveragePooling1D): Làm giảm chiều dài chuỗi đặc trưng còn một nửa (pooling size = 2). Có tác dụng làm giảm số lượng tham số, chống overfitting, giữ lại đặc trưng quan trọng.
- Lớp làm phẳng (Flatten): Để di chuyển dữ liệu vào lớp tiếp theo, làm phẳng được sử dụng để chuyển đổi dữ liệu từ một mảng ba chiều thành một chiều. Về cơ bản, nó làm phẳng đầu ra của lớp tích chập để tạo ra một vector đặc trưng có độ dài riêng biệt để đưa vào lớp Dense.
- Lớp kết nối đầy đủ (Dense): Lớp này chấp nhận đầu vào dưới dạng mảng một chiều. Các lớp này có giá trị đơn vị biểu thị các nơ-ron trong lớp đầu ra của chúng gồm một lớp ẩn có 64 nơ-ron với hàm kích hoạt ReLU để học các quan hệ phi tuyến giữa các đặc trưng đã trích xuất.
- Lớp Dropout: áp dụng dropout rate 0.3 nhằm giảm hiện tượng overfitting ngẫu nhiên bỏ 30% kết nối trong quá trình huấn luyện.
- Lớp đầu ra (Output layer): là một nơ-ron đầu ra với giá trị liên tục dự đoán mức sử dụng năng lượng.

So với kiến trúc mạng nơ-ron tích chập (CNN) thông thường vốn được sử dụng phổ biến trong xử lý ảnh với các lớp Conv2D và các lớp pooling mô hình CNN trong nghiên cứu này đã được điều chỉnh để phù hợp với bài toán dự báo mức tiêu thụ năng lượng dựa trên dữ liệu chuỗi thời gian đa biến. Cụ thể, thay vì sử dụng Conv2D, mô hình sử dụng lớp Conv1D với 32 bộ lọc và kernel size là 3 để trích xuất đặc trưng từ dữ liệu đầu vào một chiều, cùng với tham số padding='same' nhằm giữ nguyên chiều dài chuỗi [51], đảm bảo không mất thông tin theo thời gian. Đồng thời, mô hình kết hợp Batch Normalization và AveragePooling1D để tăng độ ổn định và giảm số lượng tham số. Phần đầu ra gồm các lớp Dense và Dropout giúp học các quan hệ phi tuyến và hạn chế overfitting. Thiết kế này cân bằng giữa hiệu quả học và khả năng tổng quát, phù hợp với bài toán dự báo mức tiêu thụ năng lượng.

4.2.1.2. Mô hình DRNN

Mô hình mạng nơ-ron hồi tiếp sâu DRNN được xây dựng nhằm dự báo mức tiêu thụ năng lượng trong nhà máy thép thông minh, dựa trên dữ liệu chuỗi thời gian đa biến gồm 7 đặc trưng đầu vào. DRNN đặc biệt phù hợp để xử lý dữ liệu chuỗi có sự phụ thuộc theo thời gian, giúp nắm bắt được các mối quan hệ giữa các mốc thời gian liên kề. Hình 4.6 mô tả kiến trúc của mô hình DRNN được sử dụng:



Hình 4.6. Kiến trúc mô hình DRNN

Cấu trúc mô hình gồm các lớp sau:


- Lớp đầu vào (Input layer): Nhận dữ liệu chuỗi thời gian 1 chiều với window size và 7 đặc trưng. Dữ liệu được đưa vào dưới dạng ma trận 3 chiều (batch size, window size, num features).
- Lớp RNN thứ nhất (SimpleRNN(128)): Có 128 đơn vị ẩn, sử dụng hàm kích hoạt tanh, và return sequences = True để giữ toàn bộ chuỗi đầu ra nhằm truyền cho lớp tiếp theo. Lớp này giúp mô hình học được các đặc trưng cơ bản trong chuỗi thời gian.
- Lớp RNN thứ hai (SimpleRNN(64)): Tương tự lớp đầu tiên nhưng giảm số lượng đơn vị xuống còn 64. Lớp này tiếp tục trích xuất các đặc trưng ở cấp độ cao hơn từ chuỗi thời gian đã xử lý.

- Lớp RNN thứ ba (SimpleRNN(32)): Đây là lớp RNN cuối cùng với return sequences = False, nghĩa là chỉ giữ lại đầu ra tại bước thời gian cuối cùng, đại diện cho toàn bộ chuỗi đầu vào.
- Lớp Dropout: sau mỗi lớp SimpleRNN đều sử dụng Dropout với tỷ lệ 0.2 để giảm hiện tượng overfitting bằng cách ngẫu nhiên bỏ đi 20% liên kết trong quá trình huấn luyện.
- Lớp kết nối đầy đủ (Dense(1)): Lớp đầu ra duy nhất với một nơ-ron, trả về giá trị liên tục đại diện cho dự đoán mức tiêu thụ năng lượng tại thời điểm tiếp theo.

Mô hình DRNN thông thường bao gồm 2 lớp RNN được xếp chồng nhằm khai thác tốt các đặc trưng tuần tự trong dữ liệu chuỗi thời gian đơn biến là khá hiệu quả [52]. Tuy nhiên, với bộ dữ liệu chuỗi thời gian đa biến gồm nhiều đặc trưng nên đề xuất mô hình DRNN được thiết kế trong đề tài gồm 3 lớp SimpleRNN với số lượng đơn vị ẩn giảm dần ($128 \rightarrow 64 \rightarrow 32$), kết hợp với các lớp Dropout có tỷ lệ 0.2 sau mỗi lớp. Cấu trúc này cho phép mô hình học đặc trưng theo thời gian ở nhiều cấp độ, trong đó các lớp đầu tiên học xu hướng tổng thể, còn các lớp sau có vai trò tinh lọc thông tin. Việc giảm dần số lượng đơn vị ẩn giúp mô hình tránh việc dồn quá nhiều tham số vào lớp cuối, đồng thời giảm độ phức tạp và nguy cơ quá khớp. Thiết kế này đảm bảo mô hình đủ sâu để học được mối quan hệ phức tạp trong dữ liệu tiêu thụ năng lượng, đồng thời duy trì tính ổn định và khả năng tổng quát hóa trong quá trình huấn luyện.

4.2.1.3. Mô hình LSTM

Mô hình mạng nơ-ron bộ nhớ dài hạn LSTM được thiết kế để dự báo mức tiêu thụ năng lượng trong nhà máy thép thông minh, dựa trên 7 đặc trưng đầu vào là chuỗi thời gian đa biến. Hình 4.7 mô tả kiến trúc của mô hình LSTM được sử dụng:



Hình 4.7. Kiến trúc mô hình LSTM

Kiến trúc mô hình gồm các lớp như sau:

- Lớp đầu vào (Input layer): nhận chuỗi thời gian đầu vào với định dạng window size, số biến đầu vào. Đây là dữ liệu dạng 3 chiều, phù hợp với các mô hình tuần tự như LSTM.

- Lớp LSTM 1: gồm 128 đơn vị ẩn, sử dụng hàm kích hoạt tanh, và return sequences = True để giữ lại chuỗi đầu ra, phục vụ cho lớp tiếp theo. Lớp này học các đặc trưng tuần tự cơ bản từ chuỗi thời gian.
- Lớp LSTM 2: gồm 64 đơn vị ẩn, tiếp tục học các đặc trưng sâu hơn. Việc giữ return sequences = True giúp mô hình tiếp tục xử lý chuỗi qua nhiều lớp.
- Lớp LSTM 3: gồm 32 đơn vị ẩn, là lớp cuối cùng với return sequences = False, tức chỉ trả về trạng thái ẩn cuối cùng để đưa vào lớp Dense. lớp này tổng hợp thông tin toàn chuỗi để đưa ra dự báo.
- Lớp Dropout: sau mỗi lớp LSTM đều sử dụng Dropout với tỷ lệ 0.2 để giảm hiện tượng overfitting bằng cách ngẫu nhiên bỏ đi 20% liên kết trong quá trình huấn luyện.
- Lớp Dense (kết nối đầy đủ): gồm 1 nơ-ron đầu ra với giá trị liên tục, dùng để dự báo mức tiêu thụ năng lượng tại thời điểm tương lai.

Kiến trúc LSTM thông thường thường chỉ sử dụng 1 đến 2 lớp LSTM với số đơn vị ẩn lớn, nhằm khai thác đặc trưng chuỗi thời gian [52]. Tuy nhiên, với bài toán dự báo tiêu thụ năng lượng trong môi trường sản xuất thông minh với dữ liệu chuỗi thời gian đa biến, việc khai thác các đặc trưng sâu ở nhiều cấp độ thời gian là rất quan trọng. Mô hình được đề xuất trong đề tài sử dụng 3 lớp LSTM với số đơn vị ẩn giảm dần (128 → 64 → 32), kết hợp Dropout 0.2 sau mỗi lớp, giúp mô hình vừa học được đặc trưng tổng quát ở các lớp trên, vừa tinh lọc đặc trưng ở lớp dưới. Việc giảm dần số lượng đơn vị ẩn giúp mô hình tránh việc dồn quá nhiều tham số vào lớp cuối, đồng thời giảm độ phức tạp và nguy cơ quá khớp. Đây là sự điều chỉnh hợp lý so với kiến trúc LSTM thông thường, nhằm tối ưu hóa hiệu quả dự báo và tính khái quát hóa của mô hình trong môi trường công nghiệp có dữ liệu biến động và liên tục.

4.2.1.4. Huấn luyện, kiểm tra và đánh giá mô hình học sâu

Sau khi xây dựng các mô hình học sâu bao gồm CNN, DRNN và LSTM, bước tiếp theo là tiến hành dự báo với 2000 điểm dữ liệu và chia bộ dữ liệu thành 2 tập huấn luyện, kiểm tra với tỉ lệ 80/20 và đánh giá hiệu quả dự báo của từng mô hình. Các mô hình được huấn luyện trên cùng một tập dữ liệu, sử dụng các thuộc tính đầu vào giống nhau để đảm bảo tính khách quan trong so sánh. Kết quả dự báo được đánh giá dựa trên ba chỉ số phổ biến trong bài toán dự báo chuỗi thời gian là MAPE (%), RMSE và MAE. Nhằm tăng độ tin cậy cho quá trình đánh giá và loại bỏ tác động của yếu tố ngẫu nhiên trong huấn luyện mô hình học sâu, tiến hành huấn luyện từng mô hình lần lặp lại 100 riêng biệt. Trong số đó, 20 mô hình có MAPE thấp nhất trên tập kiểm tra được lựa chọn để phân tích và báo cáo kết quả. Số lần chạy lớn giúp đảm bảo tính khách quan, ổn định

và phản ánh cho hiệu suất thực tế của mô hình. Bảng 4.3 trình bày chi tiết kết quả dự báo MAPE trên tập huấn luyện của từng mô hình.

Bảng 4.3. Kết quả dự báo MAPE trên tập huấn luyện cho các mô hình


Mô hình	CNN		DRNN		LSTM	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	7.57	9.2	20.41	24.45	25.7	23.98
	11.12	16.63	16.42	16.31	30.67	32.13
	7.02	19.49	18.89	27.14	20.81	35.34
	10.49	19.9	23.43	18.04	27.93	30.14
	11.39	10.75	15.27	22.14	19.53	26.56
	12.34	9.31	17.45	24.54	26.45	32.89
	10.17	13.93	22.45	20.12	23.45	37.45
	20.33	12.18	17.12	22.54	18.13	25.53
	13.47	10.2	21.42	21.04	27.56	29.56
	8.18	13.22	20.31	25.14	26.34	22.45
Trung bình	12.34		20.73		27.13	

Bảng 4.3 trình bày kết quả MAPE trên tập huấn luyện cho ba mô hình cho thấy mô hình CNN đạt giá trị MAPE trung bình thấp nhất 12.34 và thấp hơn đáng kể so với hai mô hình còn lại lần lượt là DRNN và LSTM với giá trị 20.73 và 27.13.

