



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE CIÊNCIAS E TECNOLOGIA
UNIDADE ACADÊMICA DE ENGENHARIA QUÍMICA
GRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

TESE DE DOUTORADO

**CONTROLE PREDITIVO NEURAL APLICADO A PROCESSOS
DE SECAGEM E CURA DE PINTURA AUTOMOTIVA**

ESLEY SILVA CAVALCANTE

**Campina Grande - PB
Julho de 2023**

ESLEY SILVA CAVALCANTE

**CONTROLE PREDITIVO NEURAL APLICADO A PROCESSOS
DE SECAGEM E CURA DE PINTURA AUTOMOTIVA**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Campina Grande, como parte dos requisitos necessários para obtenção do título de Doutor em Engenharia Química.

Orientador: Prof. Dr. Luis Gonzaga Sales Vasconcelos

Campina Grande - PB

Julho de 2023

C376c Cavalcante, Esley Silva.
Controle preditivo neural aplicado a processos de secagem e cura de pintura automotiva / Esley Silva Cavalcante. - Campina Grande, 2023.
144 f. : il. color.

Tese (Doutorado em Engenharia Química) - Universidade Federal de Campina Grande, Centro de Ciências e Tecnologia, 2023.
"Orientação: Prof. Dr. Luis Gonzaga Sales Vasconcelos."
Referências.

1. Engenharia Química - Processos. 2. Indústria Automotiva. 3. Processo de Pintura. 4. Estufas de Secagem e Cura. 5. Redes Neurais Artificiais. 6. Controle Preditivo Neural. 7. Eletrodeposição. I. Vasconcelos, Luiz Gonzaga. II. Título.

CDU 66.0(043)

**CONTROLE PREDITIVO NEURAL APLICADO A PROCESSOS
DE SECAGEM E CURA DE PINTURA AUTOMOTIVA**


ESLEY SILVA CAVALCANTE

Tese apresentada em 27/06/2023


Banca Examinadora:



Prof. Dr. Luis Gonzaga Sales Vasconcelos (Orientador)

Documento assinado digitalmente
 ROMILDO PEREIRA BRITO
Data: 19/07/2023 10:38:38-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Romildo Pereira Brito (Examinador Interno)

Documento assinado digitalmente
 WAGNER BRANDAO RAMOS
Data: 19/07/2023 10:43:08-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Wagner Brandão Ramos (Examinador Interno)

Documento assinado digitalmente
 THIAGO GONCALVES DAS NEVES
Data: 19/07/2023 11:21:31-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Thiago Gonçalves das Neves (Examinador Externo)



Prof. Dr. Arioston Araújo de Moraes Júnior (Examinador Externo)



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
UNIDADE ACADEMICA DE ENGENHARIA QUIMICA
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900
Telefone: (83) 2101-1100
Site: <http://cct.ufcg.edu.br>

REGISTRO DE PRESENÇA E ASSINATURAS

ATA DA DEFESA PARA CONCESSÃO DO **GRAU DE DOUTOR** EM ENGENHARIA QUÍMICA, REALIZADA EM 27 DE JUNHO DE 2023 (Nº 137)

CANDIDATO(A): **Esley Silva Cavalcante**. COMISSÃO EXAMINADORA: Romildo Pereira Brito, Prof., Dr., UFCG/ **Presidente da Sessão** e Examinador Interno, . Luis Gonzaga Sales Vasconcelos, Prof., Dr., UFCG/ **Orientador**, Wagner Brandão Ramos, Prof., Dr., UFCG/ Examinador Interno, Thiago Gonçalves das Neves, Prof., Dr., IFRN / Examinador Externo, Arioston Araújo de Moraes Júnior Prof., Dr., UFPB / Examinador Externo. TITULO DA TESE: "Controle Preditivo Neural Aplicado a Processos de Secagem e Cura de Pintura Automotiva". ÁREA CONCENTRAÇÃO: Desenvolvimento de Processos Químicos - HORA DE INÍCIO: **14:00 horas** – LOCAL: por videoconferência. Em sessão pública, após exposição de cerca de 50 minutos, o(a) candidato(a) foi arguido(a) oralmente pelos membros da Comissão Examinadora, tendo demonstrado suficiência de conhecimento e capacidade de sistematização, no tema de sua tese, sendo **APROVADO**. Face à aprovação, declara o(a) Presidente da Comissão, achar-se a examinada, legalmente habilitado a receber o **Grau de Doutor**, no domínio da Engenharia Química, cabendo a Universidade Federal de Campina Grande, como direito, providenciar a expedição do Diploma, o que o mesmo faz jus. Na forma regulamentar, foi lavrada a presente ata, que é assinada por mim, Maricé Pereira de Araújo - Secretária - do PPGEQ e os membros da Comissão Examinadora e o(a) candidato(a). Campina Grande, 27 de junho de 2023.

Maricé Pereira de Araújo
Secretária

Romildo Pereira Brito, Prof., Dr., UFCG
Presidente da Comissão e Examinador Interno

Luis Gonzaga Sales Vasconcelos, Prof., Dr., UFCG
Orientador

Wagner Brandão Ramos, Prof., Dr., UFCG
Examinador Interno

Thiago Gonçalves das Neves, Prof., Dr., IFRN
Examinador Externo

Arioston Araújo de Moraes Júnior Prof., Dr., UFPB
Examinador Externo

Esley Silva Cavalcante
Candidato



Documento assinado eletronicamente por **ROMILDO PEREIRA BRITO, PROFESSOR 3 GRAU**, em 27/06/2023, às 16:52, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **LUIS GONZAGA SALES VASCONCELOS, PROFESSOR 3 GRAU**, em 27/06/2023, às 16:56, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **WAGNER BRANDAO RAMOS, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 27/06/2023, às 16:57, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Thiago Gonçalves das Neves, Usuário Externo**, em 27/06/2023, às 17:09, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **MARICE PEREIRA DA SILVA, SECRETÁRIA**, em 28/06/2023, às 08:47, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **ESLEY SILVA CAVALCANTE, Usuário Externo**, em 29/06/2023, às 13:44, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **3492814** e o código CRC **BAEF3F6F**.

Dedico essa dissertação primeiramente à Deus, e a minha família, em especial a meus pais, Ediene Félix da Silva Cavalcante e Edvaldo Gonçalves Cavalcante.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelas inúmeras bênçãos concedidas, por estar sempre ao meu lado, sendo o meu guia, me dando força, apoio e proteção durante todos os momentos de minha vida.

A minha mãe Ediene Felix da Silva Cavalcante e a meu pai Edvaldo Gonçalves Cavalcante, por todo amor e carinho, por lutarem para sempre me proporcionar o melhor, por me apoiarem e me aconselharem, por sempre acreditarem nos meus sonhos.

A minha irmã Evellyn Silva Cavalcante e a meu irmão Johnathan Silva Cavalcante, por todo amor, companheirismo e cumplicidade. A todos meus familiares, por me apoiarem e proporcionarem momentos felizes quando reunidos.

A minha namorada Maria Leticia Aragão e Silva, por todo amor e companheirismo.

Aos meus amigos e colegas da Legasys, por me acrescentarem pessoalmente e intelectualmente, por sempre me apoiarem e proporcionarem momentos de crescimento intelectual, alegrias e descontrações.

Aos professores Dr. Luis Gonzaga Sales Vasconcelos e Dr. Romildo Pereira Brito, por acreditarem no meu potencial, pela atenção, apoio e ajuda, e pelos conhecimentos e ensinamentos transmitidos.

Aos professores Dra. Karoline Dantas Brito e Dr. Wagner Brandão Ramos, pelo apoio e ajuda na elaboração e publicação dos artigos científicos provenientes deste trabalho.

Aos professores da Unidade Acadêmica de Engenharia Química e do Programa de Pós-Graduação em Engenharia Química, pelos conhecimentos transmitidos ao longo da graduação e da pós-graduação.

A todos que contribuíram diretamente ou indiretamente para a elaboração deste trabalho.

“Nós somos o que fazemos repetidamente. Excelência, então, não é um ato, é um hábito!”

Aristóteles

CAVALCANTE, ESLEY SILVA. **Controle Preditivo Neural Aplicado a Processos de Secagem e Cura de Pintura Automotiva**. 2023. 144 p. Tese (Doutorado em Engenharia Química) - Universidade Federal de Campina Grande, Paraíba, 2023.

RESUMO

No processo de pintura automotiva, manter condições operacionais ideais nas estufas de secagem e cura é crucial para garantir pinturas de alta qualidade, especialmente no que diz respeito aos perfis de temperatura de partes específicas da carroceria. Esse trabalho apresenta uma metodologia para desenvolver e implementar um sistema de Controle Preditivo Neural (NNPC) para os processos de secagem e cura de pintura em uma estufa automotiva utilizada na etapa de eletrodeposição (estufa *Elpo*), com o objetivo de proporcionar melhorias no controle de temperatura das partes da carroceria. Para treinar as Redes Neurais Artificiais (RNA) nas várias zonas da estufa *Elpo*, um conjunto de dados foi gerado usando um modelo fenomenológico baseado nos primeiros princípios. Para tanto, distúrbios aleatórios foram aplicados às variáveis de entrada do modelo (velocidade do transportador e temperaturas das zonas), a fim de obter a resposta dinâmica das variáveis de saída do processo (temperaturas em partes específicas da carroceria). Os conjuntos de dados foram então divididos em conjuntos de treinamento (80%), validação (10%) e teste (10%), e o treinamento das RNAs foi realizado utilizando o algoritmo backpropagation. O NNPC implementado utiliza o conjunto de RNA treinadas para a predição dos valores futuros das temperaturas em posições específicas da carroceria (variáveis controladas). Para determinar os sinais ótimos de controle (variáveis manipuladas) um otimizador baseado no modelo de Controle Preditivo Generalizado (GPC) foi utilizado, e a função objetivo foi minimizada através do Algoritmo de Otimização de Colônia de Formigas (ACO). Através de simulações de quatro cenários operacionais com distúrbios aplicados nas variáveis de entrada, os resultados demonstram o desempenho satisfatório do NNPC, mantendo as temperaturas das partes da carroceria efetivamente próximas aos *setpoints* predefinidos. Com isso, conclui-se que a utilização do NNPC oferece um melhor controle de temperatura para as partes da carroceria, mitigando problemas de pintura, reduzindo retrabalhos e custos operacionais.

Palavras-chave: Indústria Automotiva; Processo de Pintura; Estufas de Secagem e Cura; Redes Neurais Artificiais; Controle Preditivo Neural.

CAVALCANTE, ESLEY SILVA. **Neural Network Predictive Control Applied to Automotive Paint Drying and Curing Processes**. 2023. 144 p. Thesis (PhD in Chemical Engineering) - Federal University of Campina Grande, Paraíba, 2023.

ABSTRACT

In the automotive painting process, maintaining optimal operating conditions in drying and curing ovens is crucial to ensure high-quality paint finishes, particularly for specific car body-in-white (BIW) parts' temperature profiles. This study presents a methodology for developing and implementing a Neural Network Predictive Control (NNPC) system for painting drying and curing processes in an automotive oven used in the electrodeposition stage (*Elpo* oven), aiming to improve temperature control for BIW parts. To train the Artificial Neural Networks (ANN) in the various zones of the Elpo oven, a dataset was generated using a phenomenological model based on first principles. Random disturbances were applied to the input variables (conveyor speed and zone temperatures) to capture the dynamic response of the output variables (temperature in specific BIW parts). The dataset was then split into training (80%), validation (10%), and test (10%) sets, and the ANN were trained using the backpropagation algorithm. The implemented NNPC utilizes the trained ANNs to predict future temperature values in specific BIW parts (controlled variables). To determine the optimal control signals (manipulated variables), an optimizer based on the Generalized Predictive Control (GPC) model was employed, and the objective function was minimized using the Ant Colony Optimization Algorithm (ACO). Through simulations of four operational scenarios with applied disturbances to the input variables, the results demonstrate satisfactory performance of the NNPC, effectively maintaining the temperatures of BIW parts close to predefined setpoints. Thus, it is concluded that the use of NNPC offers improved temperature control for BIW parts, mitigating painting issues, reducing rework and operating costs.

Keywords: Automotive Industry; Painting Process; Drying and Curing Ovens; Artificial Neural Networks; Neural Predictive Control.

LISTA DE FIGURAS

Figura 1: Fluxograma simplificado do processo de pintura automotiva.	25
Figura 2: Camadas de revestimentos aplicados em uma carroceria automotiva.	27
Figura 3: Fenômenos de transporte e reação que ocorrem durante o processo de secagem e cura.....	27
Figura 4: Esquema de um neurônio artificial.	31
Figura 5: Estrutura da rede do tipo <i>feedforward</i> de uma única camada.	32
Figura 6: Estrutura da rede do tipo <i>feedforward</i> de múltiplas camadas.	33
Figura 7: Estrutura da rede do tipo <i>feedback</i>	33
Figura 8: Estrutura básica do controle preditivo baseado em modelo (MPC).....	35
Figura 9: Estrutura básica do controle preditivo neural (NNPC).	35
Figura 10: Representação do algoritmo <i>Backpropagation</i>	36
Figura 11: Simplex Nelder-Mead, passos de (a) reflexão, (b) expansão, (c) encolhimento, (d) contração externa e (e) contração externa.....	41
Figura 12: Representação gráfica do processo de otimização pelo método ACO na forma de uma rede multicamadas.	44
Figura 13: Partes da carroceria do veículo monitoradas.....	47
Figura 14: Representação da estufa <i>Elpo</i> em estudo.	47
Figura 15: Representação da configuração das redes neurais artificiais.	51
Figura 16: Representação da configuração das redes neurais artificiais das zonas 2-13.51	
Figura 17: Representação da configuração geral das redes neurais artificiais das zonas da estufa <i>Elpo</i>	52
Figura 18: Algoritmo para a geração do banco de dados para o treinamento.	54
Figura 19: Interface da toolbox “ <i>Neural Network training</i> ”.	55
Figura 20: Resultados do treinamento da rede neural (“ <i>Regression</i> ”)......	55
Figura 21: Resultados da análise de performance da rede (“ <i>Performance</i> ”)......	56
Figura 22: Estrutura do sistema de controle preditivo neural (NNPC) implementado. .	58
Figura 23: Algoritmo de resolução do sistema de controle preditivo neural (NNPC) implementado.	59
Figura 24: Dados experimentais (pontilhado) e resultados do modelo (contínuo) para a posição 1 da carroceria (1000 iterações).	61
Figura 25: Perfis de temperatura das posições de medições ao longo da estufa <i>Elpo</i>	62

Figura 26: Conversão de cura (reação de polimerização) das oito posições da carroceria na estufa <i>Elpo</i> .	64
Figura 27: Temperaturas das posições transformadas na janela de cura, na estufa <i>Elpo</i> .	65
Figura 28: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Estrada da Estufa e (b) Cortina de Entrada.	68
Figura 29: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 1 e (b) Zona 2.	69
Figura 30: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 3 e (b) Zona 4.	70
Figura 31: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 5 e (b) Zona 6.	71
Figura 32: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 7 e (b) Zona 8.	72
Figura 33: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Cortina de saída e (b) Saída da Estufa (Região 1).	73
Figura 34: Resultados do treinamento das redes neurais com 500 casos simulados: Saída da Estufa - Região 2.	74
Figura 35: Resultados de predição: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.	75
Figura 36: Resultados de predição: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.	76
Figura 37: Análise de performance a partir da quantidade de épocas: (a) Entrada da Estufa, (b) Cortina de Entrada, (c) Zona 1, (d) Zona 2, (e) Zona 3 e (f) Zona 4.	79
Figura 38: Análise de performance a partir da quantidade de épocas: (a) Zona 5, (b) Zona 6, (c) Zona 7, (d) Zona 8, (e) Cortina de Saída e (f) Saída - Região 1.	80
Figura 39: Análise de performance a partir da quantidade de épocas: Saída - Região 2.	81
Figura 40: Desempenho do controlador NNPC no Cenário 1 - Distúrbio de +5% na velocidade do transportador: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.	89
Figura 41: Desempenho do controlador NNPC no Cenário 1 - Distúrbio de +5% na velocidade do transportador: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.	90

Figura 42: Desempenho do controlador NNPC no Cenário 2 - Distúrbio de -5% na velocidade do transportador: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.....	92
Figura 43: Desempenho do controlador NNPC no Cenário 2 - Distúrbio de -5% na velocidade do transportador: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.....	93
Figura 44: Desempenho do controlador NNPC no Cenário 3 - Distúrbio de +5% nas temperaturas das zonas: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.....	95
Figura 45: Desempenho do controlador NNPC no Cenário 3 - Distúrbio de +5% nas temperaturas das zonas: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.....	96
Figura 46: Desempenho do controlador NNPC no Cenário 4 - Distúrbio de -5% nas temperaturas das zonas: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.....	98
Figura 47: Desempenho do controlador NNPC no Cenário 4 - Distúrbio de -5% nas temperaturas das zonas: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.....	99

LISTA DE TABELAS

Tabela 1: Especificações dimensionais e operacionais da estufa <i>Elpo</i>	47
Tabela 2: Detalhamento da otimização de ajuste do modelo fenomenológico.	49
Tabela 3: Topologia das redes neurais das zonas da estufa <i>Elpo</i>	52
Tabela 4: Coeficientes de transferência de calor por convecção determinados pela otimização.....	63
Tabela 5: Coeficientes R^2 para o treinamento, validação, teste e global das RNAs.	67
Tabela 6: Resultados para os testes com diferentes quantidades de épocas para as RNAs.	75
Tabela 7: Erro médio absoluto percentual (MAPE) dos valores calculados pelas RNAs para cada uma das partes de medições, em cada zona.....	78
Tabela 8: Condições operacionais da estufa <i>Elpo</i> : Caso base x Cenário 1 com controlador NNPC utilizando 3 métodos de otimização (Função objetivo da Equação 28).....	86
Tabela 9: Condições operacionais da estufa <i>Elpo</i> : Caso base x Cenário 1 com controlador NNPC utilizando 3 métodos de otimização (Função objetivo da Equação 29).....	87
Tabela 10: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 1 com controlador NNPC utilizando 3 métodos de otimização (Função objetivo da Equação 28).	88
Tabela 11: Condições operacionais da estufa <i>Elpo</i> : Caso base x Cenário 1 com controlador NNPC - Distúrbio de +5% na velocidade do transportador.....	91
Tabela 12: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 1 com controlador NNPC - Distúrbio de +5% na velocidade do transportador.	91
Tabela 13: Condições operacionais da estufa <i>Elpo</i> : Caso base x Cenário 2 com controlador NNPC - Distúrbio de -5% na velocidade do transportador.....	94
Tabela 14: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 2 com controlador NNPC - Distúrbio de -5% na velocidade do transportador.	94
Tabela 15: Condições operacionais da estufa <i>Elpo</i> : Caso base x Cenário 3 com controlador NNPC - Distúrbio de +5% nas temperaturas das zonas.....	97
Tabela 16: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 3 com controlador NNPC - Distúrbio de +5% nas temperaturas das zonas.	97
Tabela 17: Condições operacionais da estufa <i>Elpo</i> : Caso base x Cenário 4 com controlador NNPC - Distúrbio de -5% nas temperaturas das zonas.....	100

Tabela 18: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 4 com controlador NNPC - Distúrbio de -5% nas temperaturas das zonas. ...	100
Tabela 19: Integral do Erro absoluto (IAE) para os cenários avaliados com as estratégias de controle NNPC.....	101

NOMENCLATURA E SIMBOLOGIA

Símbolo	Significado	Unidade
k	Quantidade de partes da carroceria	-
m	Quantidade de zonas da estufa	-
n	Quantidade de pontos experimentais medidos ao longo da estufa	-
A	Área superficial do substrato coberto pelo filme	m^2
C	Concentração do solvente	$\frac{Kg \text{ solvente}}{Kg \text{ sólidos}}$
C_0	Concentração inicial do solvente	$\frac{Kg \text{ solvente}}{Kg \text{ sólidos}}$
C_{pm}	Capacidade térmica do substrato metálico	$\frac{J}{Kg \cdot K}$
D_n	Coefficiente de difusividade do solvente	$\frac{m^2}{s}$
E_d	Energia de ativação da difusão	$\frac{J}{mol}$
E_c	Energia de ativação da reação de polimerização (cura)	$\frac{J}{mol}$
h_v	Coefficiente de transferência de calor por convecção	$\frac{W}{m^2 \cdot K}$
P_{ls}	Pressão parcial de vapor do solvente na interface filme-ar	Pa
P_{lb}	Pressão parcial de vapor do solvente no meio circulante (ambiente da estufa)	Pa
R	Constante dos gases ideais	$8,314 \frac{Pa \cdot m^3}{mol \cdot K}$
t	Tempo	s
T_a	Temperatura do ar (ambiente da estufa)	K
$T(t)$	Temperatura da carroceria	K
T_w	Temperatura das paredes da estufa	K
T_o	Temperaturas das partes carroceria medidas	K
T_m	Temperaturas das partes carroceria calculadas pelos modelos (fenomenológico e RNA)	K
V_s	Volume dos materiais poliméricos presente no solvente	m^3
Z_m	Espessura do substrato metálico	m
Z_s	Espessura dos sólidos no revestimento	m
α	Conversão da reação de polimerização (cura)	-
γ	Constante	-
σ	Constante de Stefan Boltzmann	$5,67 \cdot 10^{-8} \frac{W}{m^2 \cdot K^4}$

ε	Emissividade	-
ζ	Fator de frequência da reação de polimerização	$\frac{1}{s}$
η	Constante pré-exponencial para a difusividade	$\frac{m^2}{s}$
ρ_l	Densidade do solvente	$\frac{kg}{m^3}$
ρ_m	Densidade do substrato metálico	$\frac{kg}{m^3}$
ρ_s	Densidade dos sólidos do revestimento	$\frac{kg}{m^3}$
y_i	Saída objetivada do neurônio artificial i	-
\hat{y}_i	Saída calculada pela rede neural artificial para o neurônio artificial i	-
$f(\cdot)$	Função de ativação do neurônio artificial i	-
w_{ij}	Pesos sinápticos do neurônio i	-
x_i	Sinais de entrada do neurônio artificial i	-
b_i	Bias	-
u_i	Saída do combinador linear do neurônio artificial i	-
E_p	Somatório dos erros de predição da rede neural artificial	-
E	Erro total de predição da rede neural artificial	-
J	Função objetivo do controle preditivo generalizado (GPC)	-
y_r	Referência do sinal de saída do controlador	-
y_m	Sinal de saída predito pelo modelo neural	-
N_1	Horizonte mínimo de predição	-
N_2	Horizonte máximo de predição	-
u'	Sinal de controle	-
Δu	Variação da ação de controle	-
f_{obj_k}	Função objetivo do método dos mínimos quadrados	-
y_m^{exp}	Dados experimentais do processo	-
y_m^{modelo}	Resultados obtido pelo modelo proposto	-
x_{best}	Vértice de maior valor da função objetivo no método <i>Nelder-Mead</i>	-
x_{worst}	Vértice de pior valor da função objetivo no método <i>Nelder-Mead</i>	-
x_{bad}	Vértice de segundo pior valor da função objetivo no método <i>Nelder-Mead</i>	-
x_r	Ponto de reflexão no método <i>Nelder-Mead</i>	-
x_e	Ponto de expansão no método <i>Nelder-Mead</i>	-
x_c	Ponto de contração exterior no método <i>Nelder-Mead</i>	-
x_{cc}	Ponto de contração interior no método <i>Nelder-Mead</i>	-

$[J_i]$	Matriz hessiana no método Levenberg-Marquardt	-
$[\tilde{J}_i]$	Matriz modificada no método Levenberg-Marquardt	-
μ_i	Constante positiva no método Levenberg-Marquardt	-
$[I]$	Matriz identidade no método Levenberg-Marquardt	-
P_{ij}^l	Função de probabilidade no método ACO	-
τ_{ij}^α	Feromônio total depositado em cada nó no método ACO	-
$\Delta\tau_{ij}^l$	Varição do feromônio depositado em cada nó no método ACO	-
α	Grau de importância do feromônio no método ACO	-
$N_i^{(l)}$	Conjunto de nós vizinhos ainda não visitados no método ACO	-
p	Taxa de evaporação do feromônio no método ACO	-
f_{best}	Melhor valor da função objetivo ao longo do caminho percorrido pelas formigas	-
f_{worst}	Pior valor da função objetivo ao longo do caminho percorrido pelas formigas	-
$Fobj_k$	Função objetivo para o ajuste do modelo fenomenológico de secagem e cura	-
w	coeficiente de ponderação ajustável da função objetivo para o ajuste do modelo fenomenológico de secagem e cura	-
$x_{1,j}$	Velocidade do transportador da carroceria nas zonas (Variáveis manipuladas 1)	-
$x_{2,j}$	Temperaturas das zonas (Variáveis manipuladas 2)	-
$y_{k,j}$	Temperaturas das partes da carroceria medidas (Variáveis controladas)	-
$\widehat{y}_{k,j}$	Temperaturas das partes da carroceria preditos pelos modelos de redes neurais artificiais	-
R	Matriz com valores randômicos das variáveis manipuladas	-
X	Matriz com os valores nominais das variáveis manipuladas	-
a	Varição negativa de distúrbio para geração de valores randômicos, -10%	-
b	Varição positiva do distúrbio para geração de valores randômicos, +10%	-
MAPE	Erro Médio Absoluto Percentual	%
MAE	Erro Médio Absoluto	-
MSE	Erro Médio Quadrático	-
IAE	Integral do Erro Absoluto	-