Bảng 4.4. Kết quả dự báo MAPE trên tập kiểm tra cho các mô hình

Mô hình	CNN		DRNN		LSTM	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	8.52	10.31	17.01	19.28	25.48	28
	8.81	10.95	17.08	19.42	25.67	29.33
	9.06	11.01	17.73	20.13	25.81	29.42
	9.18	11.92	18.21	20.57	25.93	30.42
	9.22	12.96	18.29	21.12	26.05	31.47
	9.41	13.06	18.34	21.42	26.32	31.5
	9.45	13.14	18.38	22.53	26.33	31.61
	9.8	13.27	18.82	22.65	27.34	32.75
	9.98	13.88	18.93	23.17	27.67	32.76
	10.07	14.12	19.18	23.23	27.82	33.87
Trung bình	10.91		19.77		28.78	

Nhằm cung cấp góc nhìn trực quan về hiệu quả dự báo của các mô hình, biểu đồ hình 4.8 trình bày giá trị MAPE trung bình trên tập kiểm tra, qua đó phản ánh mức độ sai lệch giữa kết quả dự báo và thực tế.



Hình 4.8. Giá trị MAPE trung bình trên tập kiểm tra của các mô hình

Mô hình CNN đạt kết quả dự báo chính xác nhất trên tập kiểm tra với MAPE trung bình là 10.91, thể hiện độ ổn định và hiệu quả cao trong việc dự báo. Trong khi đó, mô hình DRNN đạt MAPE trung bình là 19.77, cho thấy kết quả dự báo kém chính xác hơn so với CNN nhưng vẫn có hiệu quả khá. Cuối cùng, mô hình LSTM có MAPE trung bình là 28.78, đây là mức sai số cao nhất trong ba mô hình, cho thấy LSTM cần được tối ưu hóa thêm để cải thiện độ chính xác. Tóm lại, CNN là mô hình ưu việt nhất trong việc dự báo MAPE, trong khi DRNN và LSTM có hiệu quả thấp hơn, đặc biệt là LSTM. Vì MAPE là một chỉ số đánh giá mang tính tương đối, nhằm đảm bảo tính khách quan trong việc so sánh hiệu quả giữa các mô hình, chỉ số RMSE trên tập huấn luyện cũng được tính toán và trình bày tại Bảng 4.5.

Bảng 4.5. Kết quả dự báo RMSE trên tập huấn luyện cho các mô hình


Mô hình	CNN		DRNN		LSTM	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	4.72	3.25	13.12	11.1	14.02	14.78
	3.52	4.27	11.38	13.1	14.74	15.02
	3.44	4.4	12.43	13.19	14.03	13.53
	3.49	3.89	14.01	11.8	14.37	14.54
	4.31	5.31	12.41	13.43	11.78	13.78
	3.84	4.97	13.2	12.12	14.32	14.56
	3.81	3.51	13.93	12.52	13.54	15.24
	4.74	3.72	11.34	12.44	11.43	13.45
	4.2	4.64	12.14	11.8	14.43	14.21
	3.63	4.14	11.78	13.43	13.65	13.45
Trung bình	4.09		12.53		13.94	

Kết quả dự báo RMSE trên tập huấn luyện giữa ba mô hình tiếp tục có sự khác biệt rõ rệt giữa mô hình CNN và hai mô hình còn lại và CNN có RMSE thấp nhất là 4.09.

Bảng 4.6. Kết quả dự báo RMSE trên tập kiểm tra cho các mô hình

Mô hình	CNN		DRNN		LSTM	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	4.46	5.24	12.97	13.89	16.02	17.56
	4.14	5.44	13.02	13.9	16.74	17.89
	4.36	5.22	13.34	13.77	17.03	16.05
	4.84	4.83	13.12	14.34	16.37	17.32
	4.64	6.27	13.45	14.45	16.59	17.67
	4.75	6.17	13.65	13.95	17.23	17.98
	4.7	5.34	13.57	14.09	16.78	16.5
	5.4	4.62	13.72	14.63	16.99	17.78
	5.11	5.18	13.47	14.84	17.28	17.34
	5.33	6.84	13.67	15.45	17	16.9
Trung bình	5.14		13.86		17.05	

Nhằm cung cấp góc nhìn trực quan về hiệu quả dự báo của các mô hình, hình 4.9 trình bày giá trị RMSE trung bình của các mô hình trên tập kiểm tra, qua đó phản ánh độ lệch chuẩn của sai số dự báo cho thấy mức độ chênh lệch giữa giá trị dự báo và giá trị thực tế.



Hình 4.9. Giá trị RMSE trung bình trên tập kiểm tra của các mô hình

Bảng 4.6 và hình 4.9 trên thể hiện giá trị RMSE của ba mô hình CNN, DRNN và LSTM trên tập kiểm tra. Dựa trên số liệu, mô hình CNN có RMSE thấp nhất với giá trị trung bình khoảng 5.14, cho thấy khả năng dự báo chính xác hơn so với hai mô hình còn lại. Mô hình DRNN có RMSE trung bình là 13.86, trong khi LSTM có giá trị cao nhất, đạt trung bình 17.05. Điều này phản ánh rằng mô hình CNN cho kết quả dự báo gần với giá trị thực tế hơn, trong khi DRNN và đặc biệt là LSTM có mức sai số lớn hơn, thể hiện

độ lệch dự báo cao hơn. Nhằm tăng cường độ chính xác và toàn diện trong việc đánh giá mô hình, chỉ số MAE được sử dụng bổ sung bên cạnh các chỉ số khác. Bảng 4.7 thể hiện chỉ số MAE trên tập huấn luyện của các mô hình.

Bảng 4.7. Kết quả dự báo MAE trên tập huấn luyện cho các mô hình


Mô hình	CNN		DRNN		LSTM	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	2.98	3.15	7.77	6.1	8.18	6.34
	3.01	2.56	5.83	5.72	7.54	7.77
	4.11	2.7	6.2	6.34	7.67	7.53
	2.4	2.5	7.12	6.5	6.96	6.89
	2.63	3.27	6.16	5.91	6.37	7.23
	2.68	3.14	7.4	6.58	7.01	7.45
	3.36	4.29	6.36	7.01	6.77	6.14
	3.01	3.38	5.92	6.99	7.45	7.13
	2.42	3.31	5.67	6.5	7.98	6.67
	3.29	2.41	7.01	6.91	7.65	8.12
Trung bình	3.03		6.50		7.24	

Bảng 4.7 trình bày kết quả MAE trên tập huấn luyện cho ba mô hình. Kết quả cho thấy mô hình kết hợp CNN đạt giá trị MAE trung bình thấp nhất 3.03. Bên cạnh đó mô hình LSTM tiếp tục cho kết quả thấp nhất là 7.24.

Bảng 4.8. Kết quả dự báo MAE trên tập kiểm tra cho các mô hình

Mô hình	CNN		DRNN		LSTM	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	3.07	3.7	6.08	8.21	8.78	9.1
	3.07	4.15	6.23	6.23	8.54	9.77
	3.29	3.83	6.78	7.43	8.67	9.06
	3.59	3.78	7.07	7.95	8.96	8.67
	3.48	4.81	6.83	8.23	8.58	9.45
	3.7	4.97	7.12	6.56	8.57	9.59
	3.45	4.18	7.56	7.65	9.32	8.93
	4.1	3.75	6.77	7.32	9.12	9.6
	4.05	3.93	6.98	7.95	9.67	9.89
	4.16	5.34	7.41	8.23	8.89	9.45
Trung bình	3.92		7.23		9.13	

Nhằm cung cấp góc nhìn trực quan về hiệu quả dự báo của các mô hình, biểu đồ hình 4.10 trình bày giá trị MAE trung bình trên tập kiểm tra, qua đó phản ánh sai số tuyệt đối trung bình giữa giá trị dự báo và giá trị thực tế cho thấy mức độ chênh lệch trung bình mà mô hình tạo ra trong quá trình dự báo.



Hình 4.10. Giá trị MAE trung bình trên tập kiểm tra của các mô hình

Tương tự như hai chỉ số MAPE và RMSE đã phân tích trước đó, bảng 4.8 trên với giá trị MAE trung bình trên tập kiểm tra tiếp tục khẳng định hiệu quả vượt trội của mô hình CNN. Cụ thể, CNN đạt giá trị MAE trung bình thấp nhất 3.92, cho thấy sai số tuyệt đối trung bình giữa giá trị dự báo và thực tế là nhỏ nhất so với hai mô hình còn lại. Mô hình DRNN có MAE trung bình cao hơn 7.23, trong khi LSTM tiếp tục cho kết quả kém nhất với giá trị trung bình lên tới 9.13. Điều này cho thấy mô hình CNN không chỉ ổn định mà còn duy trì được độ chính xác cao hơn xuyên suốt các chỉ số đánh giá. Ngoài độ chính xác, thời gian huấn luyện cũng là yếu tố quan trọng khi triển khai mô hình. Bảng 4.9 so sánh thời gian huấn luyện trung bình của CNN, DRNN và LSTM để thấy rõ ưu nhược điểm về tốc độ xử lý:

Bảng 4.9. Thời gian huấn luyện trung bình của các mô hình học sâu

Mô hình	Thời gian huấn luyện trung bình (giờ)
CNN	28
DRNN	188
LSTM	302


Kết quả cho thấy mô hình CNN có thời gian huấn luyện trung bình ngắn nhất, chỉ khoảng 28 giây, nhờ cấu trúc mạng đơn giản và khả năng tính toán song song hiệu quả. Trong khi đó, DRNN và đặc biệt là LSTM mất nhiều thời gian hơn để huấn luyện (188 giây và 302 giây tương ứng), do đặc thù của các mô hình tuần tự phải xử lý theo từng bước thời gian.

Tuy nhiên, hiệu suất của CNN vẫn chịu ảnh hưởng đáng kể từ các tham số huấn luyện đầu vào như số lượng bộ lọc filters, kích thước kernel, dense units, dropout rate, epochs, batch size. Do việc lựa chọn thủ công các siêu tham số thông qua thử và sai không chỉ tiêu tốn nhiều thời gian mà còn không đảm bảo tìm được cấu hình tốt nhất và mô hình dễ gặp tình trạng quá khớp hoặc học kém. Do đó, để tối ưu hóa cải thiện hiệu quả và độ tin cậy của mô hình, cần áp dụng thêm một giải pháp tối ưu hóa tự động được trình bày trong phần 4.2.2.

4.2.2. Mô hình kết hợp học sâu và các thuật toán tối ưu hóa sinh học

Trong báo cáo này, mô hình dự báo mức tiêu thụ năng lượng sử dụng sự kết hợp giữa học sâu và thuật toán tối ưu hóa sinh học. Cụ thể, mô hình học sâu được sử dụng để học và trích xuất các đặc trưng phức tạp từ chuỗi thời gian, còn thuật toán sinh học được dùng để tối ưu các siêu tham số của các mô hình học sâu như filters, kernel, dense units, dropout rate, epochs, batch size.

Hình 4.11 mô tả kiến trúc của phương pháp đề xuất. Quy trình trên mô tả hệ thống dự báo mức tiêu thụ năng lượng sử dụng mạng nơ-ron tích chập CNN kết hợp với các thuật toán tối ưu sinh học. Đầu tiên, dữ liệu được thu thập và tiền xử lý, bao gồm chuẩn hóa để đưa các giá trị về cùng thang đo. Sau đó, mô hình CNN thực hiện trích xuất đặc trưng từ dữ liệu đầu vào thông qua các tham số như số lượng bộ lọc filters, kích thước kernel, dense units, dropout rate, epochs, batch size. Để tối ưu hóa hiệu suất của mô hình và giảm thiểu sai số dự báo, các thuật toán tối ưu sinh học như WaOA, COA, AVOA được tích hợp nhằm tự động tìm kiếm bộ tham số tốt nhất trong không gian siêu tham số. Sau khi quá trình tối ưu hoàn tất, mô hình CNN sẽ sử dụng bộ tham số tốt nhất để tiến hành huấn luyện chính thức và thực hiện dự báo mức tiêu thụ năng lượng. Kết quả đầu ra là các giá trị dự báo được kỳ vọng có độ chính xác cao, hỗ trợ hiệu quả cho quá trình giám sát, quản lý và tối ưu hóa năng lượng trong môi trường sản xuất thông minh. Các công thức ở phần này được lấy từ các tài liệu tham khảo tương ứng [41-43].



Hình 4.11. Kiến trúc của phương pháp đề xuất

4.2.2.1. Mô hình kết hợp CNN – WaOA

Thuật toán tối ưu hải mã WaOA là một metaheuristic sinh học lấy cảm hứng từ hành vi di cư và săn mồi của hải mã. Khi kết hợp với CNN, WaOA giúp tìm kiếm tổ hợp tham số huấn luyện tối ưu như số lượng bộ lọc filters, kích thước kernel, dense units, dropout rate, epochs, batch size. Các bước tiến hành của CNN – WaOA được phát triển được minh họa bằng các bước sau.