SUMÁRIO

1	INTRODUÇÃO E CONTEXTUALIZAÇÃO	19
2	OBJETIVOS	24
2.1	OBJETIVO GERAL	24
2.2	OBJETIVOS ESPECÍFICOS	24
3	REVISÃO BIBLIOGRÁFICA	25
3.1	PROCESSO DE PINTURA AUTOMOTIVA	25
3.2	MODELAGEM FENOMENOLÓGICA DO PROCESSO DE SECAGEM E CURA DE PINTURA AUTOMOTIVA	27
3.3	REDES NEURAIS ARTIFICIAIS	30
3.3.1	ARQUITETURA DA REDE NEURAL	32
3.3.2	APRENDIZADO (TREINAMENTO).....	34
3.4	CONTROLE PREDITIVO	34
3.5	CONTROLE PREDITIVO NEURAL (NNPC)	35
3.5.1	IDENTIFICAÇÃO DO MODELO NEURAL.....	36
3.5.2	FUNÇÃO OBJETIVO DO CONTROLE PREDITIVO	38
3.6	MÉTODOS DE OTIMIZAÇÃO	39
3.6.1	MÉTODO DOS MÍNIMOS QUADRADOS.....	39
3.6.2	MÉTODO SIMPLEX NELDER-MEAD.....	40
3.6.3	MÉTODO DE LEVENBERG-MARQUARDT.....	42
3.6.4	MÉTODO DE OTIMIZAÇÃO DE COLÔNIA DE FORMIGAS (ACO)	43
4	MATERIAIS E MÉTODOS	46
4.1	IMPLEMENTAÇÃO E AJUSTE DO MODELO FENOMENOLÓGICO	46
4.2	TREINAMENTO E IDENTIFICAÇÃO DO MODELO NEURAL	50
4.3	IMPLEMENTAÇÃO DO SISTEMA DE CONTROLE PREDITIVO NEURAL (NNPC).....	56
5	RESULTADOS E DISCUSSÕES	60
5.1	VALIDAÇÃO DO MODELO FENOMENOLÓGICO E SIMULAÇÃO DO CASO BASE.....	60
5.2	IDENTIFICAÇÃO E VALIDAÇÃO DO MODELO NEURAL	66

5.3	ANÁLISE DO DESEMPENHO DO SISTEMA DE CONTROLE PREDITIVO NEURAL (NNPC).....	81
5.3.1	AVALIAÇÃO DOS MÉTODOS DE OTIMIZAÇÃO DO CONTROLADOR NNPC.....	82
5.3.2	ESTRATÉGIA DE CONTROLE 1 (NNPC-1).....	89
5.3.2.1.	CENÁRIO 1 - DISTÚRBO DE +5% NA VELOCIDADE DO TRANSPORTADOR.....	89
5.3.2.2.	CENÁRIO 2 - DISTÚRBO DE -5% NA VELOCIDADE DO TRANSPORTADOR.....	91
5.3.3	ESTRATÉGIA DE CONTROLE 2 (NNPC-2).....	94
5.3.3.1.	CENÁRIO 3 - DISTÚRBIOS DE + 5% NAS TEMPERATURAS NAS ZONAS	94
5.3.3.2.	CENÁRIO 4 - DISTÚRBIOS DE -5% NAS TEMPERATURAS DAS ZONAS	98
6	CONCLUSÕES.....	102
7	SUGESTÕES PARA TRABALHOS FUTUROS	105
8	REFERÊNCIAS	106
	APÊNDICES	109
	APÊNDICE 1: ARTIGO 1 (PUBLICADO EM REVISTA A1)	109
	APÊNDICE 2: ARTIGO 2 (PUBLICADO EM REVISTA A4)	117
	APÊNDICE 3: ARTIGO 3 (PUBLICADO EM REVISTA A1)	133

1 INTRODUÇÃO E CONTEXTUALIZAÇÃO

Melhorar a eficiência dos processos para maximizar resultados é uma tarefa cada vez mais difícil na indústria automobilística, principalmente pela necessidade de sobrevivência das companhias, hoje cada vez mais inseridas no mercado globalizado. Produção, qualidade, custos, meio ambiente, responsabilidade social e segurança são vetores presentes em qualquer processo, e maximizar resultados implica posicionar essas variáveis para obter uma sinergia ideal entre elas.

De acordo com Dickie *et al.* (1997), as operações de montagem automotiva podem ser divididas em três etapas principais: construção de carroceria, operações de pintura e montagem final. As operações de pintura na indústria automotiva normalmente envolvem pré-tratamento, aplicação, secagem e cura de três ou mais revestimentos orgânicos.

Durante o processo de pintura, a carroceria é movida por um transportador a uma velocidade constante, sendo submetido à aplicação, secagem e cura de revestimentos orgânicos. As etapas de aplicação dos revestimentos orgânicos são realizadas em cabines de pintura, enquanto as etapas de secagem e cura são realizadas em estufas, que apresentam dimensionamento específicos e operam a temperaturas específicas.

Em certas indústrias automotivas, a aplicação, secagem e cura são realizadas em uma etapa por eletrodeposição (etapa *Elpo*) e em três etapas por pulverização (etapas *Primer*, *Basecoat* e *Clearcoat*).

Conforme indicado por Ashrafizadeh *et al.* (2012), a qualidade da pintura da carroceria de um automóvel depende da intensidade, duração e mecanismo de transferência de calor nas estufas presentes na unidade de pintura. Os principais mecanismos de transferência de calor envolvidos no processo de cura correspondem a radiação e convecção. A transferência de calor por radiação é devida ao uso de painéis de radiação próximo a entrada das cabines, enquanto a transferência de calor por convecção ocorre através de ventiladores de ar quente ao longo da estufa. As etapas que envolvem o mecanismo convectivo são responsáveis pelo alto consumo de energia.

As falhas na pintura envolvem retrabalho, o que significa um aumento no custo de produção, além de que um recall por falha na pintura pode resultar na entrega de um novo veículo ao cliente. Para manter um cenário que garanta a qualidade da pintura, os engenheiros geralmente manipulam empiricamente e de maneira conservativa a temperatura de cada câmara da estufa, visto que a qualidade da pintura é significativamente afetada pela distribuição uniforme da temperatura no interior da estufa e na velocidade do transportador (diretamente relacionada à produção). Neste sentido, a

relação entre produção, consumo de energia e qualidade é fundamental para garantir que as decisões sejam tomadas com segurança.

Portanto, o estudo e desenvolvimento de um modelo representativo desse processo é vital para compreensão e otimização desse processo, evitando a ocorrência de falha e promovendo a redução do custo com energia. A literatura aberta dispõe de diversos trabalhos que propõem modelos matemáticos e estudos utilizando técnicas de fluidodinâmica computacional, com foco no processo de secagem e cura de pintura automotiva.

Em Lou e Huang (2000), um modelo dinâmico simplificado baseado em primeiros princípios é desenvolvido para caracterizar o processo de secagem do revestimento *clearcoat* em uma estufa. O modelo demonstra sua capacidade de fornecer previsões precisas da formação do filme, permitindo uma análise detalhada das operações de secagem e cura.

Zelder e Steinbeck-Behrens (2009) utilizaram técnicas de fluidodinâmica computacional (CFD) com o módulo VPS/DRY (CADFEM GmbH) para analisar o perfil de temperatura da carroceria durante o processo de secagem em uma estufa. Os resultados obtidos podem ser utilizados para gerar uma curva de temperatura para cada localização na carroceria.

Rao *et al.* (2013) empregaram uma abordagem semi-computacional, combinando um solucionador em CFD e um modelo de rede térmica, para prever as temperaturas das partes da carroceria durante o processo de cura em uma estufa de pintura automotiva. Eles propuseram o conceito de utilizar um revestimento para cobrir os suportes, fornecendo proteção parcial contra o ar quente emitido. Essa abordagem inovadora resultou em uma redução substancial no consumo de energia do forno.

Mehdipour *et al.* (2015) realizaram um estudo comparativo entre estufas de radiação e fornos de convecção utilizando técnicas de CFD e o método de fronteira móvel. Os resultados indicaram que o uso de estufas de radiação resultou em uma economia notável de 50% de energia em comparação com os fornos de convecção.

Despotovic e Babic (2018) apresentam um modelo matemático destinado a simular os fluxos de energia em fornos de pintura automotiva. O modelo permite a análise de várias variáveis e seu impacto nos parâmetros operacionais, como a temperatura do ar e da carroceria. Essas informações podem ajudar os projetistas na seleção de cenários ideais para projetar novas estufas de pintura automotiva ou reconfigurar os existentes, com o objetivo de alcançar a temperatura do ar interna desejada.

Estes modelos são extremamente precisos, embora alguns sejam computacionalmente demorados, demandando a utilização de equipamentos com alto valor agregado. No diz respeito especificamente aos estudos de fluidodinâmica computacionais (CFD), estes são tipicamente aplicados na fase de projeto, em mudanças estruturais ou mudanças operacionais em estado estacionário.

Além disso, ainda existem outros empecilhos para implementação de tais modelos, devido à grande quantidade de parâmetros e complexidade envolvida na determinação dos mesmos, dentre os quais destacam-se os coeficientes de transferência de calor. Em alguns estudos os autores especificam os coeficientes de transferência de calor como função da velocidade do ar na superfície da carroceria e consideram que estes coeficientes são constantes para determinadas zonas da estufa. Entretanto, são considerações frágeis, visto que a velocidade do ar (quente) varia com a posição na carroceria, bem como com a posição da carroceria ao longo da estufa.

Neste contexto, com o grande avanço da tecnologia, são desenvolvidas novas estratégias de identificação de modelos, e a utilização de redes neurais artificiais na identificação e no controle de processos dinâmicos não-lineares obtém resultados satisfatórios, visto que é possível obter um modelo neural que se incorpora bem à dinâmica do processo.

As redes neurais artificiais são sistemas de inteligência artificial baseados em redes neurais biológicas, capazes de coletar, armazenar e utilizar informações de determinados dados. Já o controle preditivo neural é uma estratégia de controle que utiliza um modelo baseado em redes neurais artificiais para prever a resposta futura da planta e executar ações para estabilizar a saída do processo em sua referência.

Através do desenvolvimento de um modelo utilizando um Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS), Radfar *et al.* (2010) realizaram um estudo de controle da qualidade da espessura da tinta durante a etapa de pintura por pulverização *Topcoat* (*Basecoat* e *Clearcoat*), onde concluiu-se que o modelo ANFIS do processo apresentou boa performance quando aplicado à previsibilidade da espessura da camada de tinta.

Jassbi *et al.* (2011) desenvolveram o seu estudo de melhoria do controle proativo da qualidade da espessura da tinta durante a etapa *Topcoat* utilizando técnicas de redes neurais artificiais e de regressão. Os modelos desenvolvidos não apresentaram resultados tão satisfatórios na predição da espessura da última camada de tinta, porém o modelo de RNAs apresentou resultados mais aceitáveis.

Ma e Liu (2019) utilizou modelos de regressão linear múltipla e redes neurais artificiais para prever a demanda de energia de aquecimento em tempo real e o consumo de gás natural nas estufas de cura e secagem de uma linha de pintura automotiva. O modelo baseado em RNAs apresentou confiabilidade de predição maior que 92%, possibilitando prever e controlar de forma precisa e em tempo real a demanda de gás natural das estufas.

Mesmo com as aplicações e estudos supracitados, na literatura consultada não se encontrou trabalhos com a utilização de redes neurais artificiais para a predição e controle preditivo das temperaturas das partes da carroceria automotiva ao longo das estufas de secagem e cura de tintas automotivas, variáveis estas que influenciam diretamente na qualidade da pintura. Além disso, embora seja possível monitorar as temperaturas usando equipamentos de medição online, é fisicamente impossível e economicamente inviável empregar tais equipamentos em todas as carrocerias e em todas as partes.

Neste contexto, a proposta deste trabalho consiste em desenvolver e implementar um sistema de controle preditivo baseado na utilização de redes neurais artificiais (Controle Preditivo Neural - NNPC), para o modelo dinâmico de uma estufa de secagem e cura de pintura automotiva, buscando melhorias no controle de temperatura das partes da carroceria automotiva ao longo da estufa, resultando na minimização dos problemas na pintura. O estudo foi aplicado a estufa utilizada durante a etapa de pintura por eletrodeposição (estufa *Elpo*), a qual é uma das maiores consumidoras de combustíveis da planta industrial considerada.

Uma das principais considerações em nossa metodologia foi a complexidade do problema abordado. O processo em questão apresenta complexidades como não-linearidade e dados de alta dimensão, os quais requeriam uma técnica de modelagem robusta e adaptável. As RNAs têm se mostrado altamente eficazes em capturar e aprender relações e padrões complexos, especialmente em cenários com não-linearidades. Ao utilizar RNAs em nossa metodologia, nosso objetivo era destacar suas capacidades e demonstrar seu potencial para enfrentar problemas complexos, promovendo assim sua adoção em vários domínios.

Toda modelagem e simulações apresentadas neste estudo foram conduzidos em um notebook equipado com um processador Intel Core i7 de 7ª geração, 8 GB de RAM e um disco rígido de 1 TB.

Para o melhor entendimento do desenvolvimento e estruturação desta tese, segue abaixo uma breve descrição dos capítulos que virão a seguir:

- No capítulo 2. **Objetivos**, serão apresentados o objetivo geral e os objetivos específicos deste trabalho.
- O capítulo 3. **Revisão Bibliográfica**, apresenta descrições do processo de pintura automotiva, e de toda a base teórica para a modelagem utilizada nesse trabalho: modelagem fenomenológica do processo de secagem e cura de pintura automotiva, redes neurais artificiais, algoritmos de controle preditivo e métodos de otimização.
- Em 4. **Materiais e Métodos**, toda a metodologia utilizada neste trabalho é apresentada em 3 tópicos principais: Implementação e ajuste do modelo fenomenológico do processo; treinamento e identificação do modelo neural do processo; e por fim, implementação do sistema de controle preditivo neural (NNPC);
- O capítulo 5. **Resultados e Discussões** apresenta os resultados obtidos, divididos em 3 tópicos principais: Validação do modelo fenomenológico e simulação do caso base; identificação e validação do modelo neural do processo; Análise do desempenho do sistema de controle preditivo neural (NNPC);
- O capítulo 6. **Conclusões** apresenta as conclusões e resumo dos resultados obtidos; no capítulo 7 tem-se as 7. **Sugestões Para Trabalhos Futuros**; enquanto no capítulo 8 tem-se as 8. **Referências** utilizadas neste trabalho
- Por fim, o apêndice apresenta os 3 artigos provenientes deste trabalho.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Este trabalho tem como objetivo principal desenvolver e implementar um sistema de controle preditivo neural para o modelo dinâmico de uma estufa de secagem e cura de pintura automotiva, utilizada durante a etapa de pintura por eletrodeposição (estufa *Elpo*).

2.2 OBJETIVOS ESPECÍFICOS

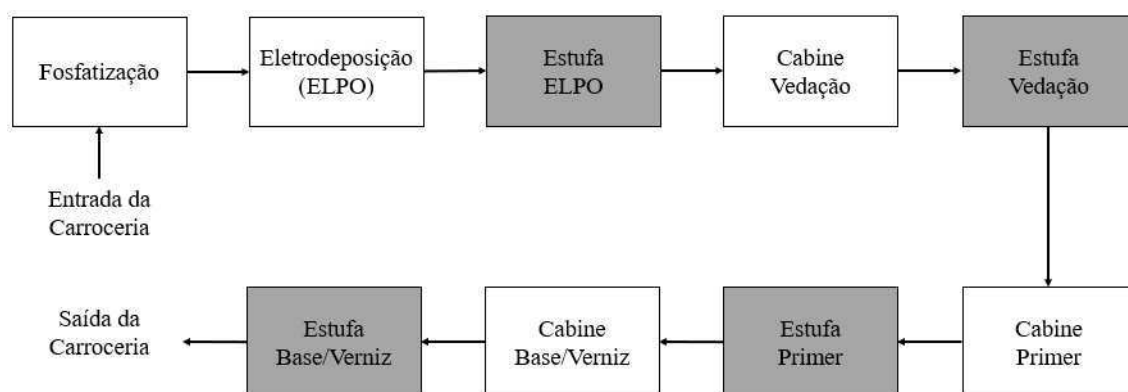
- Implementar no Matlab[®] um modelo fenomenológico transiente capaz de prever as taxas de mudanças no tempo das temperaturas das partes da carroceria automotiva, durante o processo de secagem e cura de pintura em uma estufa utilizada durante a etapa de pintura por eletrodeposição (estufa *Elpo*);
- Estabelecer os objetivos de controle do processo com a definição das variáveis controladas e variáveis manipuladas;
- Realizar o processo de treinamento da rede neural artificial e identificar o modelo do sistema dinâmico;
- Implementar o sistema de controle preditivo neural (NNPC), utilizando o modelo de rede neural artificial do processo;
- Encontrar o método de otimização mais adequado para determinação das ações ótimas do controle preditivo neural (NNPC), através da análise da atuação do controlador utilizando os métodos Simplex, Levenberg-Marquardt e *Ant Colony Optimization - ACO*;
- Verificar o desempenho do sistema de controle preditivo neural (NNPC) no controle dinâmico do modelo, com foco no controle da temperatura das partes da carroceria ao longo da estufa *Elpo* de secagem e cura de pintura.

3 REVISÃO BIBLIOGRÁFICA

3.1 PROCESSO DE PINTURA AUTOMOTIVA

A Figura 1 ilustra a sequência simplificada do processo de pintura na indústria automotiva. A carroceria é movida por um transportador através do processo a uma velocidade constante, sendo submetido à aplicação, secagem e cura de revestimentos orgânicos. Os blocos em branco representam as etapas de aplicação dos revestimentos orgânicos e os blocos em cinza representam as estufas responsáveis pelas etapas de secagem e cura no processo de pintura.

Figura 1: Fluxograma simplificado do processo de pintura automotiva.



O processo de pintura começa com um pré-tratamento da carroceria automotiva, no processo de Fosfatização. Nessa etapa, a carroceria é limpa e imersa em tanques para a realização da cobertura com uma solução de fosfato, com o objetivo de prepara a superfície metálica para o processo de pintura. A fosfatização e a formação da camada de fosfato é a etapa mais sensível e crítica do processo, pois é a etapa que determina a resistência à corrosão de todas as demais coberturas que serão adicionadas posteriormente.

A etapa de pintura por eletrodeposição (*Elpo*) é responsável por fornecer os requisitos anticorrosivos exigidos pela indústria automobilística. A pintura por eletrodeposição consiste em mergulhar a carroceria em um banho de tinta diluída em água, através da qual se faz passar uma corrente elétrica contínua.

A eletrodeposição pode ocorrer de forma anódica ou catódica. A eletrodeposição anódica ocorre quando partículas de tinta carregadas negativamente são depositadas no substrato de uma superfície carregada positivamente, enquanto a eletrodeposição catódica é um processo que deposita as partículas carregadas positivamente em um substrato

carregado negativamente. De forma simplificada, as partículas de tinta migram e se depositam inicialmente para os pontos de maior intensidade de campo elétrico na carroceria. Como a camada de tinta depositada não conduz eletricidade, os pontos com intensidade de campo elétrico menores são posteriormente recobertos com tintas, e dessa forma toda a superfície do substrato é recoberta.

Após a eletrodeposição e formação da camada *Elpo* (*E-coat*), a carroceria necessita ser aquecida para que ocorra a secagem e cura da substância aplicada. Com isso, a carroceria é direcionada para a estufa *Elpo*, sendo aquecida em temperaturas entre 170 °C e 180 °C, durante 20 a 30 minutos.

Na cabine de vedação ocorre a aplicação de selantes por bicos pressurizados em diversos locais da carroceria com o objetivo principal de proporcionar uma melhor vedação, tais como articulações e extremidades de painéis, contornos das chapas metálicas, dentre outros. Além disso, os selantes também são aplicados em áreas que precisam de proteções adicionais, tais como o assoalho externo, com o objetivo de prevenir e diminuir os efeitos causados por colisões contra a carroceria. Após a aplicação dos selantes, a carroceria é submetida ao processo de secagem e cura na estufa de vedação, tipicamente por 20 minutos à 150 °C.

Posteriormente, na cabine *Primer* é aplicada por pulverização a substância de mesmo nome sobre a camada de eletrodeposição, fornecendo uma superfície de metal lisa com aparência reflexiva e mais atraente, a camada primer (*Primercoat*). A pintura realizada na cabine *Primer* também é essencial para a durabilidade da pintura, pois o revestimento cria uma camada de amortecimento contra danos por impacto, proporciona maior resistência à corrosão e lascamentos, além de proporcionar uma melhor adesão para a aplicação da camada seguinte, composta pela tinta base e o verniz.


Após a etapa de aplicação da tinta primer, a carroceria é direcionada para a secagem e cura do revestimento na estufa *Primer* (20 a 30 minutos), a qual opera com temperatura que varia entre 150 °C e 180 °C. É importante salientar que a tinta primer contém sólidos e solventes de rápida e de lenta volatilização, sendo os solventes de rápida volatilização removidos na cabine *Primer*, enquanto os solventes de volatilização lenta são removidos na estufa *Primer*. Por esse motivo, as emissões dos compostos orgânicos voláteis são direcionadas para equipamentos de combate à poluição.

Por fim, na cabine *Base/Verniz* é feita a aplicação da tinta base e do verniz que constituem respectivamente as camadas *Basecoat* e *Clearcoat*, e que juntas formam a camada mais externa e superficial denominada de *Topcoat*. A tinta base é responsável

pela coloração final da carroceria, enquanto o verniz é responsável por proporcionar brilho e proteção à pintura. Além disso, o *Topcoat* tem a função de proteger as camadas anteriores e o substrato de danos, tais como corrosão, abrasão, penetração de umidade e de luz ultravioleta.

Desta forma, a Figura 2 apresenta a ilustração das camadas de revestimentos aplicados a uma carroceria automotiva (chapa metálica) durante o processo de pintura, que formam o substrato.


Figura 2: Camadas de revestimentos aplicados em uma carroceria automotiva.



3.2 MODELAGEM FENOMENOLÓGICA DO PROCESSO DE SECAGEM E CURA DE PINTURA AUTOMOTIVA

O modelo matemático do processo de secagem e cura que ocorrem nas estufas utilizadas no processo de pintura automotiva contempla vários fenômenos. De forma didática, a Figura 3 apresenta os fenômenos de transporte e a reação que ocorrem no filme e no substrato, na última etapa do processo de secagem e cura da pintura (estufa Base/Verniz).

Figura 3: Fenômenos de transporte e reação que ocorrem durante o processo de secagem e cura.



Após passar por todas as etapas de pintura e secagem, a carroceria chega na estufa Base/Verniz com um substrato formado pelas camadas de metal (carroceria), fosfato, *E-coat*, primer (*Primercoat*) e base (*Basecoat*), e com um filme de tinta formado pelo verniz (*Clearcoat*).

Durante o processo, o substrato apresenta os três fenômenos de transferência de calor: Transferência de calor por radiação que ocorre entre a parede da estufa e o substrato, transferência de calor por convecção que ocorre entre o ar e o substrato, e por fim, transferência de calor por condução que ocorre no interior do substrato.

No interior do filme ocorre transferência de calor por condução e transferência de massa por difusão, da interface com o substrato até a interface com o ar. Além disso, no interior do filme ocorre uma reação química de polimerização dos componentes da tinta, seguida do processo de cura, através da formação de uma rede de polímeros. Já na superfície do filme (interface filme/ar) ocorre transferência de calor por radiação e convecção, e transferência de massa do solvente por evaporação, ambos para o meio.

Como as espessuras do filme e do substrato do filme apresentam valores pequenos, o fenômeno de transferência de calor por condução é insignificante quando comparado aos fenômenos de radiação e convecção e, portanto, pode ser negligenciado no modelo. Assim, o modelo de transferência de calor apresentado na Equação (1) caracteriza a contribuição dos mecanismos de transferência de calor, com base nas condições operacionais das zonas das estufas.

$$\frac{dT(t)}{dt} = \begin{cases} \frac{\sigma \varepsilon}{\rho_m C_{pm} Z_m} (T_w^4 - T(t)^4) + \frac{h_v}{\rho_m C_{pm} Z_m} (T_a - T(t)), & \text{zonas de radiação e convecção;} \\ \frac{h_v}{\rho_m C_{pm} Z_m} (T_a - T(t)), & \text{zonas de convecção;} \end{cases} \quad (1)$$

Onde $T(t)$ é a temperatura da carroceria, T_w é a temperatura da parede da estufa, T_a é a temperatura do ar que circula na estufa, ρ_m é a densidade do substrato metálico, C_{pm} é a capacidade calorífica do substrato metálico, Z_m é a espessura do substrato metálico, σ é a constante de Stefan Boltzmann, ε é a emissividade, e h_v é o coeficiente de transferência de calor.

Durante o processo de secagem o solvente desloca-se no sentido da superfície do filme, e na superfície ocorre a transferência de massa do solvente por meio de evaporação na interface entre o ar e o filme. Neste sentido, dois modelos de transferência de massa

devem ser utilizados: o primeiro referente à difusão de massa do solvente dentro do filme, e o segundo referente à transferência de massa que ocorre na interface filme/ar.

O modelo de difusão de massa do solvente dentro do filme é dado pela Equação (2) (Lou e Huang, 2000):

$$\frac{\partial C(z, t)}{\partial t} = \frac{\partial C}{\partial z} \left(D_n(t) \frac{\partial C(z, t)}{\partial z} \right) \quad (2)$$

Onde $C(z, t)$ é concentração mássica do solvente, D_n o coeficiente de difusividade do solvente e z a espessura do filme. O coeficiente de difusividade presente na Equação (2) é calculado pela Equação (3):

$$D_n(t) = \eta \exp \left(-\frac{\gamma}{C} - \frac{E_d}{RT(t)} \right) \quad (3)$$

Onde η é uma constante pré-exponencial para a difusividade, γ uma constante, E_d a energia de ativação para a difusão e R é a constante universal do gás ideal. A resolução da Equação (3) é obtida através da aplicação das condições inicial e condições de contornos. Como condição inicial, tem-se:

$$C(z, 0) = C_0 \quad (4)$$

Como condições de contorno, adota-se a condição expressa pela Equação (5), para $z = 0$; enquanto para a transferência de massa que ocorre na interface filme/ar ($z = Z$) através do processo de evaporação é adotada a condição de contorno representada pela Equação (6) (King, 1980; Cussler, 2009).

$$\frac{\partial C(0, t)}{\partial t} = 0 \quad (5)$$

$$\frac{\partial C(z, t)}{\partial t} = \frac{D_n(t)}{Z_s} \frac{\partial C(z, t)}{\partial z} - \frac{K(P_{ls}(t) - P_{lb})}{\rho_s Z_s} \quad (6)$$

Na Equação (21), Z_s é a espessura da camada sólida do filme, ρ_s é a densidade dos sólidos presentes no filme, K é o coeficiente de transferência de massa, $P_{ls}(t)$ é a pressão

parcial do solvente na interface ar-filme e P_{lb} a pressão parcial do solvente no meio circulante.

A diminuição da espessura da camada do filme ($Z(t)$) com o tempo de secagem resultante da transferência de massa do solvente na interface ar/filme, pode ser representada pela seguinte equação:

$$Z(t) = \frac{\rho_l V_s (1 - C(t)) + \rho_s V_s C(t)}{A \rho_l (1 - C(t))} \quad (7)$$

Onde ρ_l é a densidade do solvente, ρ_s é densidade dos sólidos presentes no filme, A indica a área da superfície do substrato coberto pelo filme e V_s indica os volumes de materiais poliméricos no solvente.

Por fim, o modelo que representa a reação de polimerização e o processo de cura é dado pela Equação (8), onde α é a conversão da cura, ζ o fator de frequência da reação de polimerização, E_c a energia de ativação de cura, e m e n são constantes (ordem da reação).

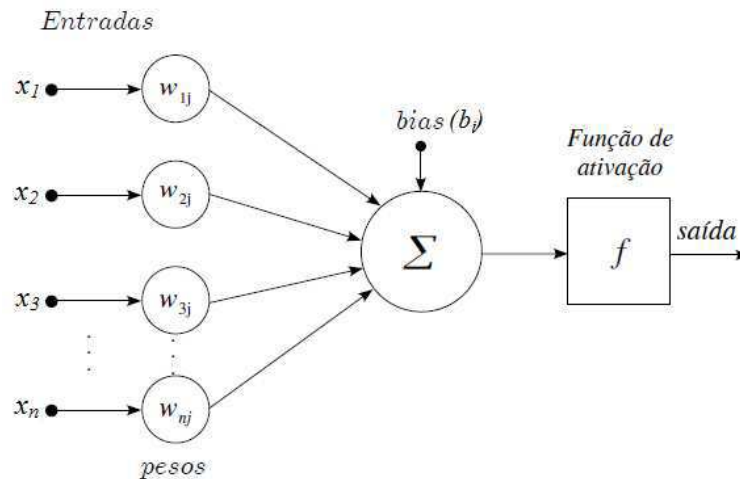
$$\frac{d\alpha(t)}{dt} = \zeta \exp\left(-\frac{E_c}{RT(t)}\right) \alpha(t)^m (1 - \alpha(t))^n \quad (8)$$

Vale salientar que, por ser um processo transiente, o tempo de resolução do modelo é definido através da divisão do comprimento da estufa (m) pela velocidade do transportador da carroceria (m/min), obtendo assim o tempo do processo em minutos.

3.3 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são sistemas de inteligência artificial inspirados nas características de processamento de informação encontradas nos neurônios biológicos, capazes de coletar, armazenar e utilizar informações baseadas em dados a elas fornecidos. As redes neurais são formadas por um conjunto de neurônios artificiais que interagem entre si. O neurônio artificial é o elemento da rede neural onde são realizados os processamentos e cálculos. A Figura 4 apresenta o modelo de um neurônio artificial.

Figura 4: Esquema de um neurônio artificial.



Como pode-se observar na figura acima, o modelo do neurônio artificial considera basicamente um vetor de entrada x , uma matriz de pesos sinápticos, uma função de ativação e um vetor de saída y . A saída do neurônio i é dada de acordo com a seguinte equação:

$$y_i = f \left[\left(\sum_{j=1}^n w_{ij} x_j \right) + b_i \right] \quad (9)$$

Onde,

w_{ij} são os pesos sinápticos do neurônio i ;

x_i são os sinais de entrada;

f é a função de ativação interna associada ao neurônio i ;

b_i é o *bias*.

De acordo com Haykin (2001), todos os sinais de entrada são ajustados através dos pesos sinápticos e posteriormente somados. O *bias*, que pode ser positivo ou negativo, é aplicado externamente ao somador com a finalidade de aumentar ou diminuir a entrada líquida deste somatório na função de ativação. Por fim, após este processamento, os sinais passam por uma função de ativação.

A ativação do neurônio se dá quando um conjunto de entradas é aplicado, onde a resposta é determinada pela função de ativação. As funções de ativação são funções de transferência que determinam o tipo e a magnitude de saída de cada neurônio, podendo ser funções do tipo linear, limiar, sigmóidal, degrau, tangente hiperbólica, dentre outras.


3.3.1 ARQUITETURA DA REDE NEURAL

A arquitetura (topologia) da rede neural diz respeito quanto à sua estruturação e como os neurônios estão conectados, podendo apresentar-se de diversas formas, conforme a necessidade de aplicação.

A estrutura de uma rede neural é constituída basicamente de uma camada de entrada, camadas intermediárias e uma camada de saída. Em geral, são classificados três tipos de arquitetura de redes neurais: Redes *feedforward* de uma única camada, redes *feedforward* de múltiplas camadas e redes recorrentes (*feedback*).

As redes *feedforward* de uma única camada são redes em que os neurônios estão organizados na forma de camadas, e são formadas por apenas uma camada de entrada e uma camada de saída. A Figura 5 apresenta a estrutura da rede *feedforward* de uma única camada.

Figura 5: Estrutura da rede do tipo *feedforward* de uma única camada.



Fonte: Haykin, 2001.

Por sua vez, as redes *feedforward* de múltiplas camadas são redes formadas por uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas (intermediárias). A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede (Matsunaga, 2012).

Neste tipo de redes neurais, os nós da camada de entrada da rede fornecem os elementos do padrão de ativação, que constituem os sinais de entrada aplicados aos neurônios na camada seguinte, ou seja, a primeira camada oculta. Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante, até atingir a camada de saída.

De acordo com Haykin (2001), a vantagem das redes de múltiplas camadas em relação às redes de única camada é observada na capacidade que os neurônios das camadas ocultas têm de extrair informações mais precisas dos dados. A estrutura da rede *feedforward* de múltiplas camadas é apresentada na Figura 6.

Por fim, as redes recorrentes ou *feedback* podem ou não apresentar camadas ocultas, mas necessariamente apresentam pelo menos um laço de realimentação. Estes laços são feitos à medida que as saídas de neurônios de determinadas camadas são reintroduzidas como entradas em neurônios de camadas anteriores ou da mesma camada. Esta presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem da rede. A estrutura da rede *feedback* de múltiplas camadas é apresentada na Figura 7. A arquitetura da rede neural artificial utilizada neste trabalho é a do tipo *feedforward* de múltiplas camadas, com apenas uma camada oculta.

Figura 6: Estrutura da rede do tipo *feedforward* de múltiplas camadas.

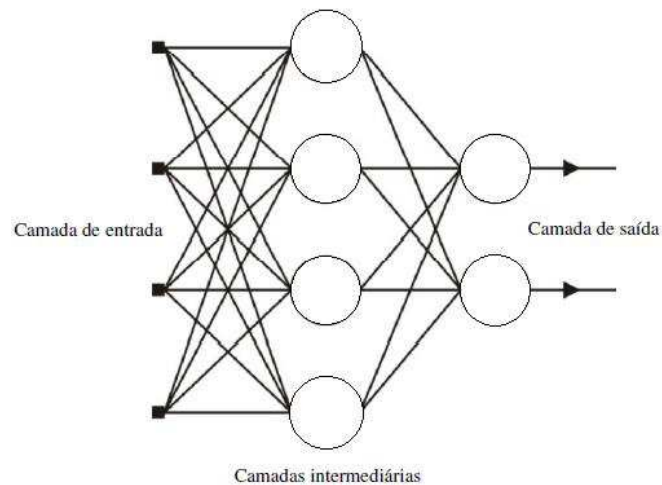



Figura 7: Estrutura da rede do tipo *feedback*.



3.3.2 APRENDIZADO (TREINAMENTO)

O aprendizado, conhecido como treinamento das redes neurais é a etapa onde se codificam as informações referentes ao processo, através da utilização de dados de entrada e saída coletados. O treinamento que tem por objetivo primordial ajustar os pesos sinápticos de modo a efetuar a correção do erro é classificado como treinamento supervisionado e não supervisionado.

No treinamento supervisionado, o supervisor recebe um conjunto de dados e confere o quanto a rede está próxima de uma solução aceitável, e age ajustando os parâmetros do treinamento (pesos sinápticos), de modo a promover um menor erro. Este procedimento é feito de forma iterativa até o erro atingir o valor mínimo desejado.

Por sua vez, no treinamento não supervisionado não há influência do programador no treinamento da rede neural, de modo que os pesos são modificados e adaptados através de padrões pré-estabelecidos.

3.4 CONTROLE PREDITIVO

O controle preditivo baseado em modelo (MPC) não designa uma estratégia de controle específica, mas uma gama ampla de métodos de controle que fazem uso de um modelo do processo unido à minimização de uma função custo para obter um sinal de controle. É uma tecnologia consolidada e tem se tornado uma abordagem padrão para implementar um sistema de controle multivariável com restrições na indústria de processos atuais (Mark *et al.* 2012; Ferramosca *et al.* 2010).

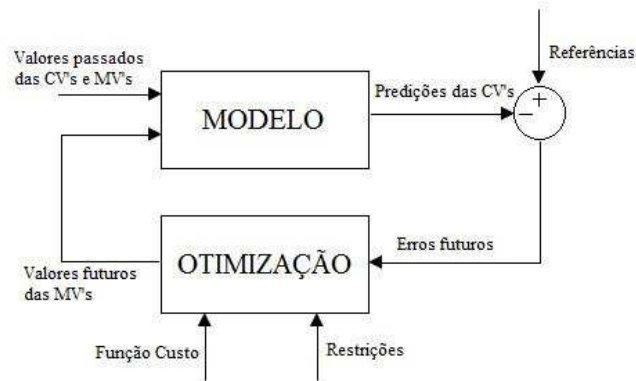
De acordo com Camacho e Bordons (2004), existem diversos métodos representativos de algoritmos MPC, dentre eles pode-se destacar o controle por matriz dinâmica (DMC), controle auto-adaptativo com predição estendida (EPSAC), controle adaptativo com horizonte estendido (EHAC) e o controle preditivo generalizado (GPC).

A estrutura básica de um algoritmo de controle preditivo baseado em modelo deve conter basicamente o modelo da dinâmica do processo e uma função custo a ser minimizada, de modo a ser possível prever os valores futuros das variáveis controladas e efetuar ações sobre as variáveis manipuladas. Neste sentido, observa-se que o MPC é composto por uma junção entre a modelagem, a otimização e o controle de processos.

A cada intervalo de controle, o MPC otimiza o comportamento futuro do processo, levando em consideração as entradas de controle atuais e futuras, calculando e executando uma sequência de ajustes das variáveis de entrada. O primeiro ajuste da sequência ótima

é então enviado ao elemento de atuação da planta e o cálculo é repetido para todos os intervalos seguintes. A Figura 8 apresenta a estrutura básica do MPC.

Figura 8: Estrutura básica do controle preditivo baseado em modelo (MPC).

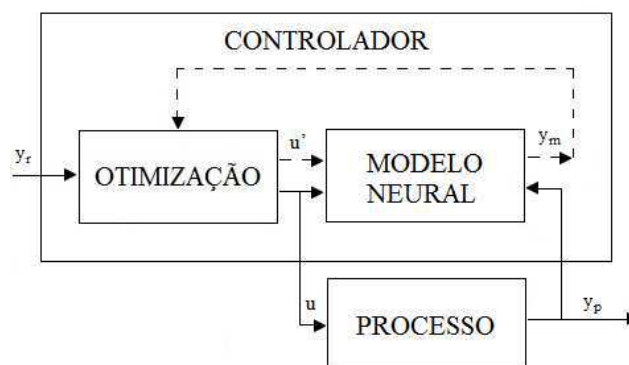


3.5 CONTROLE PREDITIVO NEURAL (NNPC)

O controle preditivo é uma técnica baseada em modelo, e com isto a precisão do modelo do processo identificado desempenha um papel importante no desempenho dos controladores preditivos. Erro de modelagem e distúrbios não medidos pode levar a um sistema de controle com baixo desempenho (Zuhua et al, 2010).

A aplicação de redes neurais artificiais (RNA) na identificação de modelos tem crescido com o objetivo de resolver problemas de modelagem em sistemas não-lineares, por apresentarem a capacidade de prever dados da dinâmica dos processos. Com isso, a estratégia de controle preditivo neural (Neural Network Predictive Control - NNPC) baseia-se na utilização de um modelo neural para realizar a predição de valores futuros do processo e na geração de uma lei de controle obtida pela otimização de uma função custo. A estrutura básica do controle preditivo neural é apresentada na Figura 9.

Figura 9: Estrutura básica do controle preditivo neural (NNPC).



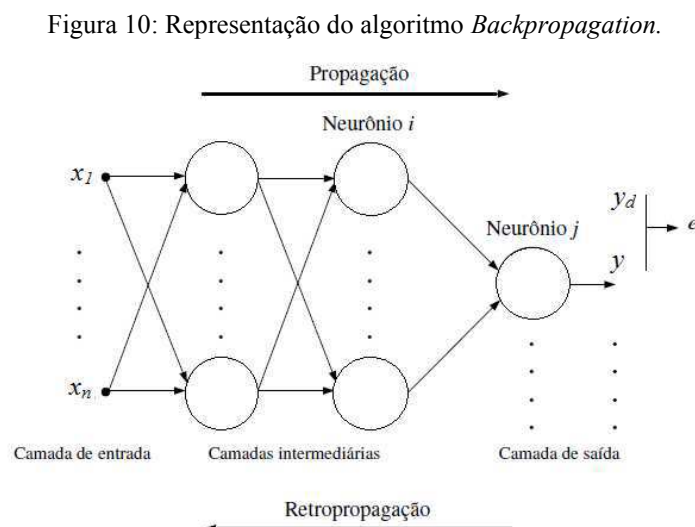
3.5.1 IDENTIFICAÇÃO DO MODELO NEURAL

Para a implementação da estratégia de controle preditivo neural é necessário inicialmente efetuar a identificação do modelo processo. Identificar um processo é encontrar um modelo que represente o sistema que se pretende controlar. A identificação do modelo é obtida através da aplicação do treinamento das redes neurais artificiais.

O algoritmo utilizado para o treinamento das redes neurais é o algoritmo *Backpropagation*, o qual é baseada-se na correção do erro por aprendizagem de uma rede multicamadas. Este algoritmo procura achar a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, através da análise da rede neural camada por camada na sua propagação e na sua retropropagação.

De acordo com Rumelhart e McClelland (1986), este algoritmo consiste em duas etapas, onde inicialmente na primeira etapa um vetor de sinal de entrada é aplicado como estímulo aos elementos da primeira camada da rede, sendo propagado até a saída, gerando uma resposta na última camada.

Posteriormente, na segunda etapa, a resposta gerada é comparada com o valor desejado, criando um erro que é retropropagado através da rede, de modo que cada elemento da camada intermediária receba a sua contribuição neste erro gerado. Utilizando uma regra de correção de erro pré-estabelecida, os pesos sinápticos para cada elemento da camada são ajustados, de modo a fazer com que ao longo do processo de treinamento o erro diminua a cada iteração, convergindo ao máximo o valor gerado para o valor de saída desejado. A Figura 10 apresenta a representação do algoritmo *Backpropagation*.



Considerando um neurônio i , a saída do combinador linear devido à aplicação dos sinais de entrada pode ser descrita matematicamente pela seguinte equação:

$$u_i = \sum_{j=1}^n w_{ij}x_j \quad (10)$$

Onde,

w_{ij} são os pesos sinápticos do neurônio i ;

x_j são os sinais de entrada.

Deste modo, o sinal de saída do neurônio i é dado por:

$$\hat{y}_i = f(u_i + b_i) \quad (11)$$

Sendo,

f é a função de ativação interna associada ao neurônio i ;

b_i é o *bias*.

O somatório dos erros entre o valor desejado e os encontrados pela rede para cada neurônio é dado por:

$$E_p = \frac{1}{2} \sum_{i \in C} (y_i - \hat{y}_i)^2 \quad (12)$$

Deste modo, o erro total (E) é obtido pelo somatório dos erros entre o valor desejado e os encontrados pela rede:

$$E = \sum_{p=1}^{N_p} E_p \quad (13)$$

O objetivo do treinamento é minimizar uma função erro de modo a obter os ajustes dos pesos sinápticos w_{ij} de cada neurônio, sendo necessária a aplicação de um método de otimização. A utilização de métodos que baseados na primeira derivada, como é o caso do método do gradiente descendente, é caracterizada por respostas lentas. Por isto, são

empregados métodos capazes de aumentar a velocidade do treinamento, tais como o método quasi-Newton e o método Levenberg-Marquardt.

3.5.2 FUNÇÃO OBJETIVO DO CONTROLE PREDITIVO

De acordo com Soloway e Haley (1996), a estratégia de controle preditivo baseado em modelo tem como base a minimização de uma função objetivo que utiliza a técnica do horizonte de predição recendente.

Dentre as classes de algoritmos MPC, o método abordado neste trabalho é o controle preditivo generalizado (GPC), cuja função objetivo J é expressa como:

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_U} (\Delta u(t+j))^2 \quad (14)$$

Onde:

N_1 é o horizonte mínimo de predição;

N_2 é o horizonte máximo de predição;

N_U é o horizonte de controle;

y_r é a referência do sinal de saída;

y_m é o sinal de saída predito pelo modelo neural;

t é o instante atual;

Δu é a variação da ação de controle, sendo definida por $u'(t+j) - u'(t+j-1)$;

ρ é a ponderação à ação de controle, utilizado para determinar a contribuição que a soma dos quadrados dos incrementos de controle tem sobre o índice de desempenho.

É possível observar que a função objetivo não leva apenas em consideração a minimização do erro quadrado médio entre o sinal de saída referência e o sinal de saída predito, mas também o quadrado da variação das ações de controle, caracterizada pela atualização no valor da entrada de controle.

Basicamente, o modelo de rede neural prevê a resposta da planta ao longo de um horizonte de tempo especificado, e estas previsões são usados na função objetivo J , de modo que a partir da aplicação de um método de otimização é possível determinar o sinal de controle que minimiza a função objetivo ao longo do horizonte especificado.

3.6 MÉTODOS DE OTIMIZAÇÃO

3.6.1 MÉTODO DOS MÍNIMOS QUADRADOS

O ajuste de curvas e estimativa de seus parâmetros são importantes etapas dos estudos experimentais e estatísticos da engenharia. Segundo Chapra (2012), as abordagens gerais para ajustes de curvas seguem duas linhas, que se distinguem através da quantidade de erro associada aos dados.

Dado um conjunto de dados que são conhecidos e valores discretos precisos, uma primeira abordagem básica é ajustar uma curva ou uma série de curvas que passam diretamente através de cada um dos pontos. Tais dados geralmente se originam de tabelas, como por exemplo valores para os calores específicos de componentes como função da temperatura. Uma técnica conhecida para a resolução por esta abordagem é a interpolação.

Uma segunda abordagem, onde os dados apresentam um grau significativo de "dispersão", a estratégia é obter uma única curva que representa a tendência geral dos dados, ou seja, a curva é projetada para seguir o padrão dos pontos tomados como um grupo. Uma abordagem dessa natureza é chamada de mínimos quadrados.

O método dos mínimos quadrados é uma técnica de otimização matemática que busca determinar numericamente um vetor x que minimize a diferença entre um conjunto de dados e um determinado modelo matemático, a partir da seguinte expressão:

$$f_{obj_k}(x) = \sum_{m=1}^n (f_m(x))^2 \quad (15)$$

Onde a função $f_{obj_k}(x)$ representa o erro total do ajuste a ser feito (resíduos), ou seja:

$$f_{obj_k}(x) = \sum_{m=1}^n (e_m)^2 = \sum_{m=1}^n (y_m^{exp} - y_m^{modelo}(x))^2 \quad (16)$$

Onde:

y_m^{exp} são os dados experimentais;

$y_m^{modelo}(x)$ são os resultados obtidos pelo modelo proposto (ou tipo de curva) como função do parâmetro x .

Para o caso de funções não lineares, o ajuste pelo método dos mínimos quadrados não é obtido de forma simples, sendo necessária a utilização de algoritmos iterativos. A partir de um vetor inicial, x_0 , com a utilização de um algoritmo de otimização, o método produz uma série de vetores x_1, x_2, \dots, x_q , que devem convergir para um vetor x_{opt} que minimize a função objetivo.

Vale salientar que o resultado obtido na maioria dos algoritmos de otimização utilizados depende dos valores das estimativas iniciais (vetor x_0), devido ao fato da função representada pela Equação 16 poder apresentar diversos mínimos locais. Além disto, costuma-se utilizar um número de pontos superior ao número de parâmetros desconhecidos do modelo matemático para reduzir-se a influência dos erros presentes nos valores da variável avaliada.

3.6.2 MÉTODO SIMPLEX NELDER-MEAD

O método Simplex *Nelder-Mead*, proposto em 1965 por John Nelder e Roger Mead, é um método numérico de busca direta amplamente utilizado para encontrar o mínimo ou o máximo de uma função objetivo em um espaço multidimensional, sendo aplicado em problemas de engenharia não-lineares, para os quais as derivadas não podem ser determinadas facilmente.

Este método baseia-se em um conceito simplex, que é a generalização de um triângulo ou tetraedro para um número arbitrário de dimensões, com $k+1$ vértices. Através de um simplex de $k+1$ vértices ordenados a cada iteração pelo valor da função, o método avalia o valor da função objetivo em um número de pontos finitos por iteração e decide qual ação tomar sem usar informações de forma implícita ou explícita da derivada.


As iterações do algoritmo de *Nelder-Mead* se iniciam com um conjunto de pontos, os vértices do simplex, que representam possíveis soluções do valor máximo da função. Em cada iteração do algoritmo tem-se como objetivo mudar a forma e o tamanho do simplex, através da identificação de um candidato para substituir o pior ponto do conjunto.

Sendo o vértice x_{best} o que apresenta o maior valor da função objetiva, x_{worst} o pior vértice, e o segundo pior vértice do simplex como x_{bad} , é possível definir a melhor face como aquela oposta ao vértice x_{worst} , que é o hiperplano que contém os outros pontos e

seu centróide é a média de todos os outros vértices (ponto c). Após isto, é feita a substituição do pior vértice por um melhor, delimitando o movimento do novo vértice sempre em direção de melhores alternativas.

A partir das iterações, são disponíveis cinco formas de deslocamento pelos pontos: reflexão, expansão, contração interna ao simplex, contração externa ao simplex e encolhimento do simplex. A Figura 11 apresenta as cinco possíveis transformações do simplex, de acordo com *Lagarias et al* (1998), onde o simplex original é apresentado pela linha tracejada, x_1 e x_3 são vértices do simplex, \bar{x} representa o centróide do melhor ponto, x_r é o ponto de reflexão, x_e é o ponto de expansão, x_c é o ponto contração exterior, x_{cc} é o ponto de contração interior.

Figura 11: Simplex Nelder-Mead, passos de (a) reflexão, (b) expansão, (c) encolhimento, (d) contração externa e (e) contração interna.



Fonte: *Lagarias et al.* (1998).

3.6.3 MÉTODO DE LEVENBERG-MARQUARDT

O método Levenberg-Marquardt é um algoritmo de otimização desenvolvido para a utilização das segundas derivadas. Este método baseia-se na modificação dos elementos da diagonal principal da matriz hessiana $[J_i]$ da seguinte forma:

$$[\tilde{J}_i] = [J_i] + \mu_i[I] \quad (17)$$

Onde, $[J_i]$ é a matriz hessiana, formada pelas segundas derivadas parciais, onde para a função custo do controlador a matriz hessiana $[J_i] = \frac{\partial^2 J}{\partial U^2}$ é:

$$[J_i] = \begin{bmatrix} \frac{\partial^2 J}{\partial u(t+1)^2} & \frac{\partial^2 J}{\partial u(t+2)\partial u(t+1)} & \cdots & \frac{\partial^2 J}{\partial u(t+NU)\partial u(t+1)} \\ \frac{\partial^2 J}{\partial u(t+1)\partial u(t+2)} & \frac{\partial^2 J}{\partial u(t+2)^2} & \cdots & \frac{\partial^2 J}{\partial u(t+NU)\partial u(t+2)} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 J}{\partial u(t+1)\partial u(t+NU)} & \frac{\partial^2 J}{\partial u(t+2)\partial u(t+NU)} & \cdots & \frac{\partial^2 J}{\partial u(t+NU)^2} \end{bmatrix} \quad (18)$$

Onde,

$[I]$ é a matriz identidade;

μ_i é uma constante positiva que garante que a matriz torne-se positiva definida.