Bước 1: Khởi tạo quần thể hải mã

Mục tiêu đầu tiên là tạo ra một quần thể ban đầu gồm n cá thể hải mã, trong đó mỗi cá thể là một tổ hợp siêu tham số của mô hình CNN:

$$W = \{ W_1, W_2, \dots, W_n \}$$

$$W_i = [\text{filters}, \text{kernel size}, \text{dense units}, \text{dropout}, \text{epochs}, \text{batch size}]$$

- Các giá trị được khởi tạo ngẫu nhiên trong phạm vi đã xác định giới hạn trên và dưới
- $i \in \{1, 2, \dots, n\}$: số cá thể hải mã trong quần thể.
- $j \in \{1, 2, \dots, m\}$: chỉ số tham số của vector W_i , với $m = 6$
- $t \in \{1, 2, \dots, T\}$: chỉ số vòng lặp của thuật toán.

Sau đó, với mỗi cá thể W_i , ta huấn luyện mô hình CNN và tính fitness bằng hàm mất mát RMSE trên tập kiểm tra:

$$F(W_i) = \text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (4.1)$$

Bước 2: Xác định hải mã mạnh nhất

Sau khi đã đánh giá tất cả các cá thể, thuật toán xác định cá thể có RMSE thấp nhất chính là cá thể mạnh nhất, được gọi là SW. Cá thể này đóng vai trò dẫn hướng cho các cá thể khác trong giai đoạn tiếp theo.

$$SW = \arg \min_{W_i} F(W_i) \quad (4.2)$$

Bước 3: Pha 1 – Tìm kiếm thức ăn

Giai đoạn này mô phỏng hành vi hải mã tìm kiếm thức ăn trong tự nhiên đây là giai đoạn khai phá. Mỗi cá thể W_i cập nhật vị trí mới tức là bộ tham số mới dựa trên hướng của hải mã mạnh nhất:

$$W_{i,j}^{P1} = W_{i,j} + \text{rand}_{i,j} \cdot (SW_j - I_{i,j} \cdot W_{i,j}) \quad (4.3)$$

Trong đó:

- $\text{rand}_{i,j} \in [0, 1]$ là số ngẫu nhiên
- $I_{i,j} \in \{1, 2\}$ là số nguyên ngẫu nhiên để tạo nhiễu
- SW_j thành phần j trong cá thể tốt nhất

Từ đó tạo ra bộ tham số mới có định hướng nhưng vẫn ngẫu nhiên, đảm bảo tính đa dạng của quần thể. Nếu vị trí mới cải thiện tức fitness giảm, thì cập nhật cá thể:

$$W_i = \begin{cases} W_i^{P1} & \text{nếu } F_i^{P1} < F_i \\ W_i & \text{ngược lại} \end{cases} \quad (4.4)$$

Bước 4: Pha 2 – Di cư

Ở pha này, hải mã mô phỏng hành vi di chuyển đến khu vực khác, tức là di chuyển tới một cá thể ngẫu nhiên W_k

Nếu $F(W_k) < F(W_i)$ tức cá thể kia mạnh hơn, thì di chuyển về phía đó:

$$W_{i,j}^{P2} = W_{i,j} + \text{rand} \cdot (W_{k,j} - I_{i,j} \cdot W_{i,j}) \quad (4.5)$$

Ngược lại, nếu W_i mạnh hơn, thì thực hiện bước đi ngược chiều:

$$W_{i,j}^{P2} = W_{i,j} + \text{rand} \cdot (W_{i,j} - W_{k,j}) \quad (4.6)$$

Nhờ vậy, thuật toán thử khám phá vùng giải pháp xung quanh các cá thể mạnh hơn, đồng thời duy trì được sự phân tán vị trí. Nếu cải thiện cập nhật lại cá thể mới:

$$W_i = \begin{cases} W_i^{P2} & \text{nếu } F_i^{P2} < F_i \\ W_i & \text{ngược lại} \end{cases} \quad (4.7)$$

Bước 5: Khai thác

Sau khi đã trải qua các pha khai phá hay tìm kiếm thức ăn và di cư, thuật toán tiến vào pha khai thác cục bộ, nơi mỗi cá thể hải mã bắt đầu tinh chỉnh nhẹ vị trí hiện tại để tìm ra nghiệm tốt hơn trong vùng gần nghiệm đang có. Pha này giúp tối ưu các tham số như filters, kernel size, dense units,... để tìm ra mô hình dự báo tốt hơn. Đây là giai đoạn cuối trong mỗi vòng lặp, giúp thuật toán hội tụ nhanh chóng về nghiệm tối ưu.

Công thức cập nhật vị trí khai thác:

$$W_{i,j}^{P3} = W_{i,j} + \left(lb_j^{(t)} + (ub_j^{(t)} - \text{rand}_{i,j} \cdot lb_j^{(t)}) \right) \quad (4.8)$$

Trong đó:

- $W_{i,j}$: Giá trị hiện tại của tham số thứ j của hải mã thứ i
- $\text{rand}_{i,j} \in [0,1]$: Một số ngẫu nhiên điều khiển mức độ dịch chuyển
- $lb_j^{(t)} = \frac{lb_j}{t}$: Giới hạn dưới cục bộ giảm dần theo số vòng lặp
- $ub_j^{(t)} = \frac{ub_j}{t}$: Giới hạn trên cục bộ giảm dần tương tự

Nếu cải thiện cập nhật lại cá thể mới:

$$W_i = \begin{cases} W_i^{p3} & \text{nếu } F_i^{p3} < F_i \\ W_i & \text{ngược lại} \end{cases} \quad (4.9)$$

Bước 6: Lặp lại và cập nhật nghiệm tốt nhất

Bước này là quá trình lặp lại bước 3 và 4 trong vòng lặp T, số vòng lặp tối đa, sau mỗi vòng lặp cập nhật cá thể hải mã tốt nhất. Kiểm tra toàn bộ quần thể, chọn hải mã có fitness tốt nhất tức là mô hình CNN có RMSE thấp nhất.

So sánh toàn bộ quần thể:

$$W_{\text{best}} = \arg \min_{W_i} F(W_i) \quad (4.10)$$

$$\text{Nếu } F(W_i^{p3}) < F(W_{\text{best}}), \text{ thì cập nhật } W_{\text{best}} \leftarrow W_i^{p3}.$$

Ghi nhận hải mã này là W_{best} chính là tập tham số CNN tối ưu hiện tại.

Bước 7: Huấn luyện mô hình CNN cuối cùng

Dùng bộ tham số tối ưu W_{best} để huấn luyện mô hình CNN trên toàn bộ tập huấn luyện. Sau đó, đánh giá hiệu suất mô hình trên tập huấn luyện và kiểm tra.

Sau khi xác định và mô tả đầy đủ các bước thực hiện của thuật toán kết hợp giữa CNN và WaOA, quá trình tiếp theo là tiến hành chuyển hóa các bước này thành dạng biểu diễn thuật toán cụ thể. Cấu trúc thuật toán sẽ bao gồm toàn bộ tiến trình từ khởi tạo dữ liệu, thiết lập tham số, huấn luyện mô hình CNN, áp dụng WaOA để tối ưu tham số huấn luyện, cho đến đánh giá kết quả và cập nhật mô hình. Trong đó, mỗi bước đều được diễn giải chi tiết về đầu vào, xử lý trung gian và đầu ra tương ứng, đảm bảo tính logic và tính khả thi khi triển khai thực tế.

Thuật toán 1. Quy trình WaOA – CNN.

Input:

$$W = \{W_1, W_2, \dots, W_n\}$$

$$t \in \{1, 2, \dots, T\}$$

Xác định T

Output:

$$W_{best}$$

Kết quả dự báo trên tập huấn luyện và kiểm tra.

Begin

1. Khởi tạo quần thể W gồm n cá thể W_i ngẫu nhiên trong không gian tìm kiếm.
2. While $t \leq t_{\max}$ do
3. For mỗi $W_i \in W$ do
4. Huấn luyện mô hình CNN với W_i .
5. Tính fitness $F(W_i)$ sử dụng phương trình (4.1)
6. End for
7. Xác định cá thể mạnh nhất ban đầu sử dụng phương trình (4.2)
8. For $i = 1$ to n do
9. // Pha 1: Tìm kiếm thức ăn
10. Tính toán vị trí mới W_i^{P1} theo phương trình (4.3)
13. Cập nhật vị trí mới W_i theo phương trình (4.4)
14. // Pha 2: Di cư
15. Chọn ngẫu nhiên một cá thể $W_k \neq W_i$.
16. If $F(W_k) < F(W_i)$ then dùng công thức (4.5) tính toán W_{ij}^{P2}
17. Else dùng công thức (4.6) tính toán W_{ij}^{P2}
18. End if
19. Cập nhật vị trí mới W_i theo phương trình (4.7)
22. // Pha 3: Khai thác cục bộ
23. Tính toán vị trí mới W_i^{P3} theo phương trình (4.8)
25. Cập nhật vị trí mới W_i theo phương trình (4.9)
26. End for
28. Cập nhật vị trí W_{best} theo phương trình (4.10)
29. Tăng vòng lặp $t \leftarrow t + 1$.
30. End while
31. Xuất W_{best} là bộ tham số CNN tốt nhất.
32. Dùng bộ tham số tối ưu W_{best} để dự báo trên tập huấn luyện và kiểm tra
33. Tính các chỉ số đánh giá hiệu suất dự báo
- End

4.2.2.2. Mô hình kết hợp CNN – COA

Để cải thiện hiệu suất của mô hình dự báo CNN mức tiêu thụ năng lượng trong nhà máy thép việc sử dụng COA để tối ưu hóa tham số đầu vào là cần thiết. COA là một thuật toán mới được phát triển, mô phỏng hành vi của gấu mèo mũi nhọn trong tự nhiên. Thuật toán này đưa ra các giải pháp chính xác cho các vấn đề tối ưu hóa bằng cách nhận thấy sự ổn định phù hợp giữa thăm dò và khai thác. Các bước tiến hành của CNN – COA được phát triển được minh họa bằng các bước sau.

Khi được tích hợp với CNN, thuật toán COA đóng vai trò tìm ra tổ hợp các siêu tham số như filters, kernel size, dense units, dropout, epochs, batch size sao cho mô hình đạt được độ chính xác dự báo cao nhất và giảm thiểu sai số. Việc kết hợp giữa CNN – COA không chỉ giúp cải thiện hiệu suất mô hình mà còn tăng tính ổn định và khả năng tổng quát của kết quả dự báo trong điều kiện dữ liệu sản xuất thực tế có tính biến động cao.

Bước 1: Khởi tạo quần thể gấu mèo mũi nhọn

Khởi tạo ngẫu nhiên một quần thể gồm N cá thể gấu mèo mũi nhọn, trong đó mỗi gấu mèo mũi nhọn đại diện cho một tổ hợp tham số của mô hình CNN.

$$C = \{C_1, C_2, \dots, C_n\}$$

$$C_i = [\text{filters, kernel size, dense units, dropout, epochs, batch size}]$$

- $i \in \{1, 2, \dots, n\}$: số cá thể gấu mèo mũi nhọn trong quần thể.
- $j \in \{1, 2, \dots, m\}$: chỉ số tham số của vector C_i với $m = 6$.
- $t \in \{1, 2, \dots, T\}$: chỉ số vòng lặp của thuật toán.

Mỗi tham số C_{ij} được khởi tạo ngẫu nhiên trong khoảng giá trị cho phép:

$$C_{ij} = lb_j + r \cdot (ub_j - lb_j), r \in [0, 1] \quad (4.11)$$

Trong đó:

- lb_j, ub_j : giới hạn dưới và trên của tham số thứ j .
- r : số thực ngẫu nhiên phân bố đều trong khoảng $[0, 1]$.