Quando μ_i é suficientemente pequeno, sendo próximo de zero, o método torna-se justamente o método de Newton, apresentando características deste método. Por outro lado, quando μ_i é suficientemente grande, o método torna-se o método do gradiente descendente com passos pequenos.

De acordo com Rao (2009), o método de Levenberg-Marquardt tenta absorver as vantagens destes dois métodos, visto que o método do gradiente descendente reduz o valor da função quando o vetor X_i está longe do ponto ótimo X^* , e o método de Newton converge rapidamente quando o vetor X_i está próximo do ponto ótimo X^* . Neste trabalho, o método de Levenberg-Marquardt é utilizado no treinamento das redes neurais, através da utilização da função “*trainlm*” do Matlab[®], que é uma função de treinamento de redes neurais que atualiza os valores de peso utilizando o método de otimização supracitado.

3.6.4 MÉTODO DE OTIMIZAÇÃO DE COLÔNIA DE FORMIGAS (ACO)

O método de otimização de colônia de formigas, *Ant Colony Optimization - ACO*, faz parte dos algoritmos de inteligência de enxame (*Swarm Intelligence*). Nestes algoritmos os agentes atuam localmente com o ambiente, interagem com o grupo e geram um padrão coerente, resultando na resolução de um determinado problema.

O *ACO* foi introduzido pela primeira vez nos anos 90 por Marco Dorigo (1992). É um algoritmo probabilístico utilizado para resolver diferentes problemas de otimização, e foi desenvolvido com base no comportamento de formigas para buscar um caminho entre sua colônia e a fonte de alimento, sendo utilizado inicialmente para solucionar o conhecido problema do caixeiro viajante (TSP).

As formigas são insetos sociais, que vivem em colônias. Durante a busca por alimentos, as formigas depositam no solo um composto orgânico chamado feromônio. Neste sentido, as formigas se comunicam por meio de trilhas de feromônios, e utilizam esta comunicação indireta para indicar para as outras o quão bom foi o caminho escolhido.

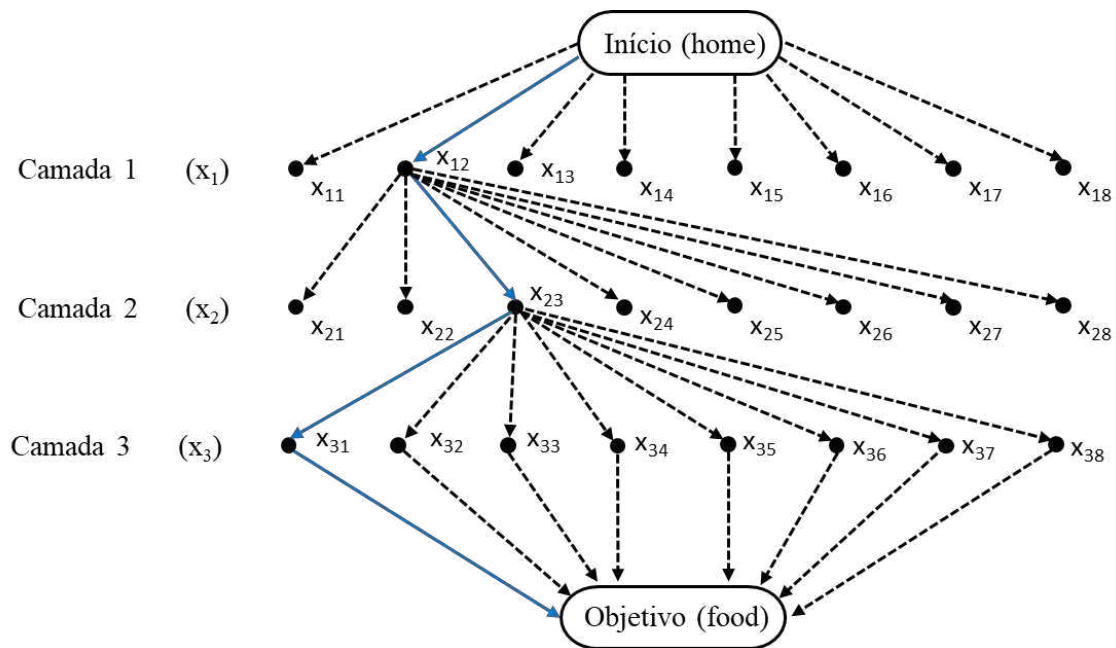
Desta forma, quando uma formiga encontra alguma quantidade de alimento, deposita feromônio nos caminhos com base na quantidade e qualidade do alimento, para que as outras formigas possam seguir esse caminho. Quanto mais alto o nível de feromônio, maior a probabilidade das outras formigas escolherem aquele caminho, e quanto mais formigas seguem o caminho, a quantidade de feromônio também aumentará.

Segundo Rao (2009), o processo de otimização através do método ACO pode ser representado como uma rede de multicamadas, conforme a Figura 12. O número de camadas da rede representa a quantidade de variáveis de decisão, e a quantidade de nós em cada uma das camadas representa o número de valores discretos permitidos para a variável de decisão correspondente.

Considere uma colônia formada por N formigas, disposta inicialmente no nó inicial da Figura 12 (Início - home). As formigas iniciam o trajeto de busca partindo do nó inicial, passando através das camadas, até atingir o nó de destino (Objetivo - food). Cada formiga k pode selecionar apenas um nó ij em cada camada, de acordo com uma regra de transição.

Essa regra de transição constitui a construção de uma solução, que segue uma fórmula probabilística em função do feromônio depositado em cada nó (τ_{ij}^α), para calcular a probabilidade de escolher ou não o próximo nó, conforme a equação 19.

Figura 12: Representação gráfica do processo de otimização pelo método ACO na forma de uma rede multicamadas.



Fonte: Adaptado de Rao 2009.

$$P_{ij}^{(k)} = \begin{cases} \frac{\tau_{ij}^{\alpha}}{\sum_{j \in N_i^{(k)}} \tau_{ij}^{\alpha}}, & \text{se } j \in N_i^{(k)} \\ 0, & \text{se } j \notin N_i^{(k)} \end{cases} \quad (19)$$

Onde τ_{ij}^{α} é a quantidade de feromônio depositado no nó (ij) , α representa o grau de importância do feromônio e $N_i^{(k)}$ indica o conjunto de nós vizinhos ainda não visitados pela formiga k .

Desta forma, o cálculo iterativo da regra de transição constitui a construção de uma solução, de modo que os nós selecionados ao longo do caminho e visitados por cada uma formiga representam uma solução candidata. Por exemplo, na Figura 12 o conjunto formado por x_{12} , x_{23} e x_{31} representa a melhor solução.

Antes de retornarem para o nó anterior, a formiga deposita uma quantidade de feromônio nos nós já visitados, $\Delta\tau^k$, de acordo com a qualidade da solução gerada. Com isso, a quantidade de feromônio depositada no nó (ij) necessita ser atualizada através da seguinte relação:

$$\tau_{ij} \leftarrow \tau_{ij} + \Delta\tau^k \quad (20)$$

Além disso, durante a movimentação das formigas, ocorre também o fenômeno de evaporação do feromônio em todos os nós, onde p representa a taxa de evaporação do feromônio:

$$\tau_{ij} \leftarrow (1 - p)\tau_{ij} \quad (21)$$

Com base nas equações 20 e 21, após a construção de todos os caminhos e o retorno das formigas para o nó inicial, a intensidade de feromônio em cada nó pode ser expressa pela equação 22:

$$\tau_{ij} = (1 - p)\tau_{ij} + \sum_{k=1}^N \Delta\tau_{ij}^k \quad (22)$$

Onde $\Delta\tau_{ij}^k$ representa a quantidade de feromônio depositada no nó ij , e pode ser calculada como:

$$\Delta\tau_{ij}^k = \begin{cases} \frac{\zeta f_{best}}{f_{worst}}, & \text{se } (i, j) \in \text{melhor caminho global} \\ 0, & \text{outra forma} \end{cases} \quad (23)$$

Onde f_{best} e f_{worst} são respectivamente o melhor e o pior valor da função objetivo ao longo do caminho percorrido pelas N formigas, e é um parâmetro utilizado para controlar a escala de atualização global do feromônio.

4 MATERIAIS E MÉTODOS

O presente trabalho foi realizado com a utilização do software Matlab[®], o qual serviu como ferramenta computacional para a modelagem e simulação do processo.

4.1 IMPLEMENTAÇÃO E AJUSTE DO MODELO FENOMENOLÓGICO

O modelo fenomenológico que representa o processo de secagem e cura de pintura automotiva descrito pelas Equações (1) - (8) foi implementado usando a plataforma Matlab[®]. Para a resolução do modelo, foi usado o método de diferenças finitas com discretização no espaço, transformando as equações diferenciais parciais em um sistema de equações diferenciais ordinárias no tempo, às quais foram resolvidas pelo método de Adams Smith, usando a função `ode15s`.


Como o estudo foi aplicado à estufa *Elpo*, a qual é utilizada durante a etapa de pintura por eletrodeposição (*Elpo*) para a realização da secagem e cura da camada de revestimento *E-coat*, o modelo implementado considerou como substrato apenas as camadas de metal e de fosfato, e como filme foi considerada a camada de *E-coat*.

Para que o modelo implementado no ambiente de programação Matlab[®] representasse fielmente o processo em estudo, fez-se necessário ajustar o modelo a dados experimentais de medições das temperaturas de determinadas partes da carroceria do veículo ao longo da estufa *Elpo*. A Figura 13 apresenta a localização das partes da carroceria que foram monitoradas e utilizadas para o ajuste do modelo.

A estufa *Elpo* é dividida em 13 zonas de diferentes comprimentos, totalizando 149,2 m. A Figura 14 apresenta a representação típica da estufa *Elpo*, enquanto as suas especificações dimensionais e operacionais são apresentadas na Tabela 1.

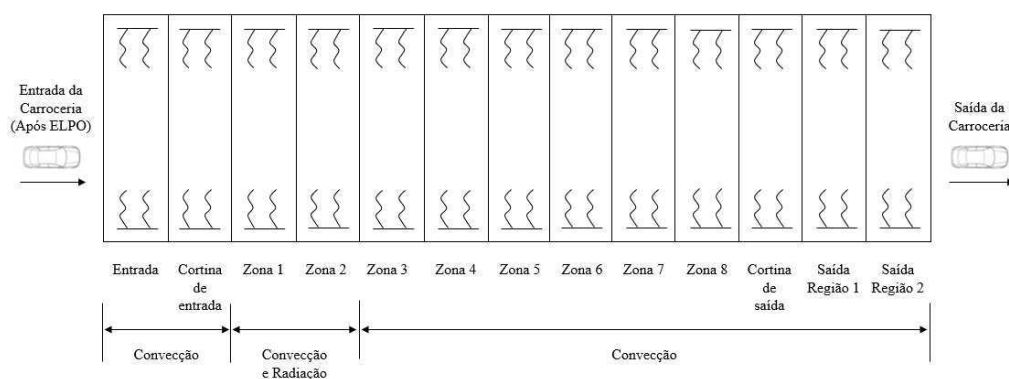
As zonas 1, 12 e 13 da estufa *Elpo* correspondem à entrada e saída, ou seja, não pertencem à estrutura interna da estufa. No entanto, essas regiões foram consideradas na modelagem pois fazem parte das curvas de aquecimento das partes da carroceria.

Figura 13: Partes da carroceria do veículo monitoradas.



Legenda:

- #1 Temperatura do ar próxima ao capô;
- #2 Teto dianteiro esquerdo;
- #3 Teto dianteiro direito;
- #4 Meio teto esquerdo;
- #5 Meio teto direito;
- #6 Coluna do meio esquerda;
- #7 Coluna do meio direita;
- #8 Porta dianteira esquerda;

Figura 14: Representação da estufa *Elpo* em estudo.Tabela 1: Especificações dimensionais e operacionais da estufa *Elpo*.

j	Zona	Comprimento (m)	Temperatura do ar (C)	Velocidade do transportador (m/min)
1	Entrada da estufa	2.0	40	4,8
2	Cortina de entrada	6.4	73	4,8
3	Zona 1	6.4	200	4,8
4	Zona 2	9.6	220	4,8
5	Zona 3	25.6	240	4,8
6	Zona 4	13.6	235	4,8
7	Zona 5	15.2	220	4,8
8	Zona 6	26.8	215	4,8
9	Zona 7	12.8	215	4,8
10	Zona 8	2.0	175	4,8
11	Cortina de saída	3.2	72	4,8
12	Saída da estufa (região 1)	16.8	40	4,8
13	Saída da estufa (região 2)	8.8	40	4,8

Ao analisar os mecanismos de transferência de calor que ocorrem nas zonas da estufa, observa-se que a convecção apresenta influência significativa em todas as zonas. Desta forma, com os dados experimentais disponíveis, o procedimento de ajuste do

modelo aos dados experimentais consiste em um problema de otimização, cuja solução é obtida a partir da determinação dos coeficientes de transferência de calor por convecção para cada parte da carroceria, e em cada zona, que minimizam a diferença entre as temperaturas medidas e as temperaturas calculadas pelo modelo.

Várias funções objetivo são disponibilizadas em estudos existentes para determinar os coeficientes de transferência de calor por convecção. Entretanto, nesse estudo foi desenvolvida uma função multi-objetivo que leva em consideração as características da estufa e das partes da carroceria. Desta forma, o problema de otimização consiste em minimizar a seguinte função objetivo:

$$Fobj_k = \sum_{j=1}^m \left(\left(\sum_{i=1}^n (T_{o\ i,j,k} - T_{m\ i,j,k})^2 \right) - wh_{j,k} \right) \quad (24)$$

Restrita a:

$$h(j, k) > 0 \quad (25)$$

Onde,

k indica o número de partes da carroceria (pontos de medições);

$j = 1, 2, \dots, m$, onde m indica o número de zonas da estufa;

$i = 1, 2, \dots, n$, onde n indica o número de pontos experimentais medidos ao longo da estufa;

T_o é a temperatura medida em cada parte da carroceria, e em cada zona da estufa;

T_m indica a temperatura calculada pelo modelo;

h é o coeficiente de transferência de calor por convecção;

w é um coeficiente de ponderação ajustável, que expressa a contribuição do coeficiente de transferência de calor na função objetivo.

Analisando a Equação (19), observa-se que a função objetivo foi estruturada utilizando o critério dos mínimos quadrados, com o objetivo de minimizar a soma dos quadrados das diferenças entre os valores calculados pelo modelo e os valores experimentais. Desta forma, o modelo deve ser ajustado para cada parte da carroceria, e para cada zona da estufa *Elpo*. Ou seja, para cada parte da carroceria k , e em cada zona da estufa m , será determinado o valor do coeficiente de transferência de calor por

convecção (h) que minimize a diferença entre a temperatura medida (T_o) e a temperatura calculada pelo modelo (T_m).

A determinação dos coeficientes de transferência de calor consiste em um problema de otimização multi-objetivo, com cada parte da carroceria tendo uma função objetivo a ser minimizada. Além disso, o número de zonas da estufa e o número de pontos experimentais das curvas de aquecimento aumentam ainda mais a dimensão do problema. A Tabela 2 apresenta os detalhes das especificações do problema de otimização.

Tabela 2: Detalhamento da otimização de ajuste do modelo fenomenológico.

Parâmetros	Valor
Funções objetivos: Partes da carroceria (k)	8
Zonas da estufa $Elpo$ (m)	13
Número de pontos da curva de aquecimento das partes da carroceria (n)	366
Número de variáveis de busca (h)	104
Números de pontos usados para calcular a função objetivo global ($k \times n$)	2928

Além disso, vale salientar que neste problema de otimização foram adicionadas restrições para que as variáveis de busca, os coeficientes de transferência de calor por convecção, não apresentassem valores negativos, conforme Equação (25). Para isso, foi utilizado um coeficiente de ponderação w , para representar a contribuição de cada função objetivo na função objetivo global.

Logo, o termo $wh_{j,k}$ apresentado na Equação (24) representa uma penalidade, sendo o valor do coeficiente w determinado empiricamente, com o objetivo para forçar o método de otimização a buscar sempre valores positivos (restrições) para os coeficientes de transferência de calor convectivos (variáveis de busca). Desta forma, para valores negativos da variável de busca h , o valor do coeficiente w é suficientemente alto para afastar a função objetivo do seu valor ótimo (mínimo), enquanto para valores positivos o coeficiente w é desprezado na Equação (24).

A característica multi-objetivo do problema de otimização formulado torna necessário o uso de um método de otimização robusto e eficiente. Assim, nesse trabalho foi utilizado o algoritmo Simplex Nelder - Mead Simplex, conforme descrito em Lagarias *et al.* (1998), através da rotina *fminsearch* do Matlab®.

Por fim, é importante enfatizar que o procedimento de otimização proposto é aplicável a todas as partes da carroceria em que há possibilidade de medições de

temperatura. Entretanto, observa-se que em áreas críticas da carroceria, como pilares e agitadores, é difícil obter dados de temperatura.

4.2 TREINAMENTO E IDENTIFICAÇÃO DO MODELO NEURAL


Após as etapas de implementação, ajuste e validação do modelo fenomenológico da estufa de secagem e cura *Elpo*, iniciou-se a etapa de obtenção do modelo neural que será utilizado na estratégia de controle preditivo. Conforme dito anteriormente, para a obtenção do modelo neural é necessário realizar a identificação do processo, que consiste em encontrar um modelo que represente o sistema, através do treinamento das redes neurais artificiais.

Neste trabalho, a arquitetura (topologia) das redes neurais artificiais utilizadas foi do tipo *feedforward* de múltiplas camadas, com apenas uma camada oculta, a qual apresenta 10 neurônios. A função de ativação utilizada foi do tipo tangente hiperbólica, e o treinamento foi realizado através da utilização do algoritmo *backpropagation*.

Inicialmente foram escolhidas quais variáveis do processo seriam consideradas como variáveis manipuladas (variáveis de entradas) e variáveis controladas (variáveis de saídas) na estratégia de controle preditivo neural. Desta forma, avaliando as necessidades operacionais de controle da qualidade de secagem e cura de pintura na estufa *Elpo*, foram definidas como variáveis manipuladas a velocidade do transportador da carroceria ($x_{1,j}$) e as temperaturas das zonas ($x_{2,j}$), enquanto como variáveis controladas foram definidas as temperaturas das posições de medições na carroceria, em cada uma das zonas ($y_{k,j}$), com j variando até o total de zonas m (13 zonas).

Pela característica dinâmica do processo, somado ao fato da estufa *Elpo* apresenta 13 zonas com condições operacionais e dimensionais distintas, verificou-se que a estratégia de controle deveria ser configurada para realizar o controle por zona, na medida que a carroceria é transportada ao longo da estufa. Desta forma, para cada uma das zonas será necessário treinar e identificar uma rede neural artificial, que levará em consideração a velocidade do transportador da carroceria e a temperatura da zona como variáveis de entrada ($x_{1,j}$ e $x_{2,j}$), e as temperaturas das posições de medições na carroceria ($y_{k,j}$) como variáveis de saída. Logo, o modelo neural da estufa *Elpo* é formado por 13 redes neurais artificiais, com a configuração apresentado na Figura 15 .

Figura 15: Representação da configuração das redes neurais artificiais.



❖ Variáveis de Entrada

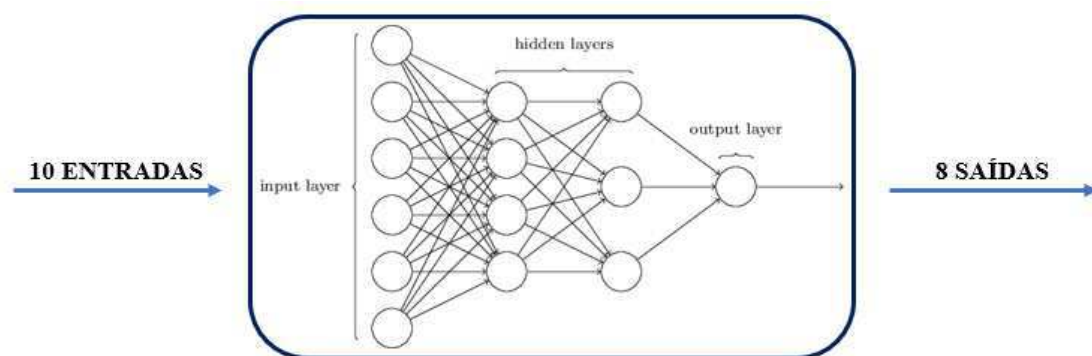
- Velocidade do transportador na zona atual ($x_{1,j}$);
- Temperatura da zona atual ($x_{2,j}$);

❖ Variáveis de Saída

- Temperaturas das posições de medições na carroceria na zona atual ($y_{k,j}$);

Todavia, como o objetivo de deixar os modelos neurais mais robustos e precisos, a partir da segunda zona da estufa (cortina de entrada) adicionou-se como variáveis de entrada das RNAs as temperaturas das posições de medições na carroceria da zona anterior. Desta forma, a partir da segunda zona da estufa, a configuração das redes neurais é constituída de 10 variáveis de entrada e 8 variáveis de saída, conforme Figura 16. Com isso, a Figura 17 apresenta a representação da configuração geral das redes neurais da estufa *Elpo*.

Figura 16: Representação da configuração das redes neurais artificiais das zonas 2-13.

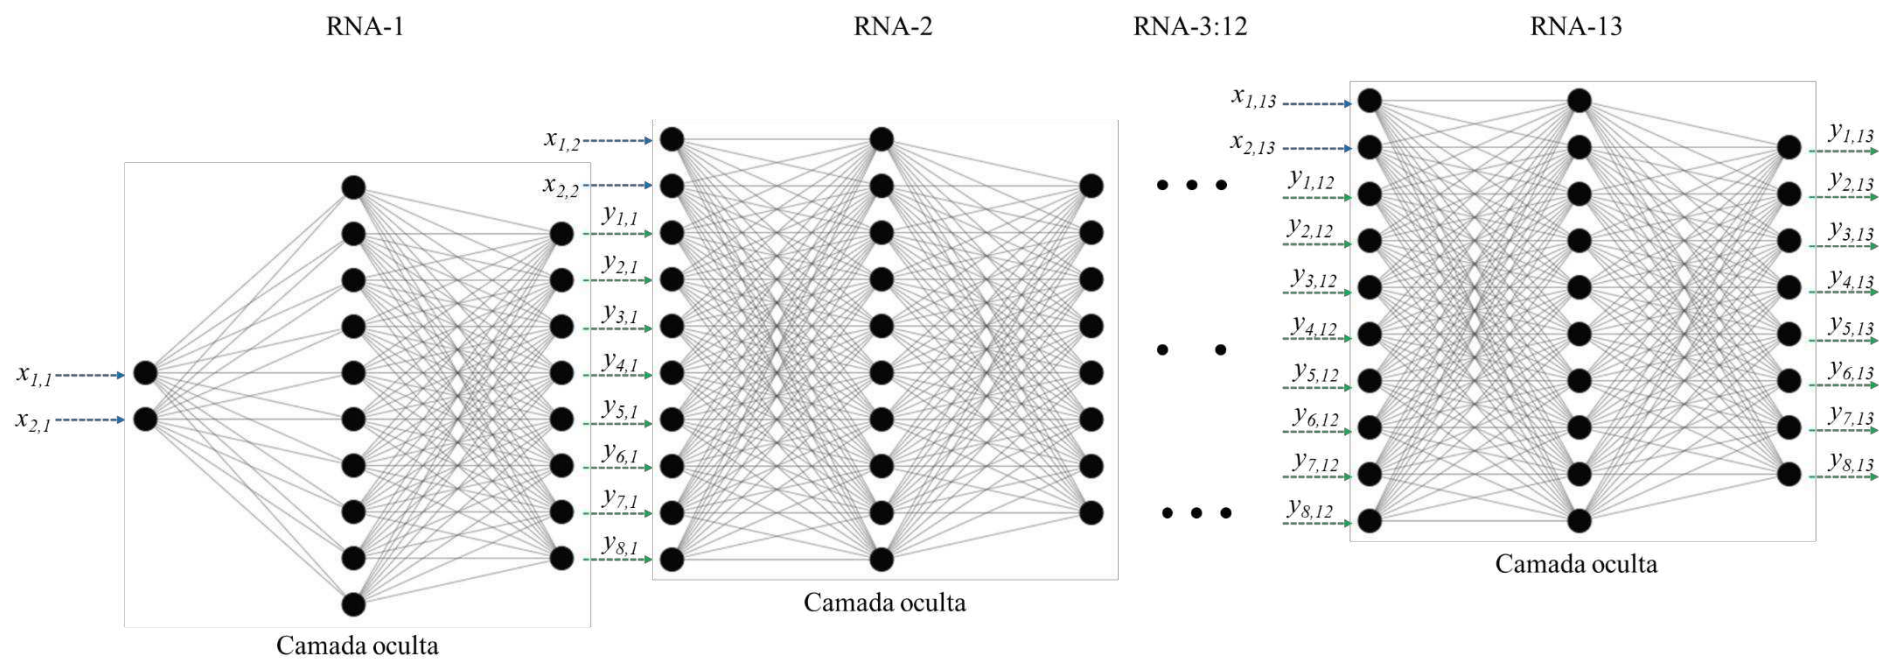


❖ Variáveis de Entrada

- Velocidade do transportador na zona atual ($x_{1,j}$);
- Temperatura da zona atual ($x_{2,j}$);
- Temperaturas das posições de medições na carroceria na zona anterior ($y_{k,j-1}$);

❖ Variáveis de Saída

- Temperaturas das posições de medições na carroceria na zona atual ($y_{k,j}$);

Figura 17: Representação da configuração geral das redes neurais artificiais das zonas da estufa *Elpo*.Tabela 3: Topologia das redes neurais das zonas da estufa *Elpo*.