Bước 2: Đánh giá chất lượng

Với mỗi cá thể gấu mèo mũi nhọn, huấn luyện mô hình CNN bằng tập tham số tương ứng và đánh giá kết quả trên tập kiểm tra.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (4.12)$$

Bước 3: Khai phá

Gấu mèo mũi nhọn mô phỏng hành vi leo cây đuổi kỳ nhông chia quần thể thành 2 nửa bằng nhau và thành hai trường hợp:

Nửa đầu gấu mèo leo cây, tiếp cận vị trí tốt nhất hiện tại Iguana gọi là "kỳ nhông".

$$\text{Iguana} = C_{\text{best}} = \arg \min_{C_i} F(C_i) \quad (4.13)$$

$$C_{ij}^{\text{new}} = C_{ij} + r \cdot (\text{Iguana}_j - I \cdot C_{ij}), I \in \{1,2\} \quad (4.14)$$

Trong đó:

- Iguana_j : giá trị thành phần thứ j của cá thể tốt nhất hiện tại.
- I : hệ số điều chỉnh, lấy ngẫu nhiên trong $\{1,2\}$.
- r : số ngẫu nhiên trong $[0,1]$.

Nửa sau tấn công Iguana rơi ngẫu nhiên trên mặt đất. Sau khi con iguana rơi xuống đất, nó được đặt ở một vị trí ngẫu nhiên trong không gian tìm kiếm. Dựa trên vị trí ngẫu nhiên này, con gấu mèo mũi nhọn trên mặt đất di chuyển trong không gian tìm kiếm, điều này được mô phỏng bằng các phương trình dưới.

Vị trí ngẫu nhiên iguana:

$$\text{Iguana}_{G_j} = lb_j + r \cdot (ub_j - lb_j) \quad (4.15)$$

Cập nhật:

$$C_{ij}^{\text{new}} = \begin{cases} C_{ij} + r \cdot (\text{Iguana}_{G_j} - I \cdot C_{ij}) & \text{nếu } F(\text{Iguana}_G) < F(C_i) \\ C_{ij} + r \cdot (C_{ij} - \text{Iguana}_{G_j}) & \text{ngược lại} \end{cases} \quad (4.16)$$

Cập nhật cá thể nếu tốt hơn:

$$C_i = \begin{cases} C_i^{\text{new}} & \text{nếu } F(C_i^{\text{new}}) < F(C_i) \\ C_i & \text{ngược lại} \end{cases} \quad (4.17)$$

r không phải là tham số cố định mà là một giá trị được tạo mới ở mỗi vòng lặp, dùng để tạo sự ngẫu nhiên và đa dạng hóa chiến lược tìm kiếm của thuật toán. Cơ chế này giúp thuật toán linh hoạt hơn và giảm nguy cơ bị kẹt trong cực trị địa phương.

Bước 4: Khai thác

Sau khi đã "khai phá" không gian tham số ở Bước 3, nếu gấu mèo mũi nhọn đã đến gần vùng tốt có RMSE thấp ở giai đoạn đầu và giữa của thuật toán thì thay vì tiếp tục đi xa, nó sẽ ở lại quanh đó và tìm kiếm chi tiết hơn và tạo ra biến thể ngẫu nhiên nhẹ xung quanh nghiệm tốt nhất.

Tính cận cục bộ của mỗi tham số j tại vòng lặp t :

$$lb_j^{local} = \frac{lb_j}{t}, ub_j^{local} = \frac{ub_j}{t} \quad (4.18)$$

Cập nhật vị trí mới trong vùng lân cận:

$$C_{ij}^{new} = C_{ij} + (1 - 2r) \cdot (lb_j^{local} + r \cdot (ub_j^{local} - lb_j^{local})) \quad (4.19)$$

Cập nhật cá thể nếu tốt hơn:

$$C_i = \begin{cases} C_i^{new} & \text{nếu } F(C_i^{new}) < F(C_i) \\ C_i & \text{ngược lại} \end{cases} \quad (4.20)$$

Bước 5: Vòng lặp tối ưu

Bước này là quá trình lặp lại bước 3 và 4 trong vòng lặp T , số vòng lặp tối đa, sau mỗi vòng lặp cập nhật cá thể gấu mèo mũi nhọn tốt nhất. Kiểm tra toàn bộ quần thể, chọn gấu mèo mũi nhọn có fitness tốt nhất tức là mô hình CNN có RMSE thấp nhất.

So sánh toàn bộ quần thể:

$$C_{best} = \arg \min_{C_i} F(C_i) \quad (4.21)$$

Nếu $F(C_i^{new}) < F(C_{best})$, thì cập nhật $C_{best} \leftarrow C_i^{new}$.

Ghi nhận gấu mèo mũi nhọn này là C_{best} chính là tập tham số CNN tối ưu hiện tại.

Bước 6: Huấn luyện mô hình CNN cuối cùng

- Dùng bộ tham số tối ưu C_{best} để huấn luyện mô hình CNN trên toàn bộ tập huấn luyện.
- Đánh giá hiệu suất mô hình trên tập huấn luyện và kiểm tra.

Sau khi xác định và mô tả đầy đủ các bước thực hiện của thuật toán kết hợp giữa CNN và COA, quá trình tiếp theo là tiến hành chuyển hóa các bước này thành dạng biểu diễn thuật toán cụ thể, nhằm minh họa rõ ràng quy trình hoạt động của mô hình. Việc trình bày thuật toán dưới dạng giả mã không chỉ giúp tăng tính trực quan, mà còn hỗ trợ việc triển khai mô hình trong thực tế một cách chính xác và có hệ thống. Phần thuật toán 2 trình bày chi tiết thuật toán CNN – COA dưới dạng các bước tuần tự.

Thuật toán 2. Quy trình COA – CNN.

Input:

$$C = \{C_1, C_2, \dots, C_n\}$$

Số vòng lặp tối đa T

Output:

C_{best} tập tham số tối ưu tương ứng với giá trị RMSE thấp nhất

Kết quả dự báo trên tập huấn luyện và kiểm tra.

Begin

1. Khởi tạo ngẫu nhiên n cá thể $C_i \in C$ theo công thức (4.11)
2. While $t \leq T$ do
 3. For mỗi $C_i \in C$ do huấn luyện mô hình CNN với C_i
 4. Tính fitness $F(C_i)$ sử dụng phương trình (4.12)
 5. End for
 6. Xác định cá thể tốt nhất ban đầu gọi là kỳ nhông Iguana theo công thức (4.13)
 7. Chia quần thể thành hai nửa bằng nhau
 8. For $i = 1$ to n do
 9. If i thuộc nửa đầu then
 - // Leo cây tấn công Iguana tính toán C_{ij}^{new} theo công thức (4.14)
 10. Else // Tấn công Iguana rơi ngẫu nhiên tính vị trí Iguana ngẫu nhiên (4.15)
 - If $F(IguanaG) < F(C_i)$ then
 - Tính toán C_{ij}^{new} theo công thức (4.16)
 - Else
 - Tính toán C_{ij}^{new} theo công thức (4.16)
 - End if
 - End if
 11. Cập nhật cá thể tốt hơn C_i theo công thức (4.17)
 12. // Khai thác - Trốn kẻ săn mồi
 13. Tính cận cục bộ theo công thức (4.18)
 14. Tính toán C_{ij}^{new} theo công thức (4.19)
 15. Cập nhật cá thể tốt hơn C_i theo công thức (4.20)
 16. End for
 17. Cập nhật vị trí C_{best} theo phương trình (4.21)
 18. Tăng $t \leftarrow t + 1$
 19. End while
 20. Xuất C_{best} là bộ tham số CNN tốt nhất.
 21. Dùng bộ tham số tối ưu C_{best} để dự báo trên tập huấn luyện và kiểm tra
 22. Tính các chỉ số đánh giá hiệu suất dự báo

End

4.2.2.3. Mô hình kết hợp CNN – AVOA

Để tăng độ chính xác và hiệu quả của mô hình CNN trong việc dự báo mức tiêu thụ năng lượng, thuật toán AVOA được tích hợp để tối ưu hóa các siêu tham số đầu vào như: filters, kernel size, dense units, dropout, epochs và batch size. AVOA mô phỏng hành vi săn mồi, chia nhóm, di chuyển và tấn công con mồi của kền kền châu Phi. Với khả năng chuyển đổi mượt mà giữa hai pha khai phá và khai thác, AVOA có ưu điểm vượt trội trong việc tránh kẹt tại cực trị địa phương và đạt nghiệm tối ưu toàn cục. Các bước tiến hành của CNN – AVOA được phát triển được minh họa bằng các bước sau.

Bước 1: Khởi tạo quần thể kền kền

Khởi tạo ngẫu nhiên một quần thể gồm n kền kền, trong đó mỗi cá thể V_i đại diện cho một bộ tham số của mô hình CNN:

$$V = \{V_1, V_2, \dots, V_n\}$$

$$V_i = [\text{filters}, \text{kernel size}, \text{dense units}, \text{dropout}, \text{epochs}, \text{batch size}]$$

- $i \in \{1, 2, \dots, n\}$: số cá thể kền kền trong quần thể.
- $j \in \{1, 2, \dots, m\}$: chỉ số tham số của vector V_i với $m = 6$.
- $t \in \{1, 2, \dots, T\}$: chỉ số vòng lặp của thuật toán.

Mỗi tham số V_{ij} được khởi tạo ngẫu nhiên trong khoảng giá trị cho phép:

$$V_{ij} = lb_j + rand_j \cdot (ub_j - lb_j) \quad (4.22)$$

Trong đó:

- lb_j, ub_j : giới hạn dưới và trên của tham số thứ j .
- r : số thực ngẫu nhiên phân bố đều trong khoảng $[0, 1]$.

Bước 2: Đánh giá chất lượng

Với mỗi cá thể kền kền, huấn luyện mô hình CNN bằng tập tham số tương ứng và đánh giá kết quả. Sau đó, với mỗi cá thể V_i , ta huấn luyện mô hình CNN và tính fitness bằng hàm mất mát RMSE.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (4.23)$$

Chọn 2 cá thể tốt nhất

- BestVulture₁ : cá thể có fitness thấp nhất
- BestVulture₂ : cá thể tốt thứ hai

Tính xác suất chọn hướng dẫn:

$$p_i = \frac{F_i}{\sum_{i=1}^N F_i} \quad (4.24)$$

Chọn hướng dẫn R(i) cho từng cá thể:

$$R(i) = \begin{cases} \text{BestVulture}_1 & \text{if } p_i \leq L_1 \\ \text{BestVulture}_2 & \text{otherwise} \end{cases} \quad (4.25)$$

Trong đó:

- $L_1 + L_2 = 1$, thường lấy $L_1 = 0.6, L_2 = 0.4$
- $R(i)$ là cá thể dẫn hướng để cập nhật vị trí mới cho V_i

Bước 3: Tính mức độ đói của kền kền

Mức độ đói F_i giúp xác định chế độ hoạt động khai thác hoặc khai phá của mỗi cá thể:

$$F_i = (2 \cdot \text{rand}_1 + 1) \cdot z \cdot \left(1 - \frac{\text{iteration}}{\text{maxiterations}}\right) + t$$

$$t = h \cdot \left[\sin \left(\frac{\pi}{2} \cdot \frac{\text{iteration}}{\text{maxiterations}} \right) + \cos \left(\frac{\pi}{2} \cdot \frac{\text{iteration}}{\text{maxiterations}} \right) - 1 \right] \quad (4.26)$$

Với:

- $\text{rand}_1 \in [0,1], z \in [-1,1], h \in [-2,2]$
- Iteration: vòng lặp hiện tại
- Maxiterations: số vòng lặp tối đa T

Bước 4: Khai phá

Nếu $|F_i| \geq 1$, cá thể V_i tiến hành khai phá không gian tìm kiếm theo hai chiến lược:
Chiến lược 1 dựa vào khoảng cách đến cá thể tốt nhất nếu $V_1 \geq \text{rand}_{V_i}$

$$D_i = |X \cdot R - V_i|, X \in [0,2]$$

$$V_i^{\text{new}} = R - D_i \cdot F_i \quad (4.27)$$

- R : là vị trí của một trong hai cá thể tốt nhất hiện tại
- D_i : độ chênh lệch giữa cá thể V_i và cá thể dẫn hướng R
- X nằm trong khoảng $[0;2]$
- Cá thể V_i sẽ tiến gần hoặc lùi ra xa khỏi R tùy thuộc vào độ đói F_i , giúp đảm bảo quá trình tìm kiếm mang tính khám phá.

Chiến lược 2 bay đến một vùng ngẫu nhiên nếu $V_1 < rand_1$. Phương pháp này giúp cá thể không bị kẹt tại vùng cục bộ mà khám phá nhiều vùng mới trong không gian tham số.

$$V_i^{new} = R - F_i + rand_2 \cdot ((ub - lb) \cdot rand_3 + lb) \quad (4.28)$$

Trong đó:

- ub, lb : vector giới hạn trên/dưới của không gian tìm kiếm
- $rand_2, rand_3$: đại diện cho một số ngẫu nhiên giữa 0 và 1

Nhờ cơ chế này, mô hình được dẫn dắt khám phá các vùng tham số khác nhau một cách linh hoạt, vừa mang tính ngẫu nhiên vừa dựa trên hướng của các cá thể mạnh hơn.

Bước 5: Khai thác

Nếu $|F_i| < 1$, tức cá thể kền kền đã đến gần con mồi nghiệm tốt, nó sẽ chuyển sang khai thác tìm kiếm kỹ hơn quanh nghiệm tốt. Gồm 2 trường hợp:

- ❖ **Trường hợp 1:** $0.5 \leq |F_i| < 1$. V_2 được tạo ra ngẫu nhiên trong khoảng $[0;1]$ và so sánh với $rand_2$.

Chiến lược 1 chiến đấu bao vây nếu $V_2 \geq rand_2$

$$V_i^{new} = D(i) \times (F_i + rand_4) - d(t) \quad (4.29)$$

Chiến lược 2 kỹ thuật bay xoay vòng được áp dụng khi $V_2 < rand_2$

$$V_i^{new} = R(i) - (S_1 + S_2) \quad (4.30)$$

Trong đó:

$$d(i) = R(i) - P(i) \quad (4.31)$$

$$\begin{aligned} S_1 &= R(i) \times \left(\frac{rand_5 \times V_i}{2\pi} \right) \times \cos(V_i) \\ S_2 &= R(i) \times \left(\frac{rand_6 \times V_i}{2\pi} \right) \times \sin(V_i) \end{aligned} \quad (4.32)$$

- $rand_4, rand_5, rand_6$: đại diện cho một số ngẫu nhiên giữa 0 và 1

- ❖ **Trường hợp 2:** $|F_i| < 0.5$. V_3 được tạo ra ngẫu nhiên trong khoảng $[0;1]$ và so sánh với $rand_3$.

Chiến lược 1 hành vi tập hợp nếu $V_3 \geq rand_3$

$$V_i^{new} = \frac{A_1 + A_2}{2} \quad (4.33)$$

$$\begin{aligned} A_1 &= \text{BestVulture}_1(i) - \frac{\text{BestVulture}_1(i) \times V_i}{\text{BestVulture}_1(i) - (V_i)^2} \times F_i \\ A_2 &= \text{BestVulture}_1(i) - \frac{\text{BestVulture}_2(i) \times V_i}{\text{BestVulture}_2(i) - (V_i)^2} \times F_i \end{aligned} \quad (4.34)$$

Cá thể tiến hành hội tụ về giữa hai cá thể tốt nhất BestVulture_1 và BestVulture_2 . Sự hội tụ này giúp quá trình tinh chỉnh nghiệm hiệu quả hơn nhờ kết hợp từ cả hai hướng tốt nhất.

Chiến lược 2 hành vi tấn công Lévy nếu $V_3 < \text{rand}_3$ là chiến lược dùng bước nhảy ngẫu nhiên dài ngắn không đều tạo đột phá trong tìm kiếm. Giúp thuật toán thoát khỏi cực trị cục bộ và tìm nghiệm tốt toàn cục

$$V_i^{\text{new}} = R(i) - |d(t)| \times F_i \times \text{Levy}(d) \quad (4.35)$$

Với:
$$\text{Levy}(x) = 0.001 \cdot \frac{u \cdot \sigma}{|v|^{1/\beta}}, \beta = 1.5 \quad (4.36)$$

β là một giá trị mặc định cố định bằng 1.5, u và v là các số ngẫu nhiên từ 0 đến 1, và σ được định nghĩa như sau:

$$\sigma = \left[\frac{\Gamma(1+\beta) \cdot \sin(\pi\beta/2)}{\Gamma((1+\beta)/2) \cdot \beta \cdot 2^{(\beta-1)/2}} \right]^{1/\beta} \quad (4.37)$$

Bước 6: Cập nhật cá thể kền kền tốt nhất

Cuối mỗi vòng lặp, thuật toán sẽ kiểm tra lại toàn bộ quần thể kền kền để tìm ra cá thể có giá trị RMSE thấp nhất, tức là mô hình CNN có hiệu suất dự báo tốt nhất.

Cá thể này được lưu lại và gán làm nghiệm tốt nhất hiện tại:

$$V_{\text{best}} = \arg \min_{V_i} F(V_i) \quad (4.38)$$

Nếu một cá thể mới vượt trội hơn so với V_{best} trước đó, thì vị trí và fitness của nó sẽ thay thế nghiệm toàn cục, làm nền tảng cho các cá thể khác di chuyển theo trong các vòng lặp tiếp theo. Việc cập nhật này đóng vai trò như một "la bàn dẫn đường", giúp thuật toán hội tụ nhanh hơn và tăng khả năng tìm ra nghiệm tối ưu toàn cục.

Bước 7: Huấn luyện mô hình CNN cuối cùng

Dùng bộ tham số tối ưu V_{best} để huấn luyện mô hình CNN trên toàn bộ tập huấn luyện. Sau đó, đánh giá hiệu suất mô hình trên tập huấn luyện và kiểm tra.

Sau khi xác định rõ các bước của thuật toán CNN – AVOA, tiến trình tiếp theo là biểu diễn chúng dưới dạng giả mã thuật toán. Việc trình bày này nhằm minh họa rõ ràng quy trình thực hiện, đồng thời hỗ trợ triển khai mô hình một cách có hệ thống và hiệu quả.

Thuật toán 3. Quy trình AVOA – CNN.

Input: $V = \{V_1, V_2, \dots, V_n\}$ và số vòng lặp tối đa T

Output: V_{best} và kết quả dự báo trên tập huấn luyện và kiểm tra.

Begin

1. Khởi tạo quần thể kền kền V với các giá trị ngẫu nhiên theo công thức (4.22)
2. While $t \leq t_{max}$ do
3. For mỗi cá thể $V_i \in V$ do
4. Huấn luyện mô hình CNN với bộ tham số V_i trên tập huấn luyện.
5. Tính fitness $F(V_i)$ theo công thức (4.23)
6. End for
7. Xác định 2 cá thể tốt nhất ban đầu
8. Khởi tạo vòng lặp: $t = 1$, thiết lập số vòng lặp tối đa $t_{max} = T$
9. For mỗi V_i do
10. Tính toán hướng dẫn $R(i)$ cho từng cá thể theo công thức (4.25)
11. Tính mức độ đói F_i theo công thức (4.26)
12. If $|F_i| \geq 1$ then
13. If $V_1 \geq rand_1$ then
14. Cập nhật V_i^{new} theo công thức (4.27)
15. Else
16. Cập nhật V_i^{new} theo công thức (4.28)
17. End if
18. End if
19. If $|F_i| < 1$ then
20. If $0.5 \leq |F_i| < 1$ then
21. If $V_2 \geq rand_2$ then
22. Cập nhật V_i^{new} theo công thức (4.29)
23. Else
24. Cập nhật V_i^{new} theo công thức (4.30)
25. End if
26. Else
27. If $V_3 \geq rand_3$ then
28. Cập nhật V_i^{new} theo công thức (4.33)
29. Else
30. Cập nhật V_i^{new} theo công thức (4.35)
31. End if
32. End if
33. End if
34. End for
35. Cập nhật vị trí V_{best} theo phương trình (4.21)
36. Tăng $t \leftarrow t + 1$
37. End while
38. Xuất V_{best} là bộ tham số CNN tốt nhất.
39. Dùng bộ tham số tối ưu V_{best} để dự báo trên tập huấn luyện và kiểm tra
40. Tính các chỉ số đánh giá hiệu suất dự báo
- End

4.3. Phân tích kết quả

4.3.1. Kết quả tìm kiếm tham số tối ưu cho CNN bằng các thuật toán tối ưu hóa

Để đánh giá hiệu quả của các thuật toán tối ưu trong việc cải thiện khả năng học và dự báo của mô hình CNN, các tham số huấn luyện chính đã được tinh chỉnh bằng ba thuật toán tối ưu bao gồm COA, WaOA và AVOA. Bảng 4.10 trình bày giá trị tham số tối ưu tương ứng mà mỗi thuật toán tìm được, bao gồm số lượng num filters, kích thước kernel, số đơn vị trong lớp Dense, tỷ lệ dropout, số epoch, kích thước batch và thời gian huấn luyện trung bình của mỗi mô hình kết hợp.

Bảng 4.10. Các tham số huấn luyện tối ưu cho mô hình CNN kết hợp

Tham số	Mô hình		
	CNN-COA	CNN-WaOA	CNN-AVOA
Num filters	75	93	110
Kernel size	5	4	5
Dense units	201	147	222
Dropout rate	0.3	0.5	0.3
Epochs	89	95	86
Batch size	73	86	110
Thời gian huấn luyện trung bình	1 giờ 24 phút	1 giờ 57 phút	1 giờ 42 phút

Từ bảng tham số, có thể thấy rằng mỗi thuật toán tối ưu tìm ra một cấu hình khác nhau cho mô hình CNN, phản ánh sự khác biệt trong chiến lược tìm kiếm lời giải tối ưu của từng thuật toán.

- Số lượng bộ lọc: Mô hình CNN - AVOA sử dụng số lượng bộ lọc cao nhất 110, cho phép trích xuất nhiều đặc trưng hơn từ dữ liệu. Trong khi đó, WaOA và COA chọn ít bộ lọc hơn 93 và 75, cho thấy xu hướng giảm độ phức tạp mô hình nhằm tránh overfitting.
- Kích thước kernel: COA và AVOA chọn kernel size là 5, lớn nhất trong ba thuật toán, giúp nắm bắt thông tin theo thời gian ở phạm vi rộng hơn. Trong khi đó, WaOA chọn kích thước nhỏ hơn 4, tập trung vào đặc trưng cục bộ.
- Số đơn vị trong lớp Dense: COA và AVOA cũng có số đơn vị Dense cao là 201 và 222, cho thấy độ sâu tính toán lớn hơn ở lớp kết nối đầy đủ, còn WaOA 147 đơn vị, hướng đến cân bằng giữa khả năng học và đơn giản hóa mô hình.

- Dropout rate: WaOA áp dụng dropout cao nhất 0.5, cho thấy sự nhấn mạnh vào việc giảm overfitting. COA và AVOA lại chọn mức thấp hơn 0.2, có thể nhằm duy trì khả năng học mạnh hơn trong khi vẫn kiểm soát overfitting vừa đủ.
- Epochs: WaOA cần huấn luyện lâu hơn 95 epochs, ngụ ý rằng mô hình phức tạp hơn và cần thời gian hội tụ dài hơn. COA và AVOA cần ít hơn 89 và 86 epochs, giúp rút ngắn thời gian huấn luyện.
- Batch size: AVOA chọn batch size lớn nhất 110, phù hợp với kiến trúc phức tạp và ổn định gradient hơn. Ngược lại, COA chọn batch nhỏ 73, giúp cập nhật tham số nhanh và có thể học được nhiều biến động nhỏ hơn trong dữ liệu.
- Về thời gian huấn luyện, CNN-COA là nhanh nhất với 1 giờ 24 phút, trong khi CNN-WaOA chậm nhất (1 giờ 57 phút) do quá trình tối ưu phức tạp hơn. CNN-AVOA mất 1 giờ 42 phút, ở mức trung bình. Điều này cho thấy mỗi thuật toán tối ưu ảnh hưởng rõ rệt đến thời gian huấn luyện mô hình.

Nhìn chung, thuật toán AVOA tạo ra mô hình với độ phức tạp cao hơn, trong khi COA và AVOA hướng đến thiết kế nhẹ hơn. Việc lựa chọn tham số phản ánh sự đánh đổi giữa khả năng học sâu và tránh quá khớp, đồng thời cho thấy mỗi thuật toán có cách tiếp cận khác nhau trong việc tối ưu hóa hiệu năng dự báo của mô hình CNN.