Zonas	Arquitetura	Neurônios na camada de entrada	Neurônios na camada oculta	Neurônios na camada de saída	Função de Ativação
1	<i>Feedforward</i> de múltiplas camadas	2	10	8	Tangente hiperbólica
2-13		10	10	8	

Após a definição das variáveis de entrada e de saída, foi necessário efetuar a aplicação de perturbações sobre cada variável de entrada, de modo a ser possível obter as respostas dinâmicas do processo à estas perturbações, e gerar o banco de dados para os treinamentos das redes neurais artificiais.

Deste modo, utilizando o modelo fenomenológico implementado da estufa *Elpo*, através da utilização da função “*rand*” do Matlab®, aplicou-se distúrbios do tipo randômicos na velocidade do transportador e nas temperaturas das zonas, conforme a Equação abaixo:

$$R = X \{1 + [a + (b - a)rand(1,1)]\} \quad (26)$$

Onde R é a matriz com valores randômicos das variáveis de entrada, X é a matriz com os valores nominais das variáveis de entrada, a é a variação negativa, b é a variação positiva. Para o treinamento, foram definidas variações de -10% (a) e 10% (b) nas variáveis de entrada. Vale salientar que foram definidas tais variações (-10% e 10%) pois após consultar os dados disponíveis, verificou-se que as variáveis manipuladas normalmente não variam tanto no processo, e com isso, as variações especificadas apresentam um range aceitável para o treinamento.

Com o objetivo de verificar o desempenho do treinamento das redes neurais com o aumento da quantidade de dados, foram gerados bases de dados com 100, 200, 300, 400, 500 e 1000 casos simulados, com cada caso simulado sendo gerado através da utilização de uma matriz randômica das variáveis de entrada com valores diferentes. O Algoritmo para a geração do banco de dados para o treinamento das redes neurais é apresentado na Figura 18.

Após a obtenção do banco de dados para os treinamentos, formados pelas variáveis de entradas randômicas e as variáveis de saída (respostas do modelo), iniciou-se os procedimentos de treinamentos das redes neurais. Os treinamentos foram realizados de forma separada para cada uma das bases de dados com 100, 200, 300, 400, 500 e 1000 casos, através da utilização da função “*trainlm*” do Matlab®, que é uma função de treinamento de redes neurais que atualiza os valores de peso utilizando o método de otimização de *Levenberg-Marquardt*. Vale salientar que para todos os treinamentos realizados, os dados disponíveis (100, 200, 300, 400, 500 e 1000) foram separados em dados de treinamento (80% dos dados), dados de validação (10% dos dados) e dados de teste (10% dos dados).

Com isso, após os treinamentos é possível verificar os resultados através da opção “Regression”, presente na interface da toolbox “Neural Network training”, onde os gráficos referentes ao treinamento, validação, teste e global da rede neural são apresentados, disponibilizando os valores dos coeficientes de ajuste R^2 . Além disso, a função “trainlm” analisa a performance da rede neural para diferentes quantidades de épocas, selecionando a que apresenta o melhor ajuste, através do cálculo do erro quadro médio (mse). A interface da toolbox, e exemplos de resultados da regressão e da análise de performance da rede são apresentados respectivamente na Figura 19, Figura 20 e Figura 21.

Figura 18: Algoritmo para a geração do banco de dados para o treinamento.

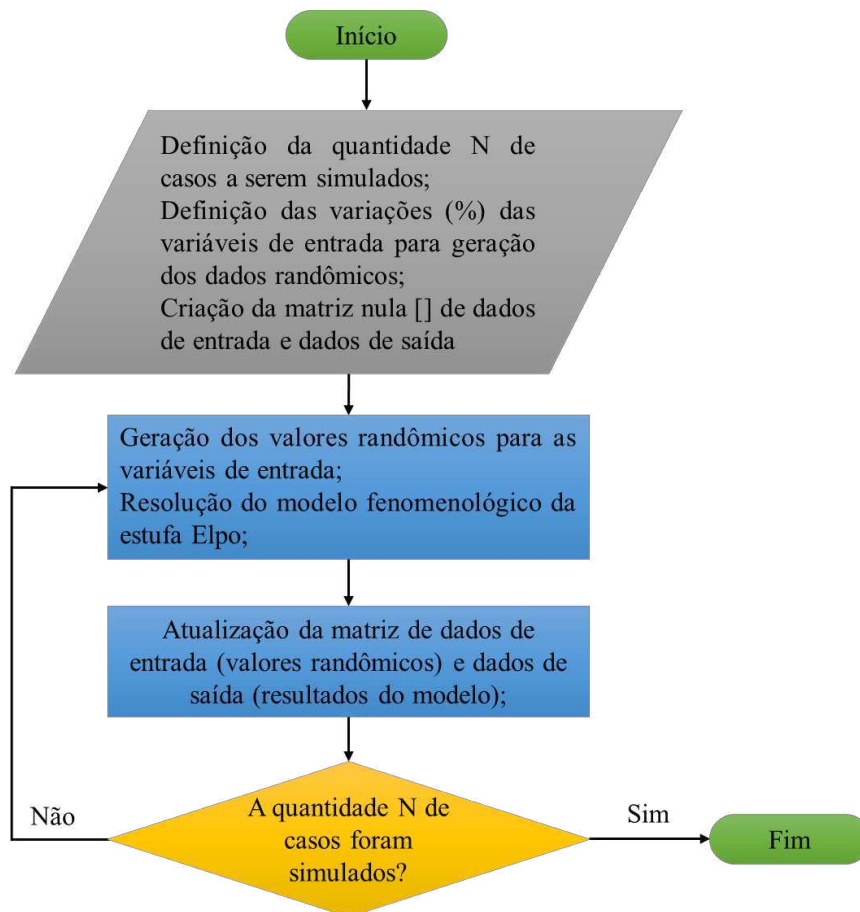


Figura 19: Interface da toolbox “Neural Network training”.

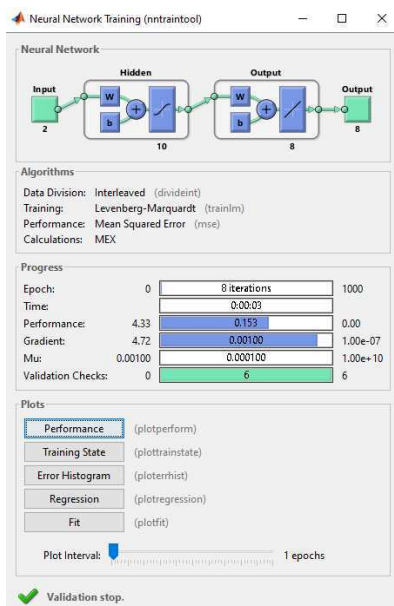


Figura 20: Resultados do treinamento da rede neural (“Regression”).





Figura 21: Resultados da análise de performance da rede (“Performance”).



Por fim, considerando os treinamentos feitos com as bases de dados com 100, 200, 300, 400, 500 e 1000 casos, os modelos de redes neurais para as 13 zonas que apresentaram os melhores ajustes são selecionados e salvos, para serem utilizados na etapa seguinte, de desenvolvimento e implementação do sistema de controle preditivo neural.

4.3 IMPLEMENTAÇÃO DO SISTEMA DE CONTROLE PREDITIVO NEURAL (NNPC)

A proposta de controle deste trabalho baseia-se na implementação de um sistema de controle preditivo neural - NNPC, o qual tem como objetivos primordiais realizar a predição de valores futuros da planta através do uso de um modelo neural identificado previamente com base em dados da planta, e executar ações capazes de manter a estabilidade das variáveis de processo.

Desta forma, com posse dos modelos de redes neurais para as 13 zonas que foram identificados e validados, implementou-se a estratégia de controle preditivo neural NNPC, baseado no modelo do controle preditivo generalizado (GPC), cuja função objetivo J é expressa pela Equação 8 apresentada anteriormente.

A Figura 22 apresenta a representação da estrutura da estratégia de controle NNPC, enquanto a Figura 23 apresenta o algoritmo de resolução da estratégia de controle. De forma geral, na medida que a carroceria vai sendo transportada por cada uma das 13 zonas da estufa, os modelos de rede neurais atuam prevendo as temperaturas das partes da carroceria (variáveis controladas $y_{k,j}$), e estas previsões são utilizadas na função

objetivo J , de modo que a partir da aplicação de um método de otimização é possível determinar os valores de velocidade do transportador nas zonas ou de temperatura das zonas (sinais de controle, variáveis manipuladas $x_{1,j}$ e $x_{2,j}$) que minimizam a função objetivo. Essas determinações, feitas zona por zona, fazem com que as temperaturas das partes da carroceria atinjam valores iguais/próximos de seus *setpoints*, e com isso, se mantenham controladas ao longo do processo.

É importante salientar que para obter o comportamento e as respostas reais do processo, mediante aplicação de distúrbios e dos sinais de controle da estratégia implementada, o “Processo” na estufa Elpo foi representado através da utilização do modelo fenomenológico, o qual foi previamente implementado e validado neste trabalho, conforme apresentado nos itens 3.2 e 4.1.

Figura 22: Estrutura do sistema de controle preditivo neural (NNPC) implementado.

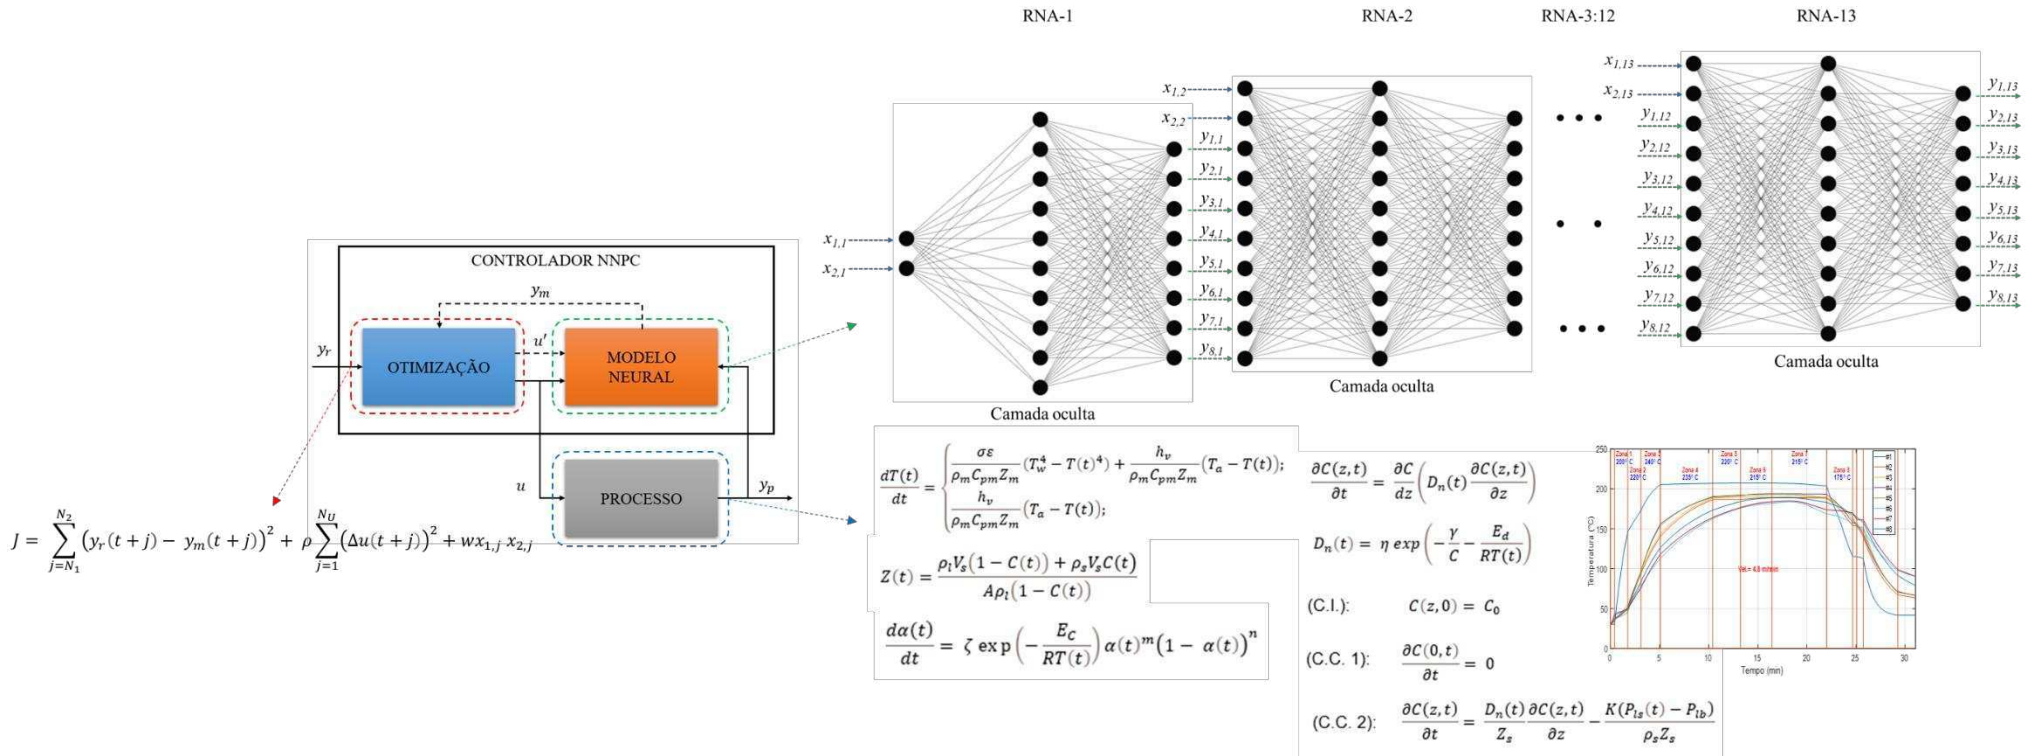
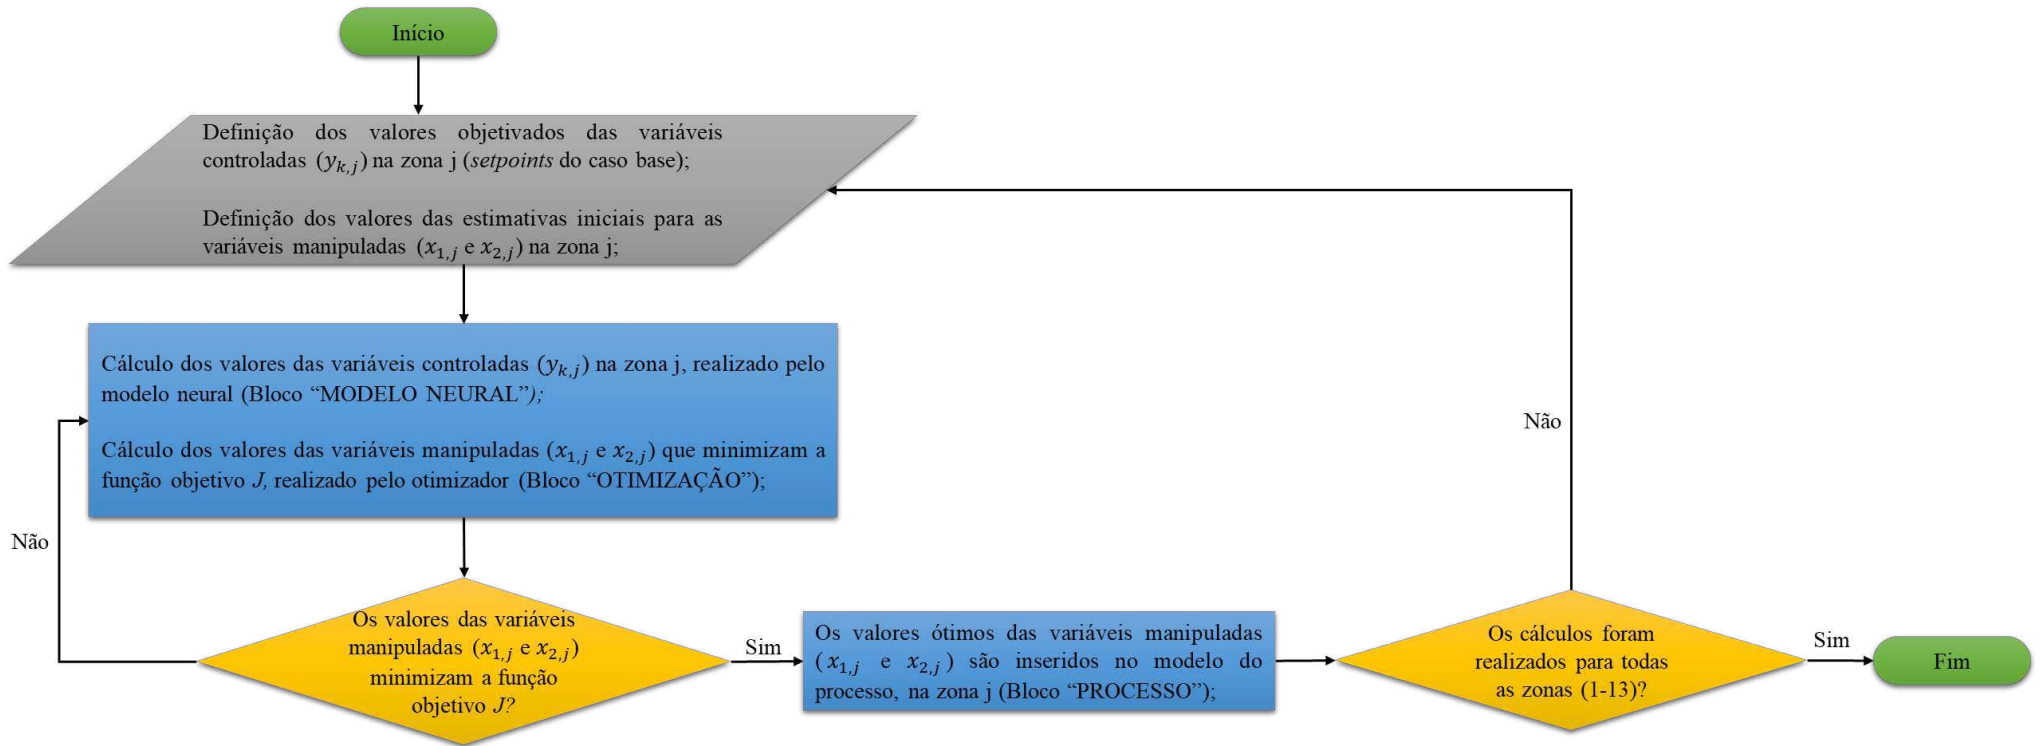


Figura 23: Algoritmo de resolução do sistema de controle preditivo neural (NNPC) implementado.



5 RESULTADOS E DISCUSSÕES

Este tópico apresenta os resultados obtidos neste trabalho. Inicialmente, no item 5.1, serão apresentados os resultados para a validação do caso base do modelo fenomenológico da estufa *Elpo*, obtidos através da aplicação da metodologia de otimização para determinação dos parâmetros de transferência de calor por convecção.

Posteriormente, no item 5.2 serão apresentados os resultados do treinamento, da identificação e validação do modelo neural da estufa *Elpo*. Por fim, no item 5.3 serão apresentados os resultados da implementação da estratégia de controle preditivo neural (NNPC), e a análise do desempenho do sistema de controle NNPC no controle dinâmico do modelo, com foco no controle da temperatura das partes da carroceria ao longo da estufa *Elpo*.


5.1 VALIDAÇÃO DO MODELO FENOMENOLÓGICO E SIMULAÇÃO DO CASO BASE

Como o estudo foi aplicado à estufa *Elpo*, o material de revestimento considerado foi o *E-coat*. Já os valores de espessura, densidade e capacidade térmica do substrato metálico foram considerados respectivamente iguais a 0,001 m, $2.700 \frac{Kg}{m^3}$ e $840 \frac{J}{Kg.K}$.

A metodologia de otimização para a determinação dos parâmetros de transferência de calor por convecção foi realizada através de um procedimento iterativo, no qual a partir de estimativas iniciais dos coeficientes, foi possível determinar os valores dos parâmetros que forneceram o melhor ajuste do modelo aos dados experimentais, validando o modelo para o caso base da estufa *Elpo*. Desta forma, as estimativas iniciais utilizadas para os valores do coeficiente de transferência de calor foram $5 \frac{W}{m^2.K}$, com a rotina de otimização sendo submetida a 10, 100 e 1.000 iterações. Após as simulações, observou-se que os resultados gerados pelo modelo se ajustam melhor aos dados da planta após 1.000 iterações, correspondendo, assim, ao valor estabelecido para o ajuste das curvas de aquecimento.

A Figura 24 apresenta uma comparação entre os dados experimentais (pontilhado) e os resultados apresentado pelo modelo (contínuo) para a posição da carroceria (temperatura do ar próxima ao capô), considerando o total de 1.000 iterações.

Figura 24: Dados experimentais (pontilhado) e resultados do modelo (contínuo) para a posição 1 da carroceria (1000 iterações).



É possível verificar um desempenho satisfatório do procedimento de otimização, pois verifica-se um bom ajuste entre o modelo e os dados medidos. Os coeficientes de transferência de calor por convecção do modelo que foram determinados usando os dados industriais para o forno *Elpo* são apresentados na Tabela 4.

Desta forma, a Figura 25 apresenta as curvas de aquecimento simuladas para as oito posições de medições de temperatura ao longo das zonas da estufa *Elpo*, usando os coeficientes de transferência de calor por convecção determinados pelo procedimento de otimização, onde é possível observar diferentes condições de aquecimento nas posições de medições de temperatura.

A Figura 26 apresenta a conversão de cura para as oito posições da carroceria. É possível observar que as curvas estão na forma de um sigmoide, o que é explicado pela baixa diferença entre a taxa de evaporação do solvente e a reação de polimerização. Conforme esperado, os perfis de conversão de cura também diferem-se de acordo com a posição de medição, e isso deve-se à diferença entre as taxas de evaporação, resultantes das diferenças nas curvas de aquecimento observadas na Figura 26.

É possível observar que a cura de 100% é alcançada em todas as posições. No entanto, em vez de avaliar apenas a taxa de conversão, é de suma importância observar em quanto tempo a cura atinge um nível próximo a 100%, visto que em qualquer estufa, ou mesmo ao deixar a carroceria secando no ambiente, a conversão de cura atingiria um valor de 100%, mesmo que seja necessário um período de tempo significativamente mais longo

para atingir essa condição. Evidentemente, a qualidade da pintura não seria a mesma e a produtividade seria baixa.

Segundo Lou e Huang (2000), um dos fatores que influencia diretamente a qualidade da pintura é a taxa de evaporação do solvente. Uma remoção rápida do solvente pode causar estouros, formação de bolhas e rugas na pintura. Por outro lado, se a taxa de evaporação do solvente for muito baixa, a reação de polimerização também pode ser prejudicada, causando problemas similares.

Figura 25: Perfis de temperatura das posições de medições ao longo da estufa *Elpo*.