4.3.2. Kết quả dự báo của mô hình CNN kết hợp với thuật toán tối ưu

Để đánh giá hiệu quả dự báo của các mô hình được đề xuất vẫn lấy 2000 điểm dữ liệu để tiến hành dự báo và dữ liệu đã được chia thành hai tập 80% cho huấn luyện và 20% cho kiểm tra. Sau khi huấn luyện mô hình trên tập dữ liệu huấn luyện và tiến hành kiểm tra trên tập dữ liệu kiểm tra, đã thu được kết quả dự báo của ba mô hình kết hợp: CNN - WaOA, CNN - COA và CNN - AVOA. Các mô hình này được đánh giá thông qua ba chỉ số phổ biến gồm MAPE, RMSE và MAE. Để tăng cường độ tin cậy trong đánh giá và loại bỏ ảnh hưởng của các yếu tố ngẫu nhiên phát sinh trong quá trình huấn luyện mô hình học sâu, mỗi mô hình được tiến hành huấn luyện 100 lần lặp lại độc lập. Trong các lần huấn luyện đó, 20 mô hình có MAPE thấp nhất trên tập kiểm tra được chọn để phân tích chuyên sâu và trình bày kết quả. Cách tiếp cận này góp phần đảm bảo tính ổn định, khách quan và đại diện cho hiệu suất thực tế của mô hình. Việc so sánh kết quả giữa các mô hình cho phép đánh giá hiệu quả của từng phương pháp tối ưu khi kết hợp với mạng nơ-ron tích chập CNN, từ đó xác định phương án tối ưu nhất trong dự báo mức tiêu thụ năng lượng của nhà máy sản xuất thông minh.

Bảng 4.11. Kết quả dự báo MAPE trên tập huấn luyện cho các mô hình kết hợp


Mô hình	CNN - WaOA		CNN - COA		CNN - AVOA	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	6.97	9.32	7.78	6.89	10.72	8.72
	5.18	8.46	8.36	10.07	8.55	6.36
	9.01	12.67	5.68	5.64	6.6	7.06
	8.29	7.9	10.55	7.76	7.43	8.26
	10.81	11.72	5.35	6.98	8.07	6.54
	8.54	8.12	5.16	8.58	7.79	8.63
	6.3	9.2	6.66	7.71	7.5	10.56
	10.53	11.11	7.12	6.73	8.71	11.79
	7.84	10.1	5.6	4.1	11.2	7.97
	10.11	9.98	8.86	8.76	8.97	9.97
Trung bình	9.11		7.22		8.57	

Bảng 4.11 trình bày kết quả MAPE trên tập huấn luyện cho ba mô hình kết hợp gồm CNN - WaOA, CNN - COA và CNN - AVOA. Kết quả cho thấy mô hình kết hợp CNN - COA đạt giá trị MAPE trung bình thấp nhất 7.22.

Bảng 4.12. Kết quả dự báo MAPE trên tập kiểm tra cho các mô hình kết hợp

Mô hình	CNN - WaOA		CNN - COA		CNN - AVOA	
Lần	1-10	11-20	1-10	11-20	1-10	11-20
	6.8	8.39	3.74	6.21	6.66	7.68
	6.83	8.32	5.21	6.22	6.79	7.72
	7.29	8.44	5.35	6.27	6.88	7.83
	7.34	8.52	5.43	6.27	6.93	7.95
	7.41	8.6	5.85	6.29	6.95	8.18
	7.48	8.63	6.11	6.32	7.11	8.24
	7.59	8.67	6.12	6.34	7.32	8.35
	7.67	8.69	6.15	6.36	7.41	8.48
	7.91	8.91	6.17	6.71	7.57	8.54
	8.31	8.95	6.18	6.93	7.57	8.66
Trung bình	8.04		6.01		7.64	

Nhằm cung cấp góc nhìn trực quan về hiệu quả dự báo của các mô hình, biểu đồ hình 4.12 trình bày giá trị MAPE trung bình trên tập kiểm tra của ba mô hình kết hợp, qua đó phản ánh mức độ sai lệch giữa kết quả dự báo và thực tế.



Hình 4.12. Giá trị MAPE trung bình trên tập kiểm tra của các mô hình kết hợp

Bảng 4.12 trình bày kết quả MAPE trên tập kiểm tra cho ba mô hình kết hợp gồm CNN - WaOA, CNN - COA và CNN - AVOA. Kết quả cho thấy các mô hình kết hợp có kết quả tốt hơn mô hình CNN và đặc biệt mô hình CNN - COA đạt giá trị MAPE trung bình thấp nhất 6.01, thể hiện hiệu quả dự báo cao nhất trong ba mô hình được so sánh. Mô hình CNN - AVOA và CNN - WaOA có MAPE trung bình cao hơn lần lượt là 7.64 và 8.04. Do MAPE là một chỉ số đánh giá mang tính tương đối, nhằm đảm bảo tính khách quan trong việc so sánh hiệu quả giữa các mô hình, chỉ số RMSE trên tập huấn luyện cũng được tính toán và trình bày tại bảng 4.13.

Bảng 4.13. Kết quả dự báo RMSE trên tập huấn luyện cho các mô hình kết hợp


Mô hình	CNN - WaOA		CNN - COA		CNN - AVOA	
Lần	1-10	11-20	1-10	1-10	11-20	1-10
	2.96	3.16	2.53	2.58	2.52	3.56
	3.49	2.92	2.72	3.73	3.43	2.65
	3.48	3.35	3.3	2.98	2.47	3.16
	4.67	3.05	3.24	3.3	3.8	2.87
	2.89	2.42	2.34	2.44	3.39	2.89
	3.34	3.12	2.61	2.29	2.46	2.81
	2.78	3.56	2.64	3.04	2.8	3.57
	2.92	4.45	2.8	2.61	2.74	2.77
	2.89	4.87	2.53	3.78	3.5	3.32
	3.48	3.14	2.85	2.92	2.61	2.95
Trung bình	3.35		2.86		3.01	

Kết quả dự báo RMSE trên tập huấn luyện giữa 3 mô hình với kết quả lần lượt là CNN – COA, CNN – AVOA, CNN – WaOA có RMSE tương ứng là 2.86, 3.01, 3.35. Mô hình CNN - COA tiếp tục cho kết quả tốt nhất.

Bảng 4.14. Kết quả dự báo RMSE trên tập kiểm tra cho các mô hình kết hợp

Mô hình	CNN - WaOA		CNN - COA		CNN - AVOA	
Lần	1-10	11-20	1-10	1-10	11-20	1-10
	3.58	4.47	2.66	3.5	3.64	3.96
	3.95	4.51	3.39	4.4	3.45	3.34
	3.9	4.1	3.51	3.58	3.56	4.61
	4.04	4.23	3.8	3.97	4.35	4.3
	3.86	4.22	3.03	3.61	3.65	3.72
	3.85	4.77	2.97	3.44	4.12	4.04
	3.92	3.98	3.5	4.01	3.77	5.06
	4.53	4.79	3.63	3.24	3.69	3.22
	4.34	4.24	3.27	3.56	3.38	4.25
	5.19	3.46	3.45	3.57	4.19	3.91
Trung bình	4.20		3.50		3.91	

Nhằm cung cấp góc nhìn trực quan về hiệu quả dự báo của các mô hình, biểu đồ hình 4.13 trình bày giá trị RMSE trung bình các mô hình kết hợp trên tập kiểm tra, qua đó phản ánh độ lệch chuẩn của sai số dự báo cho thấy mức độ chênh lệch giữa giá trị dự báo và giá trị thực tế.



Hình 4.13. Giá trị RMSE trung bình trên tập kiểm tra của các mô hình kết hợp

Trong ba mô hình, CNN - COA tiếp tục cho kết quả nổi bật với giá trị RMSE trung bình thấp trên tập test nhất 3.50, phản ánh sai số dự báo nhỏ hơn và ổn định hơn so với các mô hình còn lại. Mô hình CNN - AVOA và CNN - WaOA có RMSE trung bình là

3.91 và 4.20 cao hơn đôi chút so với CNN - COA nhưng vẫn thể hiện hiệu suất tốt. Kết quả này một lần nữa khẳng định việc kết hợp CNN với thuật toán COA giúp nâng cao độ chính xác và giảm sai số dự báo rõ rệt.

Bảng 4.15. Kết quả dự báo MAE trên tập huấn luyện cho các mô hình kết hợp


Mô hình	CNN - WaOA		CNN - COA		CNN - AVOA	
Lần	1-10	11-20	1-10	1-10	11-20	1-10
	1.86	2.23	1.38	1.57	3.54	2.5
	2.06	2.17	1.54	2.2	1.48	1.75
	2.16	2.32	2.16	1.94	1.54	1.98
	1.89	2.65	1.92	1.88	1.56	1.62
	1.74	2.78	1.4	1.5	2.34	2.71
	2.08	2.91	1.48	2.35	2.38	1.67
	1.72	2.12	1.53	2.12	1.56	1.46
	1.7	3.21	1.63	1.47	1.53	2.59
	1.83	3.13	1.47	2.68	2.11	2.32
	1.98	3.45	1.85	1.76	2.49	1.71
Trung bình	2.30		1.79		2.04	

Bảng 4.15 trình bày kết quả MAE trên tập huấn luyện cho ba mô hình kết hợp gồm CNN - WaOA, CNN - COA và CNN - AVOA. Kết quả cho thấy mô hình kết hợp CNN - COA đạt giá trị MAE trung bình thấp nhất 1.79.

Bảng 4.16. Kết quả dự báo MAE trên tập kiểm tra cho các mô hình kết hợp

Mô hình	CNN - WaOA		CNN - COA		CNN - AVOA	
Lần	1-10	11-20	1-10	1-10	11-20	1-10
	2.78	3.27	1.82	2.45	2.57	2.92
	2.92	3.42	2.34	3.16	2.47	2.47
	3.04	3.15	2.38	2.78	2.62	3.37
	3.06	3.08	2.69	2.92	3.15	3.23
	2.89	3.29	2.27	2.64	2.66	2.82
	2.93	3.56	2.21	2.6	3	3.07
	2.93	3.04	2.65	3.08	2.78	3.76
	3.52	3.63	2.6	2.44	2.81	2.51
	3.16	3.27	2.55	2.64	2.57	3.25
	3.91	2.69	2.59	2.6	3.2	2.99
Trung bình	3.18		2.57		2.91	

Nhằm cung cấp góc nhìn trực quan về hiệu quả dự báo của các mô hình, biểu đồ hình 4.14 trình bày giá trị MAE trung bình trên tập kiểm tra của các mô hình kết hợp, qua đó phản ánh sai số tuyệt đối trung bình giữa giá trị dự báo và giá trị thực tế cho thấy mức độ chênh lệch trung bình mà mô hình tạo ra trong quá trình dự báo.



Hình 4.14. Giá trị MAE trung bình trên tập kiểm tra của các mô hình kết hợp


Tương tự như hai chỉ số MAPE và RMSE đã phân tích trước đó, bảng 4.16 với giá trị MAE trung bình tiếp tục khẳng định hiệu quả vượt trội của mô hình CNN - COA. Cụ thể, CNN đạt giá trị MAE trung bình thấp nhất 2.57, cho thấy sai số tuyệt đối trung bình giữa giá trị dự báo và thực tế là nhỏ nhất so với hai mô hình còn lại. Mô hình CNN - AVOA có MAE trung bình cao hơn 2.91, trong khi CNN - WaOA tiếp tục cho kết quả kém hơn với giá trị trung bình lên tới 3.18.

Các bảng trên trình bày kết quả dự báo trên tập huấn luyện và kiểm tra của ba mô hình kết hợp là CNN - WaOA, CNN - COA và CNN - AVOA, được đánh giá qua ba chỉ số phổ biến: MAPE, RMSE và MAE. Có thể thấy rằng mô hình CNN - COA đạt hiệu quả vượt trội hơn so với hai mô hình còn lại về mọi chỉ số.

Từ kết quả trên có thể rút ra rằng mô hình CNN kết hợp với COA là phương án tối ưu nhất trong ba phương pháp được so sánh, khi mang lại độ chính xác cao hơn và sai số dự báo thấp hơn rõ rệt. Nhìn chung, việc kết hợp mô hình học sâu CNN với các thuật toán tối ưu đã cải thiện đáng kể khả năng dự báo, tuy nhiên lựa chọn thuật toán tối ưu phù hợp đóng vai trò then chốt trong hiệu quả cuối cùng của mô hình.