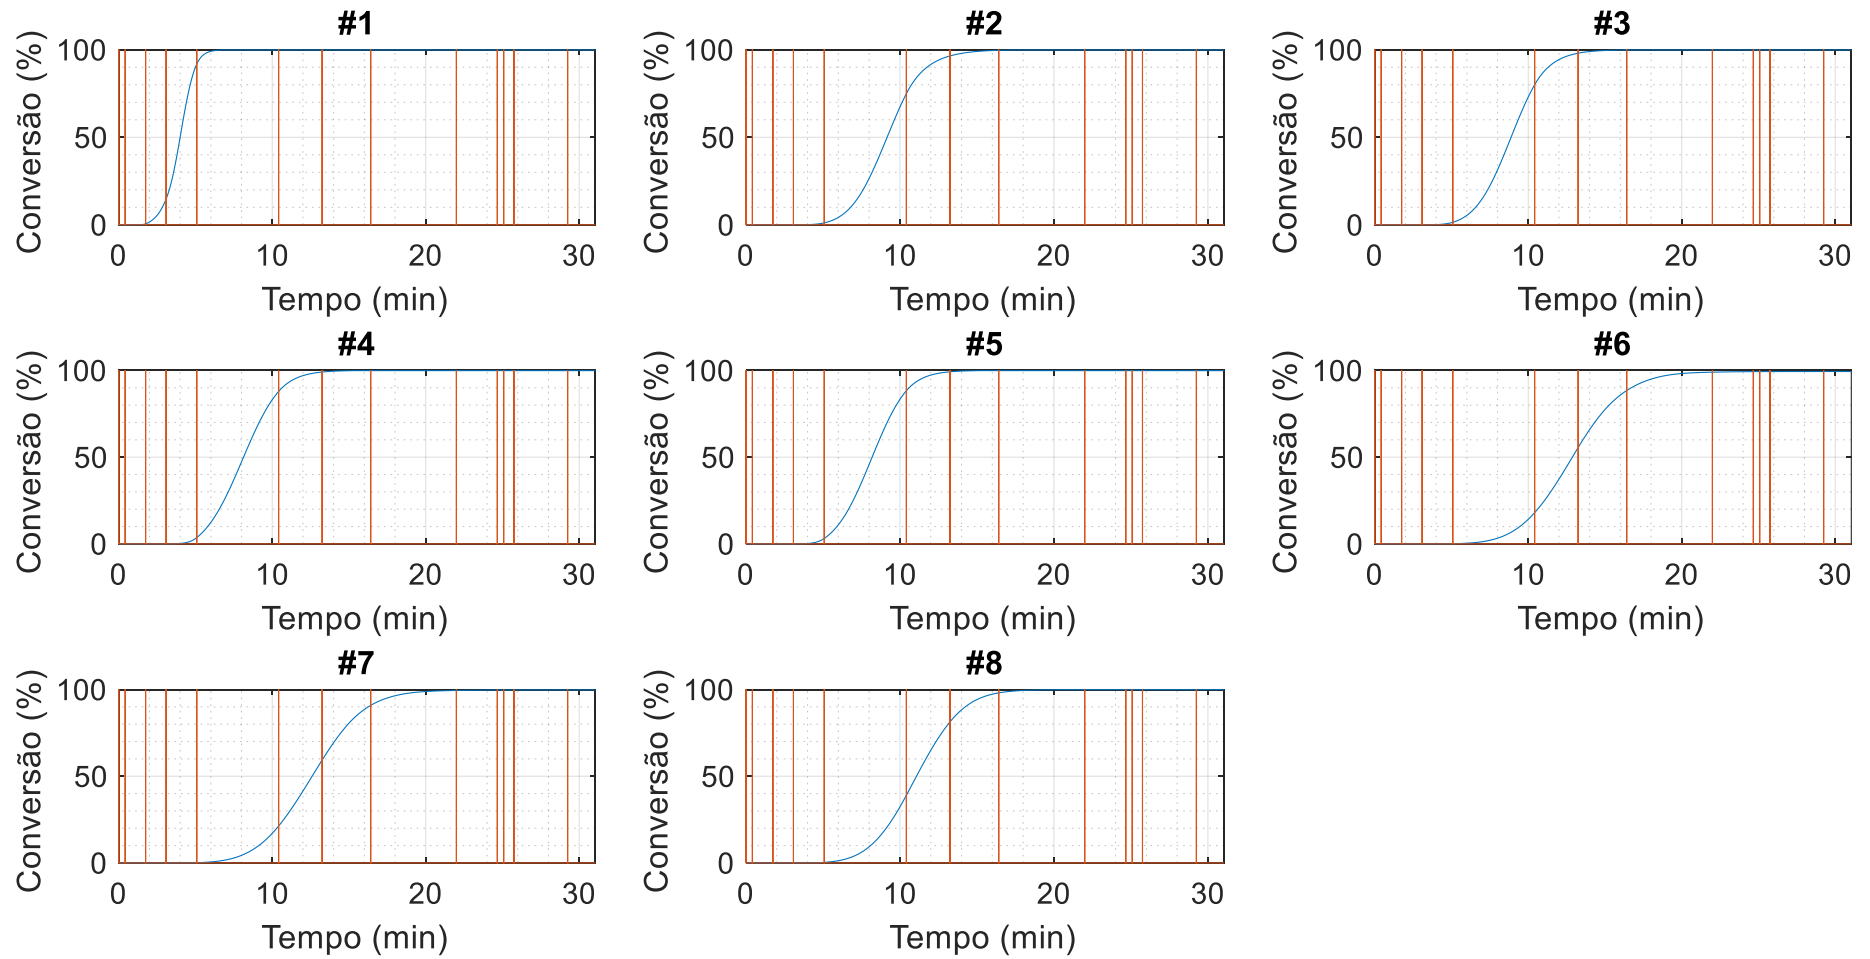


Tabela 4: Coeficientes de transferência de calor por convecção determinados pela otimização ($\frac{W}{m^2 \cdot K}$).

	Entrada da estufa	Cortina de entrada	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 6	Zona 7	Zona 8	Cortina de saída	Saída da estufa (região 1)	Saída da estufa (região 2)
Temperatura do Ar próxima ao capô	2.6539	13.1972	16.499	11.6916	3.9851	0.6735	0.0604	0.1484	17.9268	1.4905	6.1516	532.725	0.2827
Teto dianteiro esquerdo	1.0532	0.7943	5.5645	9.3063	6.3453	0.37	1.9687	2.1538	7.0193	1.39	7.0083	2.3144	3.9628
Teto dianteiro direito	3.4785	1.9952	6.5373	8.055	5.7692	1.5042	2.0662	2.5956	5.2674	3.0899	5.5053	0.8548	1.6945
Meio teto esquerdo	2.8036	1.2986	5.6813	10.2343	5.4971	2.5546	3.0343	2.6756	5.9769	2.898	4.0767	2.1454	3.4887
Meio teto direito	2.2468	1.3607	5.5087	10.1315	5.9965	2.0998	0.7259	5.0295	5.2369	5.5785	2.8092	0.5177	1.007
Coluna do meio esquerda	4.3603	0.4483	3.7114	5.7618	4.1909	3.6928	2.9639	5.0093	1.5933	4.5527	3.3309	1.4976	3.4536
Coluna do meio direita	3.2724	0.7755	2.1312	6.0133	3.2586	2.6875	3.107	3.5794	1.6925	4.611	3.2375	9.8725	49.6115
Porta dianteira esquerda	2.8794	1.6981	6.7052	9.4117	5.3979	2.376	1.6879	1.7741	5.2927	3.3879	6.6184	6.859	11.8637


Figura 26: Conversão de cura (reação de polimerização) das oito posições da carroceria na estufa *Elpo*.

Em resumo, observa-se que a diferença de conversão de cura em cada posição da carroceria depende da cinética de cura, que depende de uma série de fatores, incluindo a temperatura atingida na região, os coeficientes de transferência de calor, velocidade do ar e posição de cada região na estufa.

Desta forma, também é indicado verificar a qualidade da pintura através da análise de uma janela de cura recomendada pelo fabricante dos revestimentos. De acordo com Dickie *et al.* (1997), as janelas de cura fornecidas pelos fabricantes dos materiais servem para orientar o desenvolvimento das condições de processo, e exibem intervalos de tempo e temperatura durante os quais as propriedades de desempenho geralmente aceitáveis podem ser alcançadas. Com isso, o uso da janela de cura e de um painel de temperatura/tempo permite analisar se a qualidade da cura da tinta é satisfatória e se está dentro das especificações.

A Figura 27 apresenta a janela de cura recomendada pelo fabricante para o processo de cura do revestimento *E-coat* (região delimitada pela linha preta) e as curvas de aquecimento de cada posição da carroceria. O modelo matemático disponibilizado em Xiao *et al.* (2006) foi utilizado para o desenvolvimento das curvas de temperatura para serem incluídas na janela de cura, as temperaturas transformadas.

Figura 27: Temperaturas das posições transformadas na janela de cura, na estufa *Elpo*.



Na Figura 27, a região delimitada pela cor azul representa a região em que as curvas de aquecimento estão mais próximas do ponto de cura ideal. A janela de cura também fornece a condição nominal de cura, que no caso em estudo é representada pelo

ponto em 25 min e 165 °C (símbolo de estrela). A cura fora da região recomendada pode resultar na formação de bolhas na superfície da carroceria, devido à evaporação desigual do solvente.

Vale ressaltar que os gráficos das figuras anteriores estão apresentando no eixo x a variável “tempo de processo (min)”, que foi obtida considerando a velocidade do transportador da carroceria ($4,8 \frac{m}{min}$) e o comprimento da estufa (149,2 m).

5.2 IDENTIFICAÇÃO E VALIDAÇÃO DO MODELO NEURAL

Com o modelo fenomenológico da estufa *Elpo* implementado, ajustado e validado, iniciou-se o procedimento de identificação e validação do modelo neural da estufa, com base nos resultados dos treinamentos para cada uma das bases de dados com 100, 200, 300, 400, 500 e 1000 casos simulados, conforme descrito no Item 4.2.

Com objetivo de verificar o desempenho das redes neurais com o aumento da quantidade de dados para o treinamento, comparou-se os resultados dos treinamentos para cada uma das bases de dados com 100, 200, 300, 400, 500 e 1000 casos simulados. Desta forma, para cada uma das bases de dados, analisou-se os resultados do treinamento em cada uma das 13 zonas da estufa, através da opção “*Regression*”, presente na interface da toolbox “*Neural Network training*”, onde foi possível verificar os gráficos dos resultados dos treinamentos, validações e testes das redes neurais.

Após realizar as comparações dos resultados dos treinamentos para as 13 zonas da estufa, verificou-se que a utilização da base de dados com 500 casos simulados gerou resultados mais satisfatórios quando comparados as demais bases de dados, no que diz respeito a predição das temperaturas das 8 partes da carroceria nas 13 zonas.

Ou seja, quando os resultados treinamento realizado com a base de dados com 500 casos são comparados com os resultados dos treinamentos realizados com quantidade de dados menores (100, 200, 300 e 400), observa-se que aumento de dados de treinamento proporcionou a obtenção de modelos neurais com melhores resultados de predição das temperaturas das 8 partes de medições. Entretanto, o aumento da base de dados para 1000 casos simulados não forneceu melhorias tão significativas nos resultados de predição, além do treinamento ter sido computacionalmente bem mais demorado, quando comparado ao treinamento com 500 casos.

Desta forma, com base na identificação das redes neurais para as 13 zonas com a utilização do banco de dados com 500 casos, os gráficos com os resultados dos

coeficientes de ajustes (determinação) R^2 para o treinamento (80% dos dados = 400 casos), validação (10% dos dados = 20 casos), teste (10% dos dados = 50 casos) e global das redes neurais são apresentados nas figuras de 28 a 34, enquanto a Tabela 5 apresenta o resumo destes resultados. É possível observar que as redes neurais obtidas para todas as zonas apresentaram valores de coeficientes de ajuste R^2 acima de 0,98, demonstrando ótimos ajustes dos modelos neurais durante as etapas de treinamento, validação e testes de predições das temperaturas das partes da carroceria.

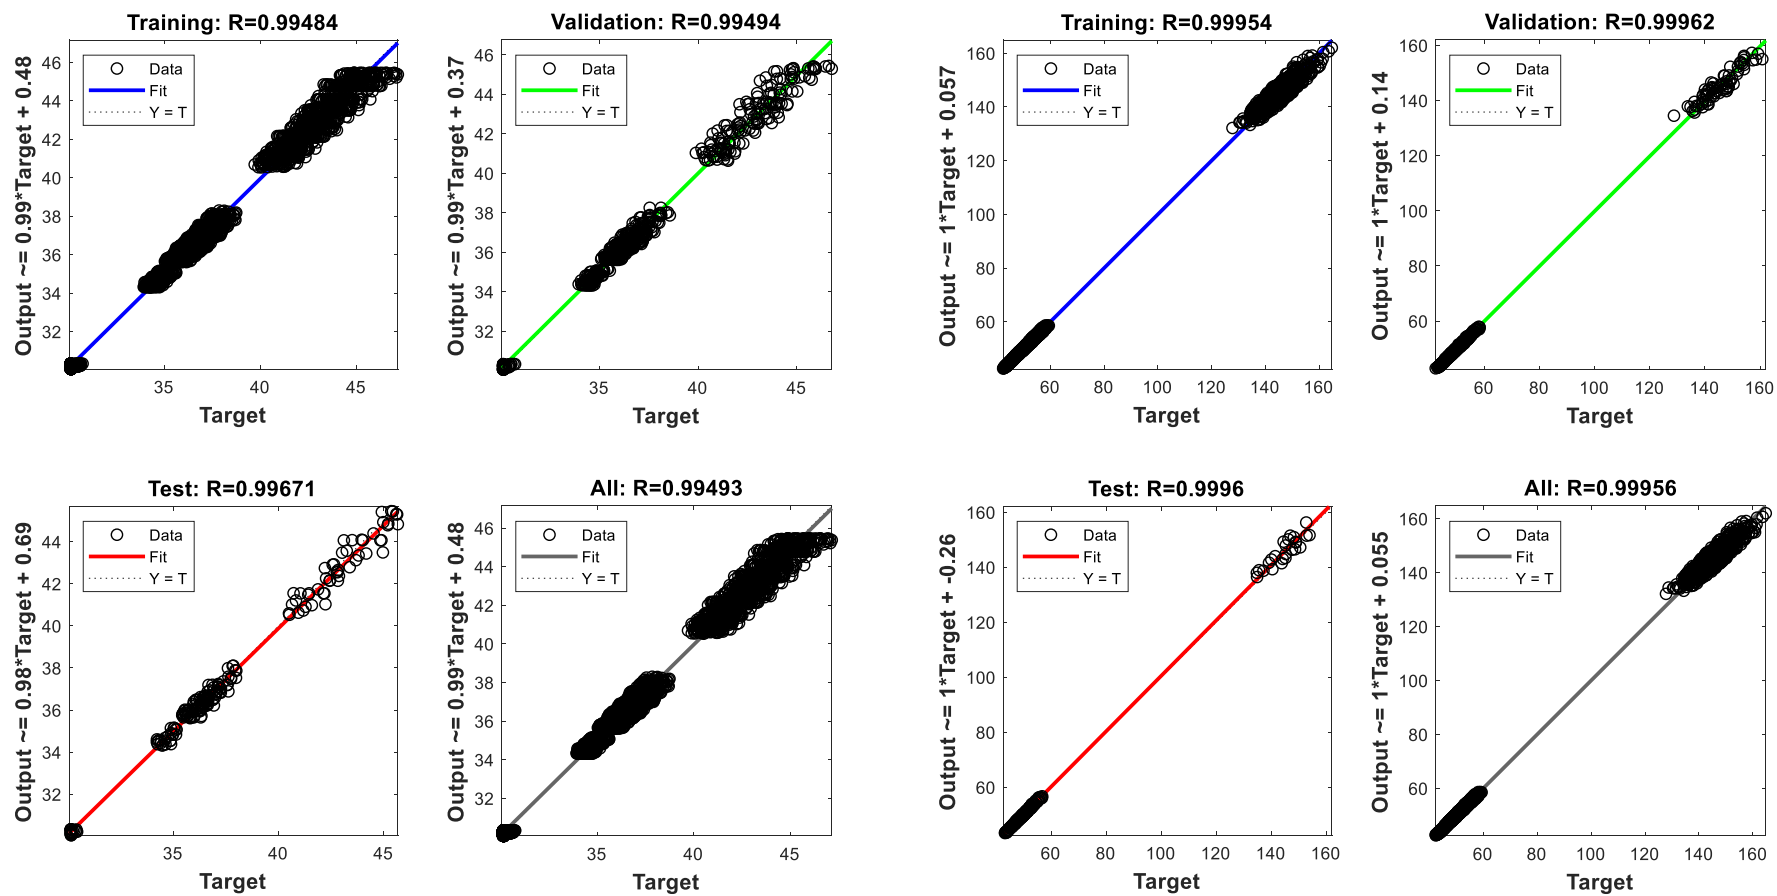
Tabela 5: Coeficientes R^2 para o treinamento, validação, teste e global das RNAs.

Zona	Treinamento	Validação	Teste	Global
Entrada da estufa	0,9896	0,9898	0,9934	0,9898
Cortina de entrada	0,9990	0,9924	0,9992	0,9992
Zona 1	0,9992	0,9992	0,9992	0,9992
Zona 2	0,9968	0,9970	0,9966	0,9968
Zona 3	0,9862	0,9815	0,9839	0,9855
Zona 4	0,9978	0,9970	0,9962	0,9976
Zona 5	0,9978	0,9972	0,9970	0,9976
Zona 6	0,9994	0,9990	0,9990	0,9992
Zona 7	0,9996	0,9996	0,9994	0,9996
Zona 8	0,9998	0,9998	0,9998	0,9998
Cortina de saída	0,9998	0,9998	0,9998	0,9998
Saída da estufa (Região 1)	0,9968	0,9972	0,9958	0,9968
Saída da estufa (Região 2)	1,0000	1,0000	1,0000	1,0000

É importante salientar que existem algumas justificativas fundamentais para os bons ajustes observados na tabela acima, que não indicam necessariamente overfitting do modelo. Em primeiro lugar, foram realizados testes com uma variedade diversificada de casos simulados, e com isso, os melhores resultados foram obtidos com o conjunto de dados de 500 casos. Em segundo lugar, experimentos meticulosos determinaram a divisão ideal do conjunto de dados em subconjuntos de treinamento, validação e teste, com proporções cuidadosamente selecionadas, que proporcionaram o desempenho geral mais favorável com 80% dos dados para treinamento, 10% dos dados para validação e 10% dos dados para teste.

Por fim, dentro do contexto específico deste modelo, as zonas de "resfriamento" na estufa (Saída da estufa - Região 1 e Saída da estufa - Região 2) apresentaram variações limitadas de temperatura, permitindo que o modelo de rede neural obtivesse previsões altamente precisas. Mesmo com alterações nos dados de treinamento ou na divisão do conjunto de dados, é provável que o modelo continue produzindo resultados favoráveis nessas 2 zonas, devido às variações de temperatura limitadas das partes da carroceria.

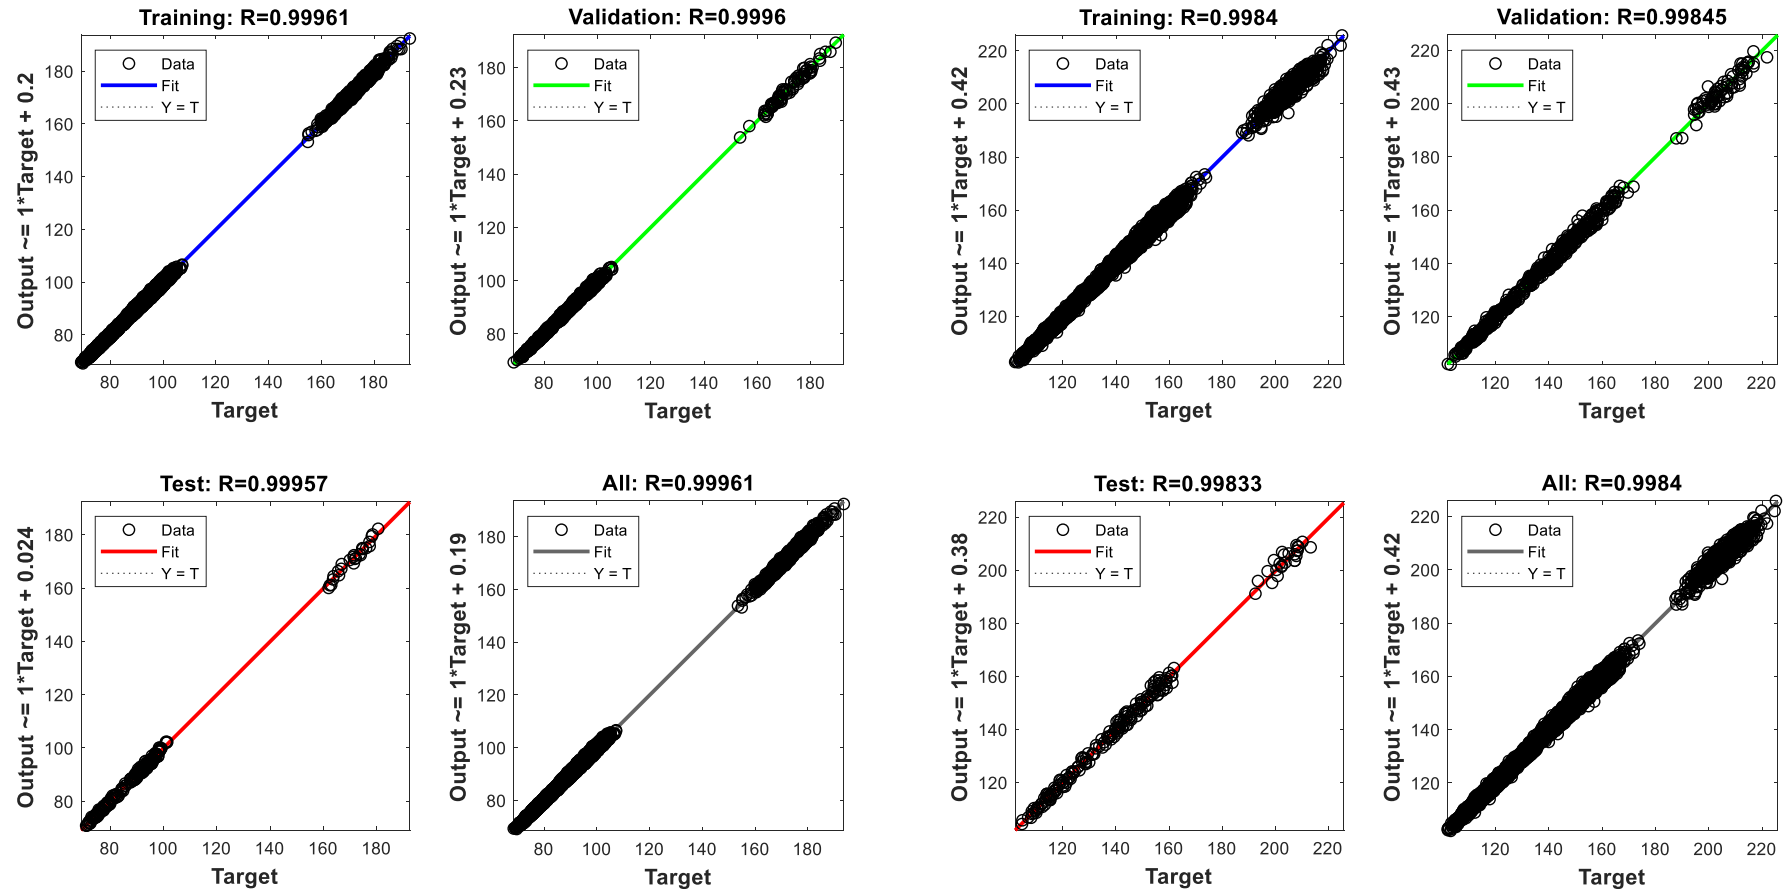
Figura 28: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Estrada da Estufa e (b) Cortina de Entrada.



(a)

(b)

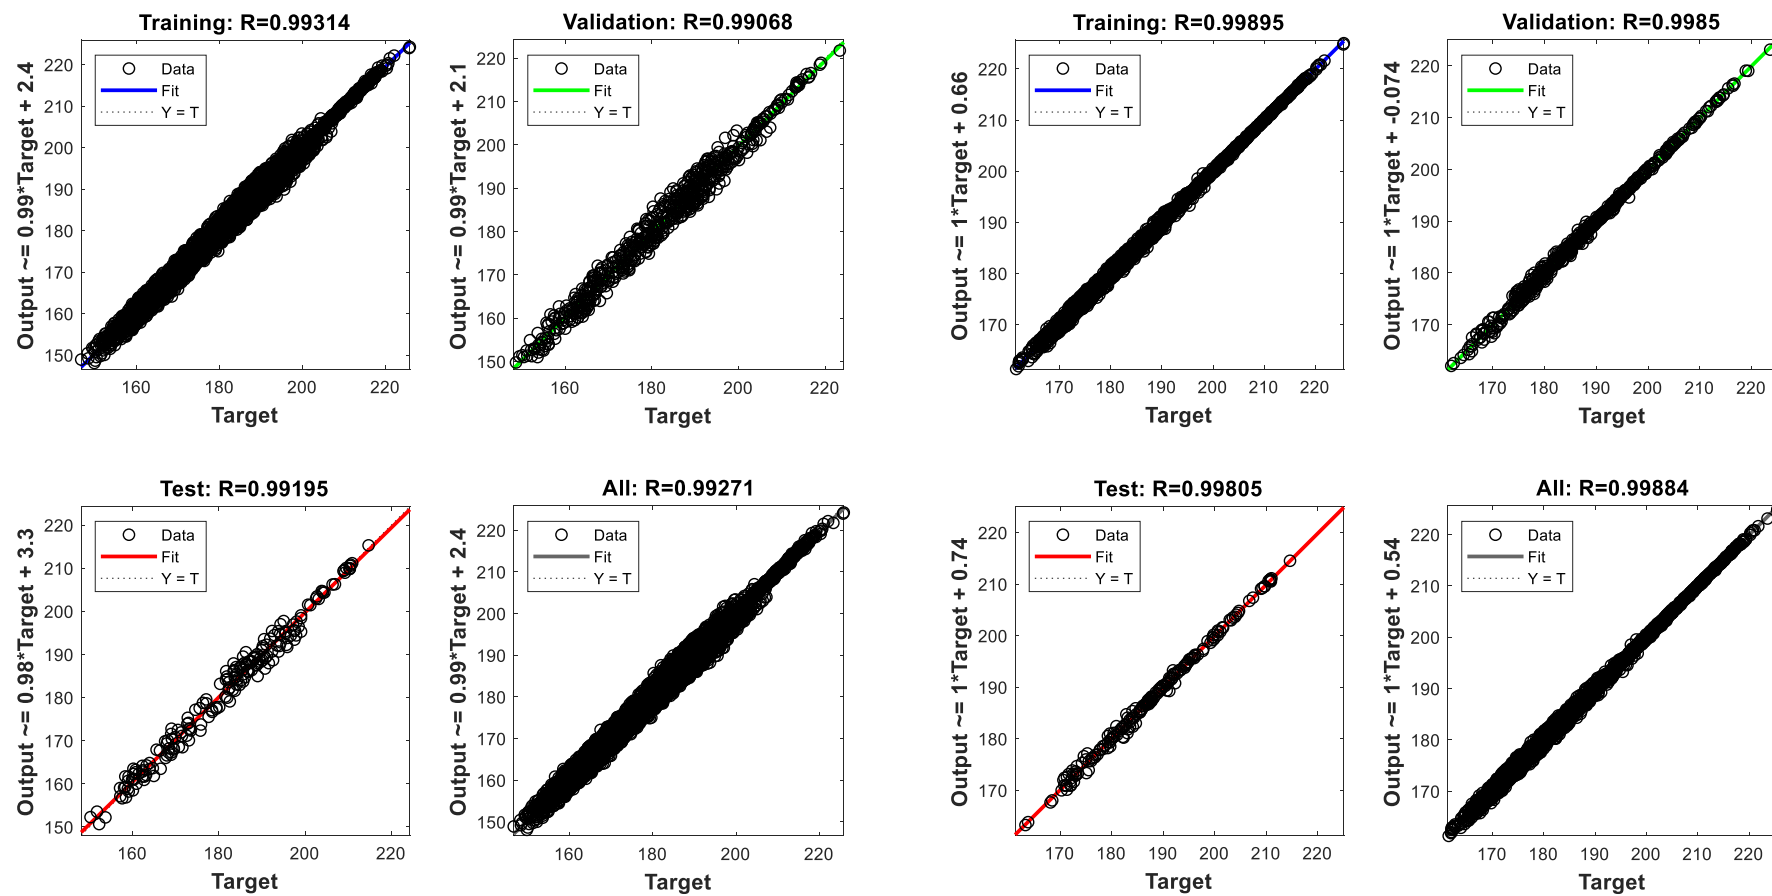
Figura 29: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 1 e (b) Zona 2.



(a)

(b)

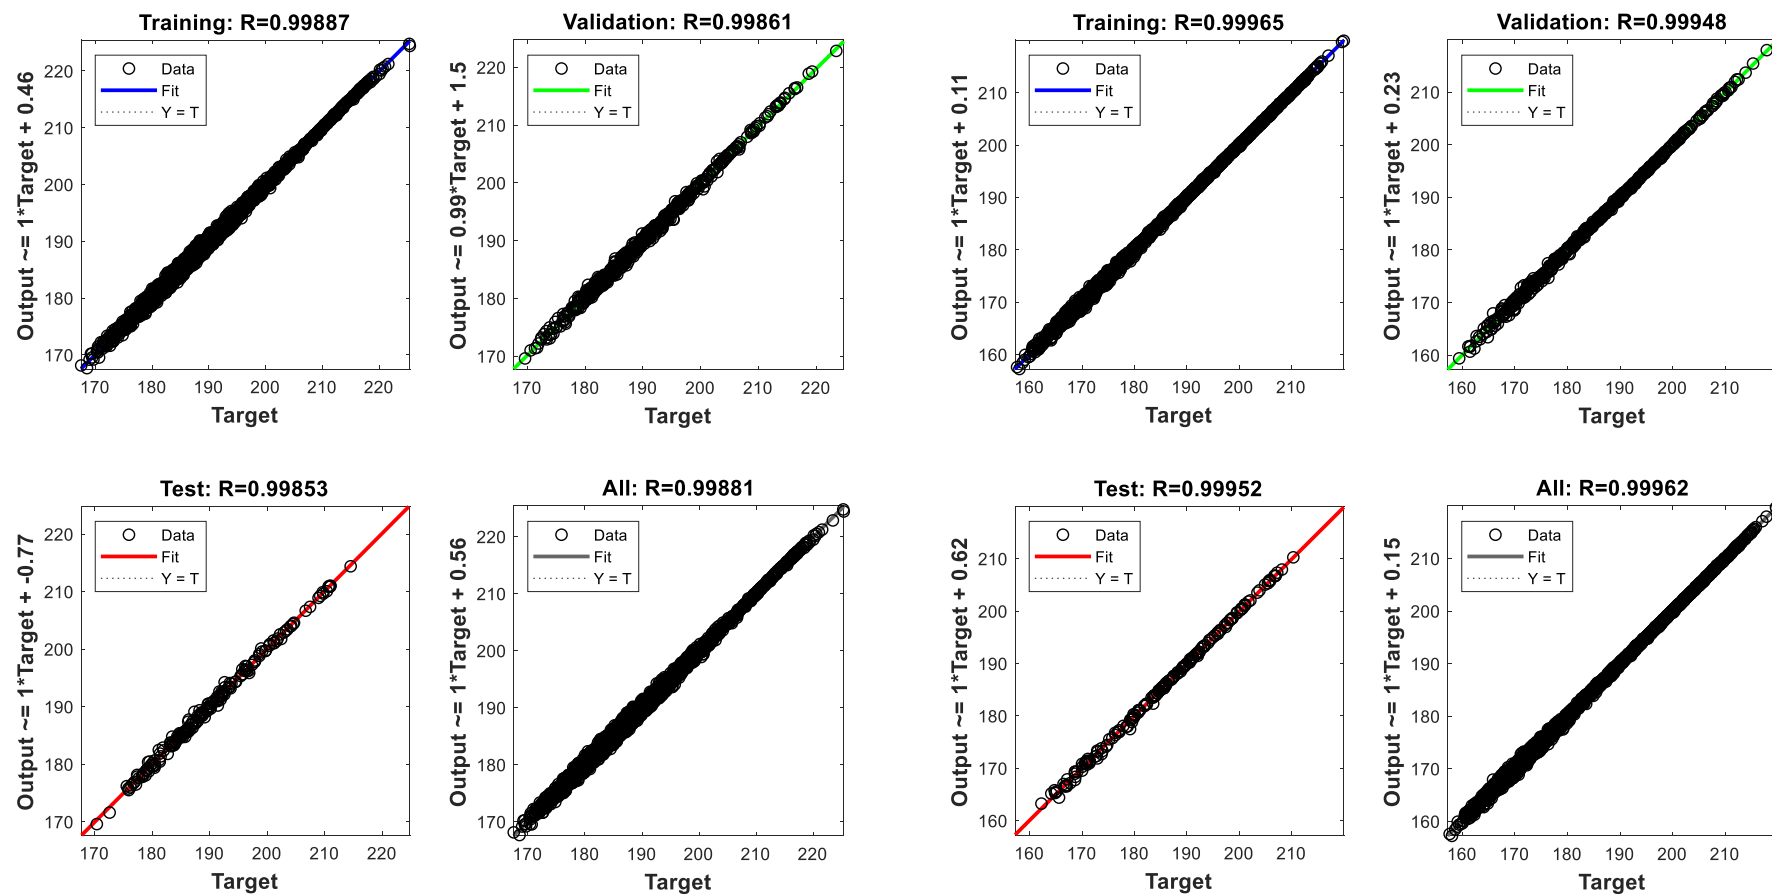
Figura 30: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 3 e (b) Zona 4.



(a)

(b)

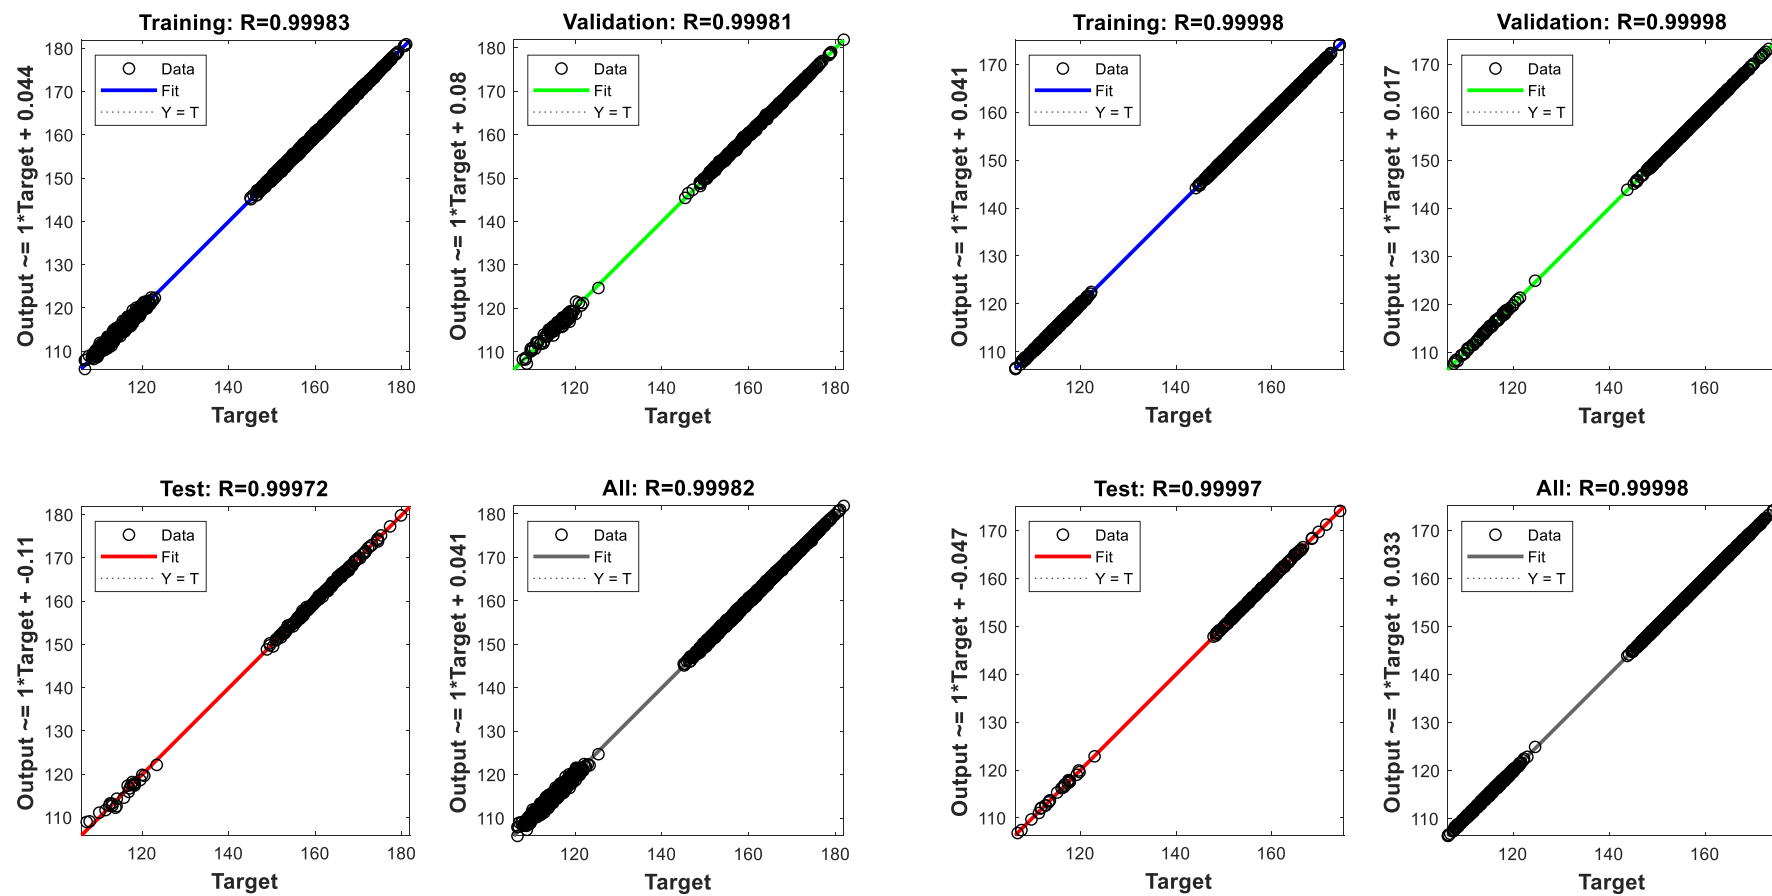
Figura 31: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 5 e (b) Zona 6.



(a)

(b)

Figura 32: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Zona 7 e (b) Zona 8.



(a)

(b)

Figura 33: Resultados do treinamento das redes neurais com 500 casos simulados: (a) Cortina de saída e (b) Saída da Estufa (Região 1).

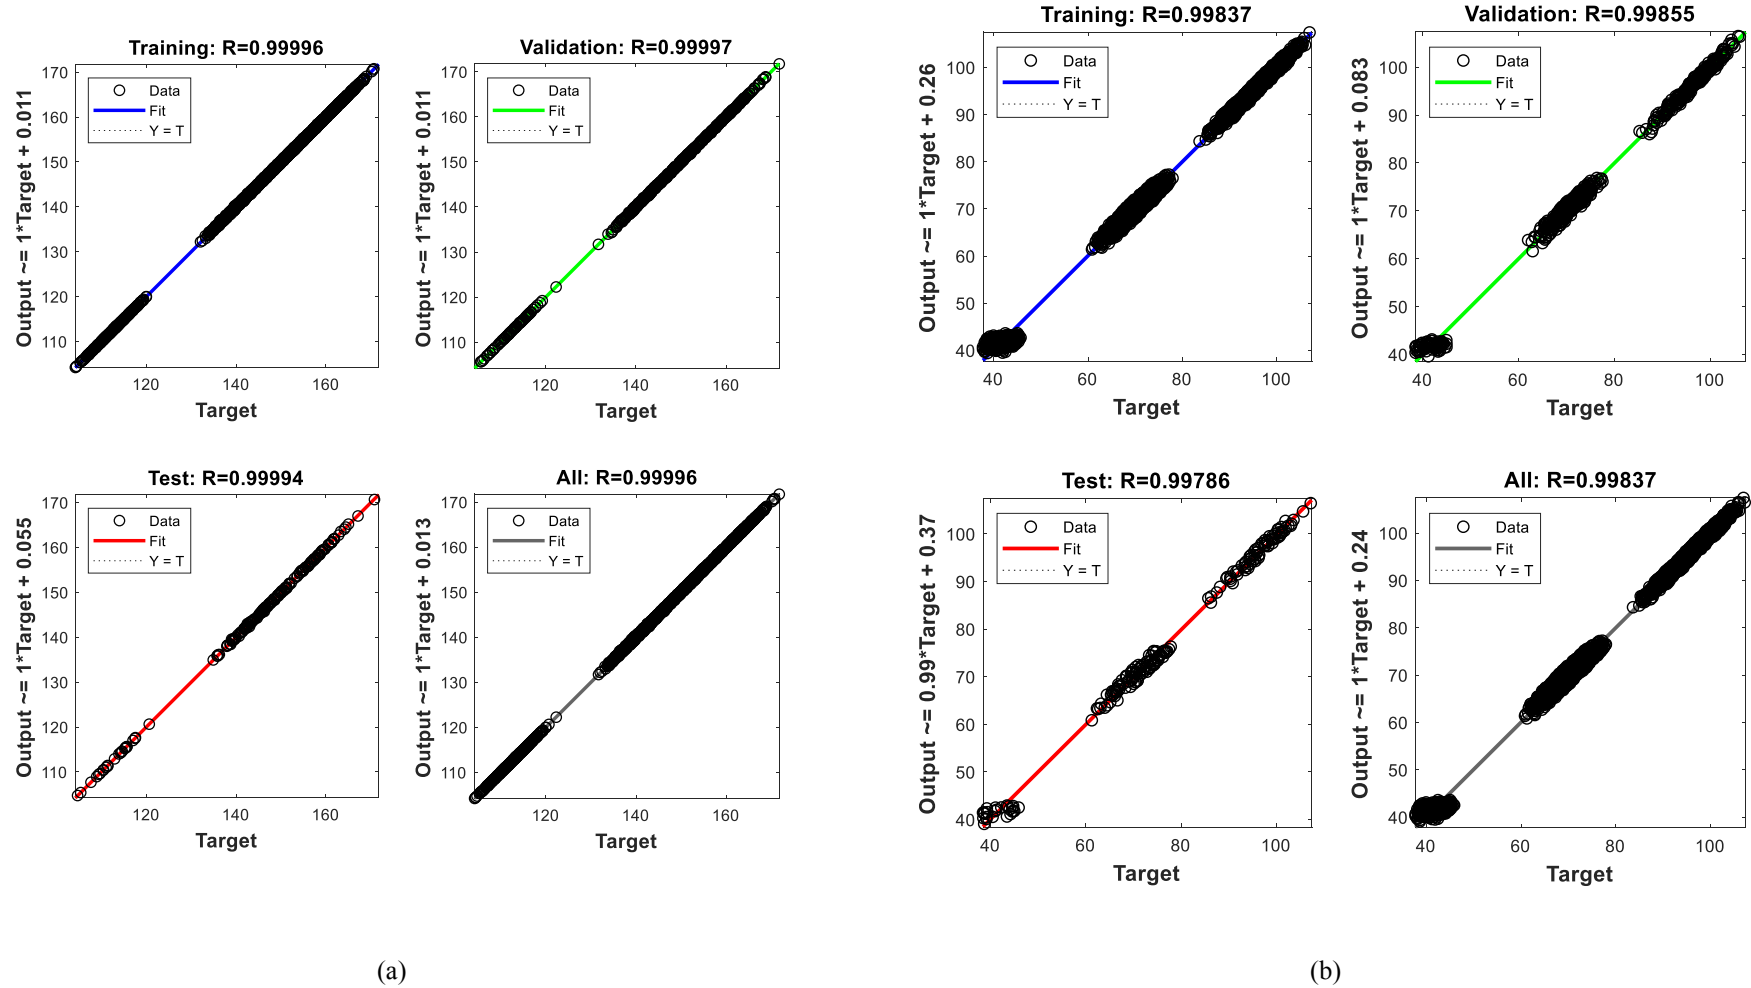
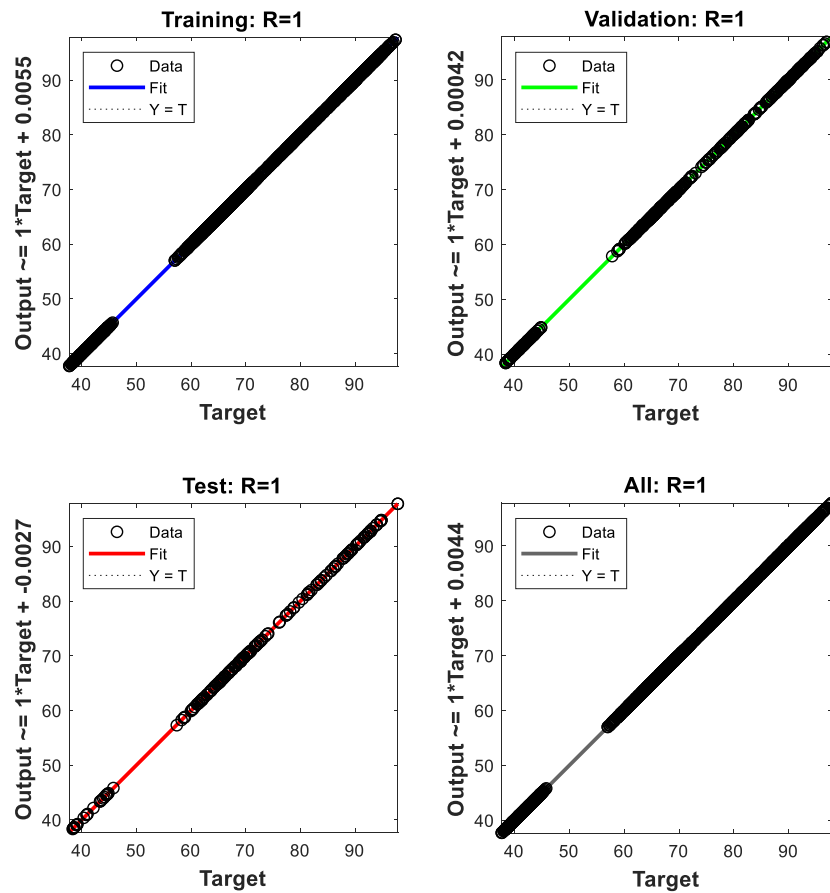


Figura 34: Resultados do treinamento das redes neurais com 500 casos simulados: Saída da Estufa - Região 2.



A Tabela 6 apresenta o resumo dos resultados das análises de performance das redes neurais com base em diferentes quantidades de épocas, onde foi feita a seleção da quantidade de épocas que apresentaram os melhores ajustes, com base no cálculo do erro médio quadrático (MSE). Os gráficos dos resultados são apresentados nas Figuras 37-39.

Para avaliar o desempenho do modelo neural obtido na predição das temperaturas das partes da carroceria (atuação como *Soft Sensor*), o modelo formado pelas redes neurais artificiais identificadas para as 13 zonas da estufa Elpo foi utilizado para simular o cenário do caso base (*setpoints* operacionais), utilizando os valores das variáveis de entrada do caso base.

Com isso, as Figura 35 e Figura 36 apresentam as comparações entre os valores de temperaturas das partes da carroceria do caso base e os valores preditos pelo modelo neural, onde é possível observar que as temperaturas das posições da carroceria preditas pelo modelo neural apresentam-se bem ajustadas aos valores de *setpoints* ao longo de todo o processo, conforme apresentado nas linhas na cor azul.

Tabela 6: Resultados para os testes com diferentes quantidades de épocas para as RNAs.

Zona	Quantidade de Épocas	Erro médio quadrático (MSE)
Entrada da estufa	1	0,165
Cortina de entrada	4	0,775
Zona 1	7	0,702
Zona 2	8	2,425
Zona 3	14	4,478
Zona 4	20	0,385
Zona 5	38	0,249
Zona 6	37	0,137
Zona 7	29	0,107
Zona 8	10	0,008
Cortina de saída	52	0,014
Saída da estufa (Região 1)	9	0,966
Saída da estufa (Região 2)	65	0,001

Figura 35: Resultados de predição: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.

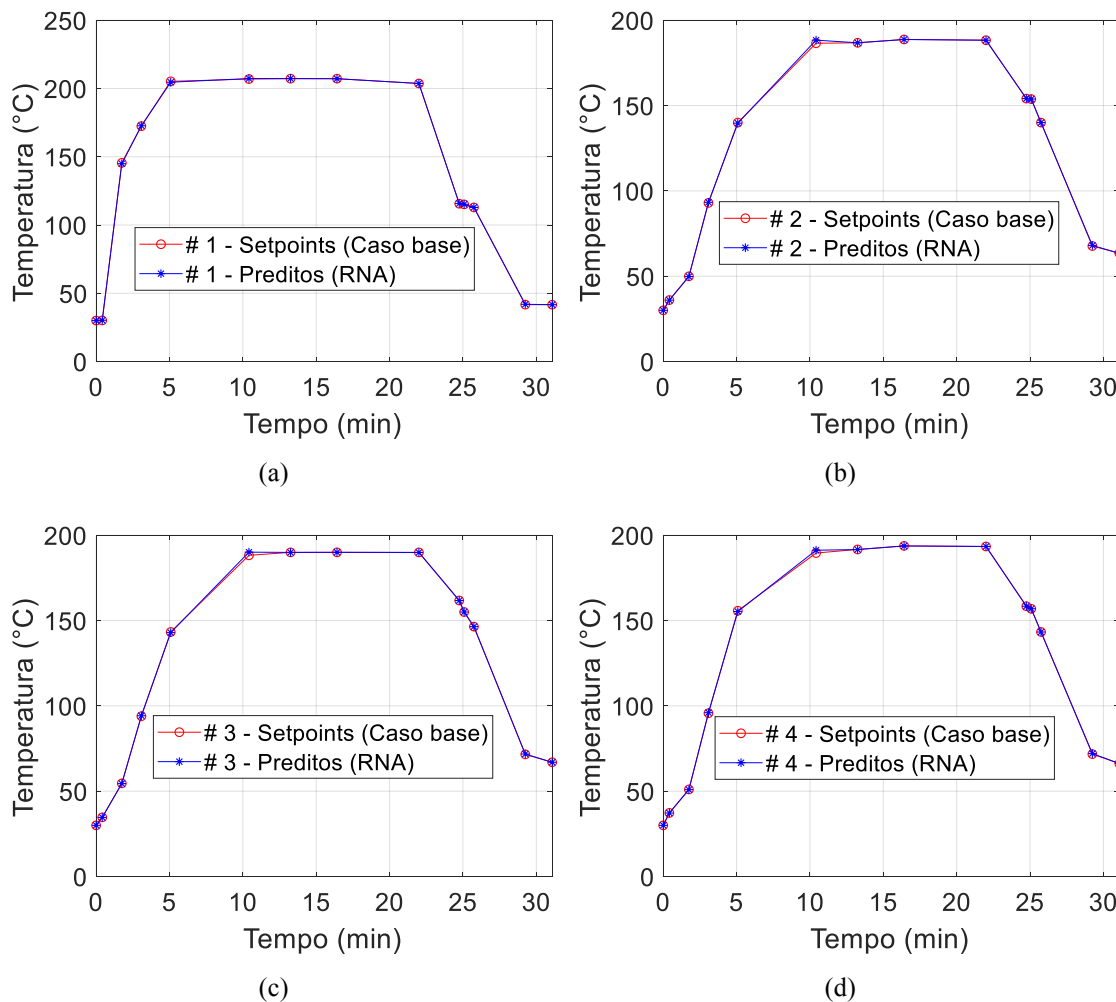
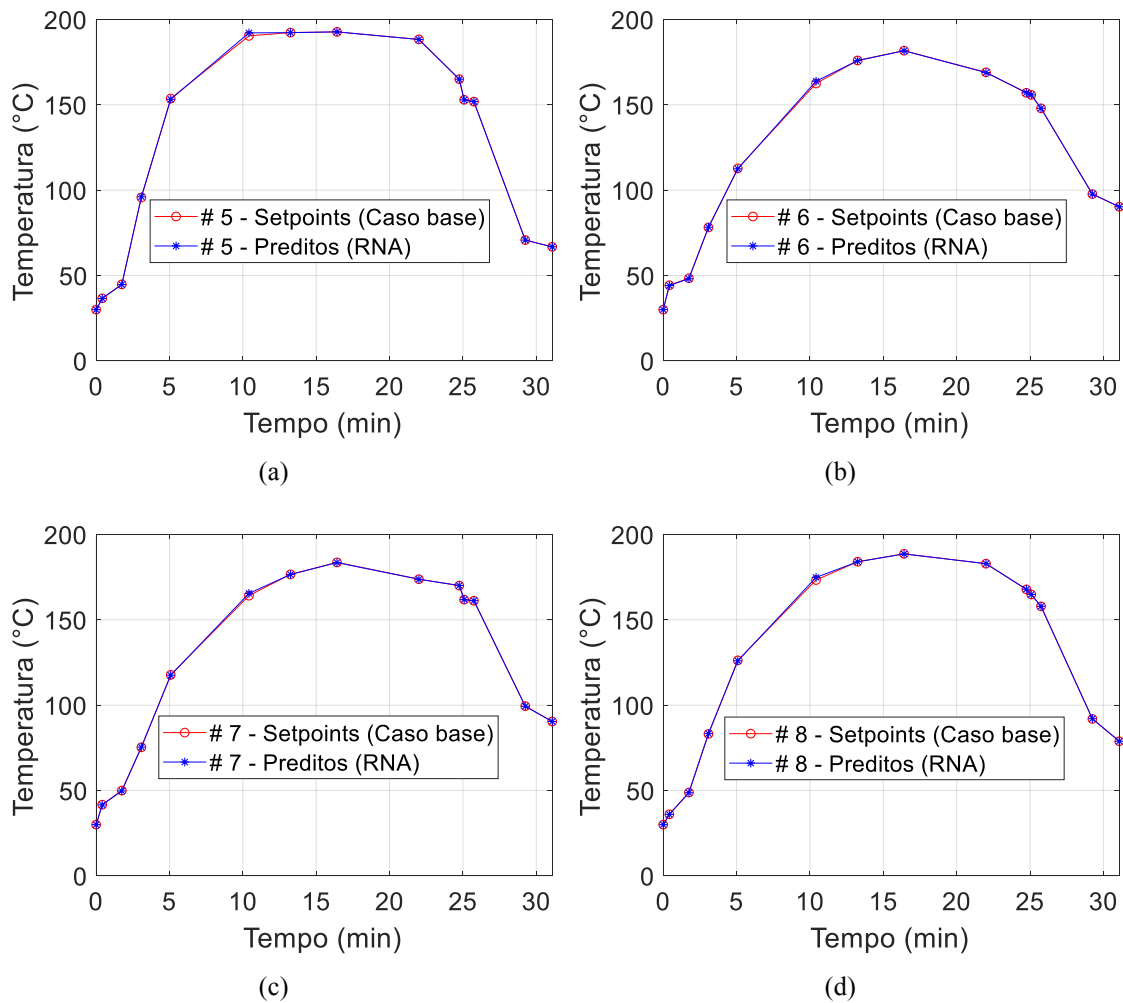


Figura 36: Resultados de predição: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.