4.4. Biểu đồ so sánh dự báo với thực tế

Để minh họa trực quan hơn cho hiệu quả dự báo của mô hình CNN - COA đã tiến hành biểu diễn kết quả dự báo so với giá trị thực tế dưới dạng biểu đồ. Qua đó, có thể đánh giá trực tiếp mức độ bám sát giữa giá trị dự báo và thực tế của mô hình theo từng mẫu dữ liệu.



Hình 4.15. Biểu đồ so sánh dự báo với thực tế của CNN-COA trên tập kiểm tra

Hình 4.15 minh họa kết quả so sánh giữa giá trị thực tế và giá trị dự báo của mô hình CNN - COA trên tập kiểm tra. Đường màu xanh biểu thị dữ liệu thực tế, trong khi đường màu đỏ thể hiện kết quả dự báo tốt nhất của mô hình. Quan sát biểu đồ cho thấy, mô hình CNN - COA bám khá sát đường thực tế, đặc biệt ở các đoạn dao động thấp và trung bình, cho thấy khả năng học và dự đoán xu hướng dữ liệu tốt. Tuy vẫn còn một số thời điểm có sai lệch, đặc biệt là tại các đỉnh hoặc các đoạn biến động mạnh, nhưng nhìn chung mô hình đã nắm bắt được cấu trúc biến động tổng thể của dữ liệu. Khoảng cách giữa hai đường là khá nhỏ trong phần lớn các mẫu, phản ánh độ chính xác của mô hình điều này cũng phù hợp với các chỉ số MAPE, RMSE và MAE đã phân tích ở phần trước. Như vậy, biểu đồ là minh chứng trực quan cho thấy mô hình CNN - COA là một lựa chọn tối ưu trong bài toán dự báo năng lượng trong môi trường nhà máy sản xuất thép thông minh.

4.5. Ứng dụng và triển khai thực tế

Việc triển khai mô hình dự báo mức tiêu thụ năng lượng trong môi trường nhà máy sản xuất thông minh không chỉ dừng lại ở giai đoạn nghiên cứu học thuật, mà hoàn toàn có thể áp dụng vào thực tiễn nếu thực hiện theo lộ trình phù hợp. Một số định hướng và lưu ý quan trọng khi triển khai như sau:

4.5.1. Các bước triển khai mô hình vào thực tế

- Tích hợp dữ liệu thời gian thực: Cần kết nối hệ thống mô hình với nền tảng thu thập dữ liệu tự động từ nhà máy (như SCADA hoặc IoT). Dữ liệu gồm: mức tiêu thụ năng lượng, lịch sản xuất, trạng thái vận hành máy móc, điều kiện môi trường, v.v.
- Xử lý và chuẩn hóa dữ liệu: Trước khi đưa vào mô hình dự báo, dữ liệu cần được làm sạch, loại bỏ nhiễu và chuẩn hóa (chẳng hạn như chuẩn hóa Min-Max đã áp dụng trong nghiên cứu) để đảm bảo chất lượng đầu vào.
- Triển khai mô hình dự báo: Mô hình CNN kết hợp các thuật toán tối ưu COA sẽ được huấn luyện, kiểm thử và triển khai thông qua nền tảng như TensorFlow hoặc PyTorch trên máy chủ nội bộ hoặc điện toán đám mây.
- Kết nối với hệ thống hỗ trợ ra quyết định (DSS): Kết quả dự báo có thể tích hợp vào các bảng điều khiển quản trị sản xuất, hỗ trợ lập kế hoạch vận hành, lịch bảo trì hoặc điều chỉnh công suất tải theo thời gian.
- Đào tạo nhân sự vận hành: Việc chuyển giao công nghệ và đào tạo kỹ thuật viên sử dụng, giám sát và bảo trì mô hình là bước không thể thiếu để đảm bảo tính bền vững trong ứng dụng.

4.5.2. Những lưu ý khi triển khai mô hình

- Chất lượng dữ liệu: Dữ liệu đầu vào đóng vai trò quyết định độ chính xác của mô hình. Cần xây dựng cơ chế giám sát dữ liệu liên tục để phát hiện lỗi, thiếu hoặc giá trị bất thường.
- Khả năng mở rộng: Khi triển khai mô hình sang các nhà máy hoặc dây chuyền khác, cần điều chỉnh và huấn luyện lại mô hình dựa trên đặc thù dữ liệu mới.
- Ổn định và hiệu suất hệ thống: Hệ thống triển khai cần đảm bảo khả năng hoạt động ổn định 24/7, có dự phòng khi lỗi xảy ra và tối ưu hóa hiệu suất tính toán để đảm bảo phản hồi thời gian thực.
- Bảo mật và quyền truy cập: Dữ liệu sản xuất là dữ liệu nhạy cảm, do đó cần thiết lập cơ chế kiểm soát truy cập, mã hóa thông tin và bảo mật hệ thống phù hợp.
- Tái huấn luyện định kỳ: Do điều kiện sản xuất thay đổi theo thời gian, cần lên kế hoạch tái huấn luyện mô hình định kỳ để mô hình thích nghi và đảm bảo độ chính xác dự báo.

CHƯƠNG 5: KẾT LUẬN VÀ KIẾN NGHỊ

5.1. Kết luận

Trước bối cảnh nhu cầu năng lượng ngày càng tăng và sự phát triển mạnh mẽ của mô hình nhà máy thông minh trong công nghiệp hiện đại, việc quản lý và tối ưu hóa tiêu thụ điện năng trở thành một thách thức thiết yếu, đặc biệt đối với các ngành công nghiệp tiêu thụ nhiều năng lượng như ngành thép.

Nghiên cứu này đã tiến hành khảo sát một cách toàn diện về đặc điểm vận hành của cả hai loại hình nhà máy thép truyền thống và thông minh, nhằm làm rõ sự khác biệt trong cách thức tổ chức sản xuất, giám sát năng lượng và quản lý thiết bị. Trong khi các nhà máy truyền thống chủ yếu vận hành theo quy trình thủ công, thiếu sự tích hợp giữa các hệ thống và phụ thuộc nhiều vào kinh nghiệm con người, thì các nhà máy thông minh ứng dụng công nghệ số, cảm biến IoT và hệ thống tự động hóa để theo dõi và điều khiển tiêu thụ năng lượng một cách chính xác, thời gian thực. Tuy nhiên, một thực tế cần được cân nhắc là việc vận hành một hệ thống nhà máy thông minh cũng đòi hỏi tiêu tốn một lượng năng lượng đáng kể cho các thiết bị điện tử, máy chủ xử lý dữ liệu, hệ thống cảm biến, hệ thống truyền thông và các thuật toán phân tích chạy liên tục.

Ngoài ra, nghiên cứu cũng đã xác định và phân tích tương quan các yếu tố có ảnh hưởng lớn đến mức tiêu thụ điện năng trong nhà máy, bao gồm: CO₂, Lagging CrpC, Leading CrpC, Lagging CPF, Leading CPF, Week Status và Load Type sẽ được sử dụng để xây dựng mô hình dự báo, nhằm đảm bảo độ chính xác và hiệu quả mô hình ở mức cao nhất. Bên cạnh đó NSM và Day of Week là 2 yếu tố có mức độ tương quan với mức tiêu thụ năng lượng thấp nhất là 0.23 và 0.05. Do đó, hai đặc trưng này có thể được loại bỏ khỏi tập dữ liệu đầu vào nhằm giảm độ phức tạp của mô hình mà không làm suy giảm hiệu suất dự báo. Thông qua phân tích này, không chỉ xây dựng được nền tảng dữ liệu vững chắc cho quá trình huấn luyện mô hình mà còn giúp nhận diện được các đặc trưng quan trọng cần đưa vào quá trình dự báo.

Trong nghiên cứu này đã tiến hành so sánh hiệu quả giữa các mô hình học sâu phổ biến gồm CNN, DRNN và LSTM trong bài toán dự báo mức tiêu thụ năng lượng tại nhà máy sản xuất thông minh. Kết quả thực nghiệm trên tập kiểm tra ban đầu cho thấy mô hình CNN với MAPE, RMSE, MAE trung bình lần lượt là 10.91%, 5.14, 3.92 đạt hiệu quả dự báo cao hơn đáng kể về độ chính xác so với 2 mô hình còn lại nên được chọn làm nền tảng để tiếp tục phát triển.

Tuy nhiên, trong quá trình đánh giá nghiên cứu nhận thấy rằng kết quả của mô hình CNN vẫn phụ thuộc nhiều vào quá trình lựa chọn tham số huấn luyện như số lượng bộ lọc filters, kích thước kernel, dense units, dropout rate, epochs, batch size. Để khắc phục hạn chế này và nâng cao độ chính xác, đề xuất kết hợp CNN với các thuật toán tối ưu như WAOA, COA và AVOA để tìm ra các tham số huấn luyện mang lại kết quả tối ưu nhất.

Mô hình được đánh giá thông qua các chỉ số MAE, RMSE và MAPE, cho thấy phương pháp đề xuất có khả năng thích nghi tốt với dữ liệu thực tế thu thập tại nhà máy thép Daewoo (Hàn Quốc). Kết quả thực nghiệm trên tập kiểm tra cho thấy các mô hình kết hợp đều vượt trội so với CNN ban đầu, đặc biệt là mô hình CNN - COA, với MAPE trung bình chỉ khoảng 6.01%, RMSE là 3.50 và MAE là 2.57 đều thấp hơn rõ rệt so với hai mô hình kết hợp CNN - AVOA và CNN - WAOA. Biểu đồ so sánh dự báo với dữ liệu thực tế cũng cho thấy khả năng bám sát xu hướng tốt của mô hình đề xuất.

Với những kết quả đạt được, nghiên cứu này không chỉ cung cấp một giải pháp hiệu quả trong bài toán dự báo năng lượng tại các nhà máy công nghiệp mà còn khẳng định tiềm năng của việc kết hợp mô hình học sâu với các thuật toán tối ưu hóa trong việc xử lý các bài toán dữ liệu phức tạp, có tính phi tuyến và biến động cao. Khả năng dự báo chính xác mức tiêu thụ năng lượng trong ngắn hạn giúp doanh nghiệp chủ động hơn trong việc lập kế hoạch vận hành, điều phối thiết bị, tối ưu lịch trình sản xuất và tiết kiệm chi phí năng lượng, từ đó nâng cao hiệu quả vận hành tổng thể trong bối cảnh công nghiệp 4.0.

5.2. Kiến nghị

Nên tiếp tục đánh giá khả năng áp dụng mô hình CNN kết hợp thuật toán tối ưu sinh học (như COA, AVOA, WAOA) trong các ngành công nghiệp khác ngoài thép, chẳng hạn như dệt may, xi măng hoặc hóa chất, nơi mức tiêu thụ năng lượng cũng rất lớn và có tính biến động cao. Việc này sẽ kiểm chứng tính khái quát và khả năng mở rộng của phương pháp.

Các thuật toán tối ưu hiện tại tập trung vào độ chính xác dự báo, tuy nhiên có thể mở rộng sang tối ưu đa mục tiêu, chẳng hạn vừa giảm sai số dự báo vừa giảm thời gian huấn luyện, độ phức tạp mô hình hoặc tiêu thụ tài nguyên tính toán.

Nghiên cứu có thể mở rộng sang việc tích hợp mô hình dự báo vào các hệ thống kiểm soát tự động năng lượng thông minh trong nhà máy, để từ đó thực hiện phản hồi điều khiển tự động như điều chỉnh tải tiêu thụ, phân phối lại lịch sản xuất hoặc phối hợp với hệ thống lưu trữ điện năng.

TÀI LIỆU THAM KHẢO

- [1] U.S. Energy Information Administration, "EIA projects nearly 50% increase in world energy use by 2050, led by growth in renewables," *Today in Energy*, 7 tháng 10, 2021.
- [2] C. Batra and E. Ingersoll, " In 2022, the industrial sector accounted for 37 per cent of global energy use," *IAEA Bulletin*, 2022.
- [3] L. Xiao, W. Shao, T. Liang và C. Wang, "A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting," *Applied Energy*, tập 167, số C, từ trang 135 đến 153, 2016.
- [4] F. Matsunaga, V. Zytowski, P. Valle và F. Deschamps, "Optimization of energy efficiency in smart manufacturing through the application of cyber-physical systems and Industry 4.0 technologies," *Journal of Energy Resources Technology*, tập 144(10), 102104, tháng 10, 2022.
- [5] Wang, Z.-X., Li, Q. and Pei, L.-L., "A seasonal G.M. (1, 1) model for forecasting the electricity consumption of the primary economic sectors", *Energy*, tập. 154, từ trang 522 đến 534, 2018.
- [6] Q. Yin, C. Han, A. Li, X. Liu và Y. Liu, "A review of research on building energy consumption prediction models based on artificial neural networks," *Sustainability*, tập 16, số 17, bài 7805, 2024.
- [7] A. S. Ahmad, M. Y. Hassan, M. P. Abdullah, H. A. Rahman, F. Hussin, H. Abdullah và R. Saidur, "A review on applications of ANN and SVM for building electrical energy consumption forecasting," *Renewable and Sustainable Energy Reviews*, tập 33, từ trang 102 đến 109, 2014.
- [8] F. Divina, M. Garcia Torres, F. A. Gomez Vela và J. L. Vazquez Noguera, "A comparative study of time series forecasting methods for short term electric energy consumption prediction in smart buildings," *Energies*, tập 12, số 10, bài 1934, 2019.
- [9] A. Groß, A. Lenders, F. Schwenker, D. A. Braun và D. Fischer, "Comparison of short-term electrical load forecasting methods for different building types," *Energy Informatics*, tập 4, phụ bản 3, bài 13, 2021.

- [10] I. Rojek, D. Mikołajewski, A. Mroziński và M. Macko, “Green energy management in manufacturing based on demand prediction by artificial intelligence—A review,” *Electronics*, tập 13, số 16, bài 3338, 2024.
- [11] A. M. N. Ribeiro, P. R. X. do Carmo, I. R. Rodrigues, D. Sadok, T. Lynn và P. T. Endo, “Short-term firm-level energy-consumption forecasting for energy-intensive manufacturing: A comparison of machine learning and deep learning models,” *Algorithms*, tập 13, số 11, bài 274, 2020.
- [12] M. Zahan và R. S. Kenett, “Modeling and forecasting energy consumption in the manufacturing industry in South Asia,” *International Journal of Energy Economics and Policy*, tập 3, số 1, từ trang 87 đến 98, 2013.
- [13] V. J. Mawson và B. R. Hughes, “Deep learning techniques for energy forecasting and condition monitoring in the manufacturing sector,” *Energy and Buildings*, tập 217, bài 109966, 2020.
- [14] R. D. Wang, X. S. Sun, X. Yang và H. Hu, “Cloud computing and extreme learning machine for a distributed energy consumption forecasting in equipment-manufacturing enterprises,” *Cybernetics and Information Technologies*, tập 16, số 6, từ trang 83 đến 97, 2016.
- [15] [1] F. Hu, J. Qin, Y. Li, Y. Liu, and X. Sun, "Deep fusion for energy consumption prediction in additive manufacturing," *Procedia CIRP*, tập. 104, từ trang 1878 đến 1883, 2021.
- [16] VTC News, “Xu hướng nhà máy thông minh thúc đẩy sản xuất bền vững,” *VTC News*, đoạn 1, ngày 3 tháng 3 năm 2024. [Trực tuyến]. Có tại: <https://vtcnews.vn/xu-huong-nha-may-thong-minh-thuc-day-san-xuat-ben-vung-ar835902.html> [Truy cập ngày 14 tháng 5 năm 2025].
- [17] Tạp chí điện tử Kinh Doanh & Phát Triển, “Chuyển đổi nhà máy thông minh – Cơ hội và thách thức với doanh nghiệp Việt,” *Kinh Doanh & Phát Triển*, ngày 18 tháng 4 năm 2024. [Trực tuyến]. Có tại: <https://kinhdoanhvaphattrien.vn/chuyen-doi-nha-may-thong-minh--co-hoi-va-thach-thuc-voi-doanh-nghiep-viet-31809.html> [Truy cập ngày 14 tháng 5 năm 2025].
- [18] *Tạp chí Công Thương*, “Giải pháp chuyển đổi số trong các doanh nghiệp nhỏ và vừa ở Việt Nam,” *Tạp chí Công Thương*, ngày 18 tháng 12 năm 2023. [Trực tuyến]. Có tại: <https://tapchicongthuong.vn/giai-phap-chuyen-doi-so-trong-cac-doanh-nghiep-nho-va-vua-o-viet-nam-133175.htm> [Truy cập ngày 14 tháng 5 năm 2025].
- [19] *McKinsey & Company*, “The growing imperative of energy optimization for telco networks,” *McKinsey & Company*, ngày 23 tháng 2, 2024.

- [20] V. E. Sathishkumar *et al.*, “An energy consumption prediction model for smart factory using data mining algorithms,” *KIPS Transactions on Software and Data Engineering*, tập 9, số 5, từ trang 153 đến 160, 2020.
- [21] M. Abdoos, H. Rashidi, P. Esmaeili, H. Yousefi và M. H. Jahangir, “Forecasting solar energy generation in the Mediterranean region up to 2030–2050 using convolutional neural networks (CNN),” *Cleaner Energy Systems*, tập 10, mã bài báo 100167, 2025.
- [22] Yusuf, L. A., Popoola, K. và Musa, H., “A review on energy consumption and mitigation strategies of machine tools in manufacturing process,” *International Journal of Sustainable Engineering*, tập 14, số 6, trang 1826–1842, 2021.
- [23] K. Jones, “Univariate and Multivariate Time Series Analysis with Python,” *Medium*, [Trực tuyến]. Có tại: https://medium.com/@kylejones_47003/univariate-and-multivariate-time-series-analysis-with-python-b22c6ec8f133. [Truy cập: ngày 17 tháng 5 năm 2025].
- [24] L. T. Can và T. P. Lộc, “Dự báo chuỗi thời gian với một số mô hình học máy và ứng dụng,” *Tạp chí Khoa học Đại học Cần Thơ*, tập 60 (Chuyên đề Khoa học Tự nhiên), từ trang 32 đến 39, 2024
- [25] X. Kong *et al.*, “Deep learning for time series forecasting: a survey,” *International Journal of Machine Learning and Cybernetics*, từ trang 1 đến 34, 2025.
- [26] S. C. Nayak, B. B. Misra và H. S. Behera, “Impact of data normalization on stock index forecasting,” *International Journal of Computer Information Systems and Industrial Management Applications*, tập 6, từ trang 13 đến 19, 2014.
- [27] E. H. Zaky, M. M. Soliman, A. K. Elkholy và N. I. Ghali, “Enhanced predictive modelling for 30-day readmission diabetes patients based on data normalization analysis,” *International Journal of Intelligent Engineering and Systems*, tập 14, từ trang 204 đến 216, 2021.
- [28] G. Aksu, C. O. Güzeller và M. T. Eser, “The effect of the normalization method used in different sample sizes on the success of artificial neural network model,” *International Journal of Assessment Tools in Education*, tập 6, số 2, từ trang 170 đến 192, 2019.
- [29] T. H. T. Nguyen, N. Van Pham và X. B. Do, “A Comparative Study of Machine Learning-based Models for Short-Term Multi-step Forecasting of Solar Power: An Application for Nhi Ha Solar Farm,” *Journal of Measurement, Control, and Automation*, tập 5, số 1, từ trang 14 đến 21, 2024.

- [30] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang và Y. Miao, "Review of image classification algorithms based on convolutional neural networks," *Remote Sens.*, tập 13, số 22, từ trang 4712 ... đến ..., 2021. [Trực tuyến]. Có tại: <https://doi.org/10.3390/rs13224712>
- [31] J. Gu *et al.*, "Recent advances in convolutional neural networks," *Pattern Recognit.*, tập 77, từ trang 354 đến 377, 2018. [Trực tuyến]. Có tại: <https://doi.org/10.1016/j.patcog.2017.10.013>.
- [32] S. Salman và X. Liu, "Overfitting mechanism and avoidance in deep neural networks," *arXiv tiền ấn phẩm*, arXiv:1901.06566, 2019. [Trực tuyến]. Có tại: <https://arxiv.org/abs/1901.06566>.
- [33] V. Dumoulin và F. Visin, "A guide to convolution arithmetic for deep learning," *arXiv tiền ấn phẩm*, arXiv:1603.07285, 2016. [Trực tuyến]. Có tại: <https://arxiv.org/abs/1603.07285>.
- [34] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, tập 8, từ trang 1 đến 74, 2021.
- [35] S. Hochreiter và J. Schmidhuber, "Long short-term memory," *Neural Comput.*, tập 9, số 8, từ trang 1735 đến 1780, 1997. MIT Press.
- [36] A. Graves, "Generating sequences with recurrent neural networks," *arXiv tiền ấn phẩm*, arXiv:1308.0850, 2013. [Trực tuyến]. Có tại: <https://arxiv.org/abs/1308.0850>.
- [37] Thu N. T. H., Van P. N., Bao P. Q., Nam N. V. N., Minh P. H., và Quang T. N., "Short-term forecasting of solar radiation using a hybrid model of CNN-LSTM integrated with EEMD," trong *Proceedings of the 2022 6th International Conference on Green Technology and Sustainable Development (GTSD)*, từ trang 854 đến 859, 2022.
- [38] I. Katib và M. Ragab, "Harnessing variable reduction approach with deep recurrent neural network for student's academic performance analysis," *Alexandria Engineering Journal*, tập 118, từ trang 393 đến 405, 2025.
- [39] S. Kardakis, I. Perikos, F. Grivokostopoulou, và I. Hatzilygeroudis, "Examining attention mechanisms in deep learning models for sentiment analysis," *Applied Sciences*, tập 11, số 9, tr. 3883, 2021.
- [40] X. S. Yang, *Engineering optimization: an introduction with metaheuristic applications*. Hoboken, NJ: John Wiley & Sons, 2010.
- [41] P. Trojovský và M. Dehghani, "Walrus optimization algorithm: a new bio-inspired metaheuristic algorithm," 2022.

- [42] M. Dehghani, Z. Montazeri, E. Trojovská và P. Trojovský, “Coati Optimization Algorithm: A new bio-inspired metaheuristic algorithm for solving optimization problems,” *Knowledge-Based Systems*, tập 259, trang 110011, 2023.
- [43] A. G. Hussien, F. S. Gharehchopogh, A. Bouaouda, S. Kumar và G. Hu, “Recent applications and advances of African vultures optimization algorithm,” *Artificial Intelligence Review*, tập 57, số 12, từ trang 1 đến 51, 2024.
- [44] E. Worrell, *Energy efficiency improvement and cost saving opportunities for the US iron and steel industry: an ENERGY STAR® guide for energy and plant managers*. 2011.
- [45] E. Lee, K. Baek và J. Kim, “Datasets on South Korean manufacturing factories’ electricity consumption and demand response participation,” *Scientific Data*, tập 9, bài 227, 2022. [Trực tuyến]. Có tại: <https://doi.org/10.1038/s41597-022-01248-y>.
- [46] Financial Times, “AI energy demand set to surge as technology advances, warns IEA,” *Financial Times*, 14 tháng 7, 2024. [Trực tuyến]. Có tại: <https://www.ft.com/content/735d00a8-678f-4e0c-8dcc-9d82518299ed>.
- [47] *Board Journal*, “From Green Steel to Smart Factories,” *Board Journal*, 27 tháng 1 năm 2025. [Trực tuyến]. Có tại: <https://www.boardjournal.net/2025/01/27/from-green-steel-to-smart-factories>.
- [48] DCKAP, “ERP and MES Integration: Why it matters,” 2023. [Trực tuyến]. Có tại: <https://www.dckap.com/blog/erp-and-mes-integration/>.
- [49] EOXS, “How to achieve energy efficiency in steel manufacturing,” EOXS Digital Solutions, [không rõ năm]. [Trực tuyến]. Có tại: https://eoxs.com/new_blog/how-to-achieve-energy-efficiency-in-steel-manufacturing/.
- [50] Z. Almudayni, B. Soh, H. Samra và A. Li, “Energy inefficiency in IoT networks: Causes, impact, and a strategic framework for sustainable optimisation,” *Electronics*, tập 14, bài 159, 2025.
- [51] J. Chung và B. Jang, “Accurate prediction of electricity consumption using a hybrid CNN-LSTM model based on multivariable data,” *PLOS ONE*, 23 tháng 11 năm 2022.
- [52] G. Zhang, B. E. Patuwo và M. Y. Hu, “Forecasting with artificial neural networks: The state of the art,” *International Journal of Forecasting*, tập 14, số 1, từ trang 35 đến 62, 1998.