Por fim, os modelos de redes neurais artificiais identificados para as 13 zonas da estufa *Elpo* foram utilizados para realizar o cálculo das temperaturas das partes da carroceria em cada zona, para os casos utilizados na validação (10% dos dados) e no teste (10% dos dados), totalizando 100 casos simulados. Posteriormente foi realizado o cálculo do erro médio absoluto percentual (MAPE) para cada uma das partes de medições, em cada zona, através da comparação entre os valores presentes na base de dados e os valores calculados pelas redes neurais, com base na utilização da Equação 27:


$$MAPE_k = \frac{\sum_{i=1}^q \left(\frac{|y_{i,k,j} - \widehat{y}_{i,k,j}|}{y_{i,k,j}} \right) \cdot 100}{q} \quad (27)$$

Onde q é a quantidade de simulações realizadas (100 casos simulados), $y_{i,k,j}$ são os valores de temperaturas presentes na base de dados, e $\widehat{y}_{i,k,j}$ são os valores de temperaturas preditos pelos modelos de redes neurais artificiais, para cada k posição de medição, em cada zona j , com j variando até o total de zonas m (13 zonas). É possível observar na Tabela 7 que em todas as zonas da estufa, as predições das temperaturas das partes da carroceria apresentaram valores de MAPE menores que 3,6155%, o que reafirma os ótimos desempenhos das redes neurais artificiais obtidas.


Tabela 7: Erro médio absoluto percentual (MAPE) dos valores calculados pelas RNAs para cada uma das partes de medições, em cada zona.

	Entrada da estufa	Cortina de entrada	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 6	Zona 7	Zona 8	Cortina de saída	Saída da estufa (região 1)	Saída da estufa (região 2)
Temperatura do Ar próxima ao capô	0,2621	1,5634	0,6109	1,1282	0,2262	0,0548	0,0449	0,0460	0,5576	0,1212	0,0321	3,6155	0,0316
Teto dianteiro esquerdo	0,6386	0,5086	0,8450	0,9366	1,1350	0,0568	0,1535	0,0333	0,1862	0,0477	0,1108	1,2376	0,0605
Teto dianteiro direito	0,5181	0,6665	0,7783	0,9711	1,1246	0,1037	0,0346	0,0476	0,1587	0,0219	0,0563	1,1307	0,0583
Meio teto esquerdo	0,7296	0,5009	0,8685	1,1261	0,9616	0,1225	0,2159	0,0489	0,1701	0,0376	0,0982	1,1008	0,0521
Meio teto direito	0,6859	0,3575	0,9592	1,0999	1,0646	0,1176	0,0601	0,0823	0,1128	0,0671	0,1029	1,2027	0,0673
Coluna do meio esquerda	1,2152	0,2850	0,6978	0,7439	1,0195	0,4216	0,2881	0,3351	0,0888	0,0119	0,0547	0,5077	0,0335
Coluna do meio direita	1,0600	0,3910	0,6245	0,8663	0,9742	0,3948	0,3624	0,2489	0,0380	0,0572	0,0692	0,5677	0,0378
Porta dianteira esquerda	0,6426	0,4645	0,7429	0,8738	1,0469	0,4023	0,3125	0,1211	0,0820	0,0099	0,0387	0,6563	0,0286

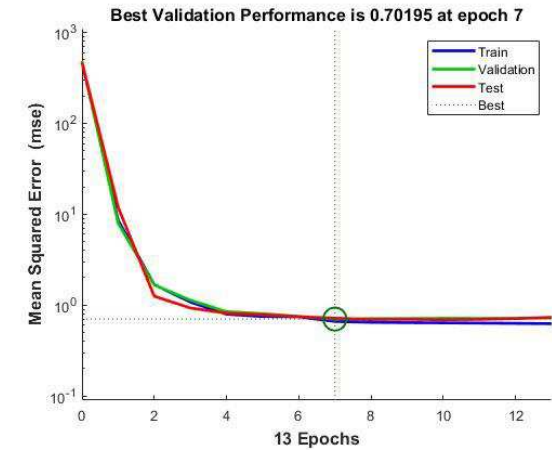
Figura 37: Análise de performance a partir da quantidade de épocas: (a) Entrada da Estufa, (b) Cortina de Entrada, (c) Zona 1, (d) Zona 2, (e) Zona 3 e (f) Zona 4.




(a)




(b)




(c)



(d)

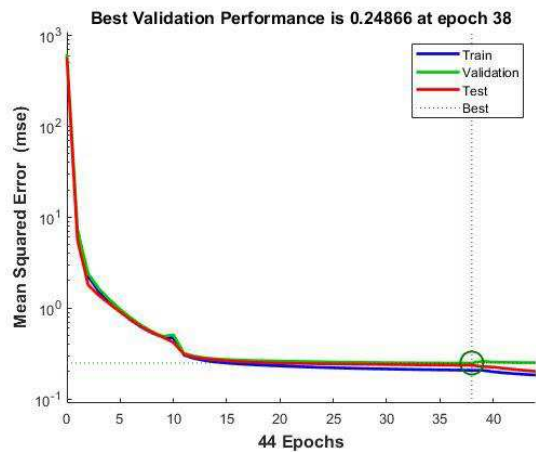


(e)




(f)


Figura 38: Análise de performance a partir da quantidade de épocas: (a) Zona 5, (b) Zona 6, (c) Zona 7, (d) Zona 8, (e) Cortina de Saída e (f) Saída - Região 1.




(a)




(b)




(c)



(d)

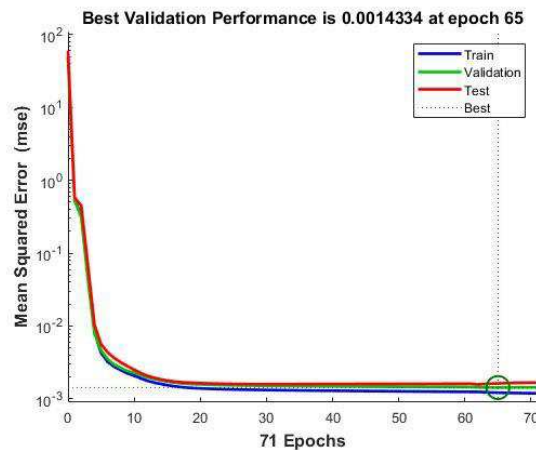


(e)



(f)

Figura 39: Análise de performance a partir da quantidade de épocas: Saída - Região 2.



5.3 ANÁLISE DO DESEMPENHO DO SISTEMA DE CONTROLE PREDITIVO NEURAL (NNPC)

Após a identificação e validação dos modelos de redes neurais artificiais para as 13 zonas da estufa *Elpo*, a estratégia de Controle Preditivo Neural (NNPC) foi implementada conforme descrito no item 4.3. Para avaliar o desempenho do controlador NNPC mediante aplicações de distúrbios nas variáveis manipuladas, velocidade do transportador da estufa *Elpo* ($x_{1,j}$) e temperaturas nas zonas da estufa *Elpo* ($x_{2,j}$), neste item foram realizadas simulações de quatro diferentes cenários operacionais da estufa *Elpo*.

Os dois primeiros cenários, que constituem a estratégia de controle 1 (NNPC-1), consistiram na aplicação de distúrbios do tipo “degrau” na velocidade do transportador da estufa *Elpo* (variáveis manipuladas $x_{1,j}$), com o otimizador implementado no sistema de controle neural preditivo (NNPC-1) irá atuar na definição de novos valores de temperaturas das zonas (variáveis manipuladas $x_{2,j}$), capazes de manter as temperaturas das posições da carroceria (variáveis controladas) com valores próximos aos seus *setpoints*.

Por sua vez, a estratégia de controle 2 (NNPC-2) é analisada no terceiro e quarto cenário, que consistiram na aplicação de distúrbios do tipo “degrau” nas temperaturas das zonas da estufa *Elpo* (variáveis manipuladas $x_{2,j}$), com o otimizador do controlador NNPC-2 atuando na definição de um único valor (valor ótimo global) de velocidade do transportador nas zonas (variáveis manipuladas $x_{1,j}$), visto que não é recomendável a nível operacional, realizar modificações sucessivas na velocidade do transportador durante o processo de secagem e cura, uma vez que tais modificações poderiam impactar nos perfis de temperatura das carrocerias seguintes.

Desta forma, os seguintes cenários foram simulados para avaliar o desempenho das duas estratégias do sistema de controle neural preditivo:

- *NNPC-1:*
 - *Cenário 1 - Distúrbio de +5% na velocidade do transportador;*
 - *Cenário 2 - Distúrbio de -5% na velocidade do transportador;*
- *NNPC-2*
 - *Cenário 3 - Distúrbio de +5% nas temperaturas do ar nas zonas;*
 - *Cenário 4 - Distúrbio de -5% nas temperaturas do ar nas zonas;*

5.3.1 AVALIAÇÃO DOS MÉTODOS DE OTIMIZAÇÃO DO CONTROLADOR NNPC

Antes de iniciar os testes de avaliação do desempenho das estratégias do sistema de controle preditivo neural, para prosseguir com a resolução do problema de otimização multi-objetivo e multi-variável implementado no sistema de controle NNPC, inicialmente foi realizada uma análise do método de otimização mais adequado para a determinação dos valores das variáveis manipuladas $x_{1,j}$ e $x_{2,j}$ que minimizam a função objetivo do controlador.

Para tanto, levando em consideração os requisitos do problema de controle da estufa *Elpo*, um termo adicional foi introduzido na função objetivo J do controle GPC (Equação 14), para minimizar o valor absoluto da variável controlada, conforme descrito na Equação (28):

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_U} (\Delta u(t+j))^2 + w x_{1,j} x_{2,j} \quad (28)$$

Onde w é um coeficiente de ponderação usado para representar a contribuição das restrições do problema na função objetivo geral; ou seja, o termo $w x_{1,j} x_{2,j}$ representa uma penalidade para afastar a função objetivo do ótimo global. O valor de w foi determinado empiricamente para forçar o método de otimização a sempre buscar valores positivos (restrições) para as variáveis de decisão (temperatura da zona ou velocidade da esteira), com base na seguinte estratégia:

- Para valores negativos das variáveis de decisão, considera-se o termo $w x_{1,j} x_{2,j}$ referente à penalidade.

- Para valores positivos das variáveis de decisão, o termo $w x_{1,j} x_{2,j}$ é desconsiderado na função objetivo.

Portanto, a função objetivo revisada (Equação 28) consiste em três componentes: o primeiro componente visa minimizar o erro, o segundo componente visa minimizar a variação da variável manipulada (esforço) e o terceiro componente representa uma penalidade para forçar o método de otimização a sempre buscar valores positivos (restrições) para as variáveis de decisão (temperatura da zona ou velocidade da esteira).

Posteriormente, foram realizadas as simulações avaliando o desempenho dos métodos de otimização. Neste momento foram avaliados três métodos, dos quais os dois primeiros são bastante conhecidos (*Simplex Nelder-Mead* e *Levenberg-Marquardt*), enquanto o terceiro (Otimização de Colônia de Formigas – ACO) também foi avaliado por já ter sido utilizado (e com êxito) em outros problemas de otimização de estufas automotivas (Xiao *et al.* 2006).

A Tabela 8 apresenta a comparação dos resultados obtidos nas simulações utilizando os três métodos de otimização, para o *Cenário 1 - Distúrbio de +5% na velocidade do transportador*.

É possível verificar que a utilização dos métodos *Simplex Nelder-Mead* e *Levenberg-Marquardt* resultaram na obtenção de valores que resultam em comportamentos bruscos nas variáveis manipuladas (temperatura nas zonas $x_{2,j}$), com as soluções obtidas convergindo para valores distantes das faixas operacionais e dos limites de treinamento das variáveis $x_{1,j}$ e $x_{2,j}$ ($\pm 10\%$ dos valores do caso base), conforme pode ser observado nos valores em destaque (vermelho). Já a aplicação do método de Otimização de Colônia de Formigas (ACO) forneceu resultados satisfatórios, com as variáveis manipuladas apresentando valores coerentes e dentro dos limites de treinamento das variáveis $x_{1,j}$ e $x_{2,j}$.

Isso deve-se ao fato de que os métodos *Simplex Nelder-Mead* e *Levenberg-Marquardt* não apresentam na formulação de seus algoritmos os limites do ambiente de busca (*bounds*), diferentemente do método de Otimização de Colônia de Formigas (ACO), o qual tem na formulação de seu algoritmo a inclusão dos limites do ambiente de busca, os quais neste trabalho são necessariamente os limites de treinamento das variáveis $x_{1,j}$ e $x_{2,j}$.

Com isso, para tentar sanar os problemas oriundos da falta dos *bounds* para os métodos *Simplex Nelder-Mead* e *Levenberg-Marquardt*, foi testada uma nova

modificação na função objetivo J do controlador (Equação 28), com o objetivo de que a nova função levasse em consideração os limites de treinamento, conforme a seguinte equação:

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_U} (\Delta u(t+j))^2 + w x_{1,j} x_{2,j} + c_1 lb + c_2 ub \quad (29)$$

Onde lb e ub são respectivamente os limites de treinamento inferior (*lower bounds*) e superior (*upper bounds*) das variáveis $x_{1,j}$ e $x_{2,j}$, e c_1 e c_2 são coeficientes de ponderação que representam a influência dos limites na função objetivo. Os valores dos coeficientes c_1 e c_2 são determinados empiricamente, com o objetivo para forçar o método de otimização a buscar sempre valores para as variáveis de decisão que fiquem dentro dos limites de treinamento (lb e ub).

Neste sentido, para valores das variáveis $x_{1,j}$ e $x_{2,j}$ que fiquem fora dos limites lb e ub , os valores dos coeficientes c_1 e c_2 são suficientemente altos para afastar a função objetivo do valor atual (mesmo que este seja um valor mínimo), enquanto para valores de $x_{1,j}$ e $x_{2,j}$ dentro dos limites lb e ub , os coeficientes c_1 e c_2 são suficientemente pequenos, sendo desprezados na Equação 29, e assim, não interferindo no valor da função objetivo.

Todavia, após realizar as simulações com a função objetivo apresentada na Equação 29, verificou-se que para os métodos *Simplex Nelder-Mead* e *Levenberg-Marquardt*, as soluções obtidas pelo controlador convergiram para os limites de treinamento das variáveis manipuladas ($\pm 10\%$ dos valores do caso base) na maioria das zonas, conforme apresentado na Tabela 9.

Com isso, conclui-se que mesmo incluindo na função objetivo as restrições para os limites de treinamento, as resoluções com os métodos *Simplex Nelder-Mead* e *Levenberg-Marquardt* não apresentaram resultados satisfatórios, indicando que para o problema de otimização do controlador NNPC desenvolvido para a estufa *Elpo*, o ideal é utilizar um método que tenha a utilização dos limites do ambiente de busca diretamente em seu algoritmo de resolução, e não apenas na função objetivo.

Por fim a Tabela 10 apresenta os valores de erro médio absoluto percentual (MAPE) e de erro médio absoluto (MAE) para cada uma das partes de medições, calculados através da comparação dos valores de *setpoints* das temperaturas das partes

(objetivados) e os valores de temperaturas obtidos através da utilização do controlador NNPC, com a utilização dos três métodos, conforme Equações 30 e 31.

$$MAPE_k = \frac{\sum_{i=1}^m \left(\frac{|y_{k,i} - \widehat{y}_{k,i}|}{y_{k,i}} \right) \cdot 100}{m} \quad (30)$$

$$MAE_k = \frac{\sum_{i=1}^m |y_{k,i} - \widehat{y}_{k,i}|}{m} \quad (31)$$

Onde m é a quantidade de zonas (13 zonas), $y_{k,i}$ são os valores objetivados de temperaturas das partes da carroceria (*setpoints*) e $\widehat{y}_{k,i}$ são os valores de temperaturas obtidos através da utilização do controlador NNPC, ambos para cada k posição de medição (8 partes de medições), e para cada zona m (13 zonas).

É possível observar que o controlador NNPC utilizando o método ACO para a resolução da função objetivo (controle GPC) apresentou valores de MAPE e MAE menores do que os casos com a utilização do método de *Levenberg-Marquardt*, com valores de MAPE abaixo de 1,4439 % e de MAE abaixo de 2,4429.

Já quando comparado aos resultados do método *Simplex Nelder-Mead*, observa-se que os valores de MAPE e MAE são iguais para os dois casos, porém, como o controlador utilizando o *Simplex Nelder-Mead* encontrou valores distantes das faixas operacionais e dos limites de treinamento ($\pm 10\%$ dos valores do caso base), os resultados obtidos não podem ser considerados coerentes, pois não refletem soluções reais.

Desta forma, após analisar tanto a capacidade de obtenção de resultados coerentes e dentro dos limites de treinamento (*lower bounds* e *upper bounds*), quanto os valores de MAPE e MAE, para a resolução do problema de otimização implementado no controlador neural preditivo utilizou-se o método de otimização de colônia de formigas (ACO), utilizando como função objetivo J a que foi apresentada na Equação 28.

Tabela 8: Condições operacionais da estufa Elpo: Caso base x Cenário 1 com controlador NNPC utilizando 3 métodos de otimização (Função objetivo da Equação 28).

Zona	Caso base		Cenário 1 com controlador NNPC Método <i>Simplex Nelder-Mead</i>		Cenário 1 com controlador NNPC Método <i>Levenberg-Marquardt</i>		Cenário 1 com controlador NNPC Método ACO	
	Temperatura das zonas (°C)	Velocidade do transportador (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)
Entrada da estufa	40	4,8	40,00	5,04	40,00	5,04	43,31	5,04
Cortina de entrada	73	4,8	177,91	5,04	177,91	5,04	79,57	5,04
Zona 1	200	4,8	321,33	5,04	322,31	5,04	217,64	5,04
Zona 2	220	4,8	228,30	5,04	223,14	5,04	217,80	5,04
Zona 3	240	4,8	241,01	5,04	249,32	5,04	257,67	5,04
Zona 4	235	4,8	272,73	5,04	273,61	5,04	255,72	5,04
Zona 5	220	4,8	208,74	5,04	202,79	5,04	213,00	5,04
Zona 6	215	4,8	211,07	5,04	226,19	5,04	207,77	5,04
Zona 7	215	4,8	209,61	5,04	189,80	5,04	207,77	5,04
Zona 8	175	4,8	172,53	5,04	177,21	5,04	159,25	5,04
Cortina de saída	72	4,8	98,74	5,04	104,88	5,04	65,65	5,04
Saída da estufa (Região 1)	40	4,8	32,66	5,04	32,61	5,04	36,40	5,04
Saída da estufa (Região 2)	40	4,8	36,59	5,04	36,47	5,04	36,55	5,04

Tabela 9: Condições operacionais da estufa Elpo: Caso base x Cenário 1 com controlador NNPC utilizando 3 métodos de otimização (Função objetivo da Equação 29).

Zona	Caso base		Cenário 1 com controlador NNPC Método <i>Simplex Nelder-Mead</i>		Cenário 1 com controlador NNPC Método <i>Levenberg-Marquardt</i>		Cenário 1 com controlador NNPC Método <i>ACO</i>	
	Temperatura das zonas (°C)	Velocidade do transportador (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)
Entrada da estufa	40	4,8	40,00	5,04	40,00	5,04	43,31	5,04
Cortina de entrada	73	4,8	80,30	5,04	80,30	5,04	79,57	5,04
Zona 1	200	4,8	180,00	5,04	182,56	5,04	217,64	5,04
Zona 2	220	4,8	198,00	5,04	198,00	5,04	217,80	5,04
Zona 3	240	4,8	264,00	5,04	264,00	5,04	257,67	5,04
Zona 4	235	4,8	211,50	5,04	211,50	5,04	255,72	5,04
Zona 5	220	4,8	203,98	5,04	198,00	5,04	213,00	5,04
Zona 6	215	4,8	236,50	5,04	236,50	5,04	207,77	5,04
Zona 7	215	4,8	193,50	5,04	193,50	5,04	207,77	5,04
Zona 8	175	4,8	192,50	5,04	192,50	5,04	159,25	5,04
Cortina de saída	72	4,8	79,20	5,04	79,20	5,04	65,65	5,04
Saída da estufa (Região 1)	40	4,8	36,00	5,04	37,12	5,04	36,40	5,04
Saída da estufa (Região 2)	40	4,8	36,00	5,04	36,00	5,04	36,55	5,04

Tabela 10: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 1 com controlador NNPC utilizando 3 métodos de otimização (Função objetivo da Equação 28).

Posição de medição	Cenário 1 com controlador NNPC Método <i>Simplex Nelder-Mead</i>		Cenário 1 com controlador NNPC Método <i>Levenberg-Marquardt</i>		Cenário 1 com controlador NNPC Método ACO	
	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)
#1 Temperatura do ar próxima ao capô	1,1509	1,4725	6,2756	10,2954	1,4439	2,4429
#2 Teto dianteiro esquerdo	0,3844	0,2703	4,1743	5,0958	0,6346	0,5757
#3 Teto dianteiro direito	0,5780	0,4025	4,4961	5,5814	0,5903	0,5627
#4 Meio teto esquerdo	0,4601	0,4732	4,3657	5,7556	0,7477	0,8190
#5 Meio teto direito	0,6308	0,5095	4,3914	5,7701	0,6317	0,6755
#6 Coluna do meio esquerda	0,7588	0,7137	2,4902	2,8142	0,8091	0,7979
#7 Coluna do meio direita	0,4820	0,4682	2,6393	3,0176	0,7143	0,6619
#8 Porta dianteira esquerda	0,5541	0,4473	2,8119	3,0298	0,6099	0,5525

5.3.2 ESTRATÉGIA DE CONTROLE 1 (NNPC-1)

5.3.2.1. CENÁRIO 1 - DISTÚRBO DE +5% NA VELOCIDADE DO TRANSPORTADOR

As Figura 40 e Figura 41 apresentam os comportamentos das temperaturas das posições na carroceria (variáveis controladas) para o *Cenário 1 - Distúrbio de +5% na velocidade do transportador*. Analisando os resultados da simulação com a utilização do controlador neural preditivo neural, observa-se que após a definição dos novos valores de temperaturas das zonas pelo controlador, as temperaturas das posições da carroceria são controladas próximas aos seus valores de *setpoints* ao longo de todo o processo, conforme apresentado nas linhas tracejadas na cor azul.

Figura 40: Desempenho do controlador NNPC no Cenário 1 - Distúrbio de +5% na velocidade do transportador: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.

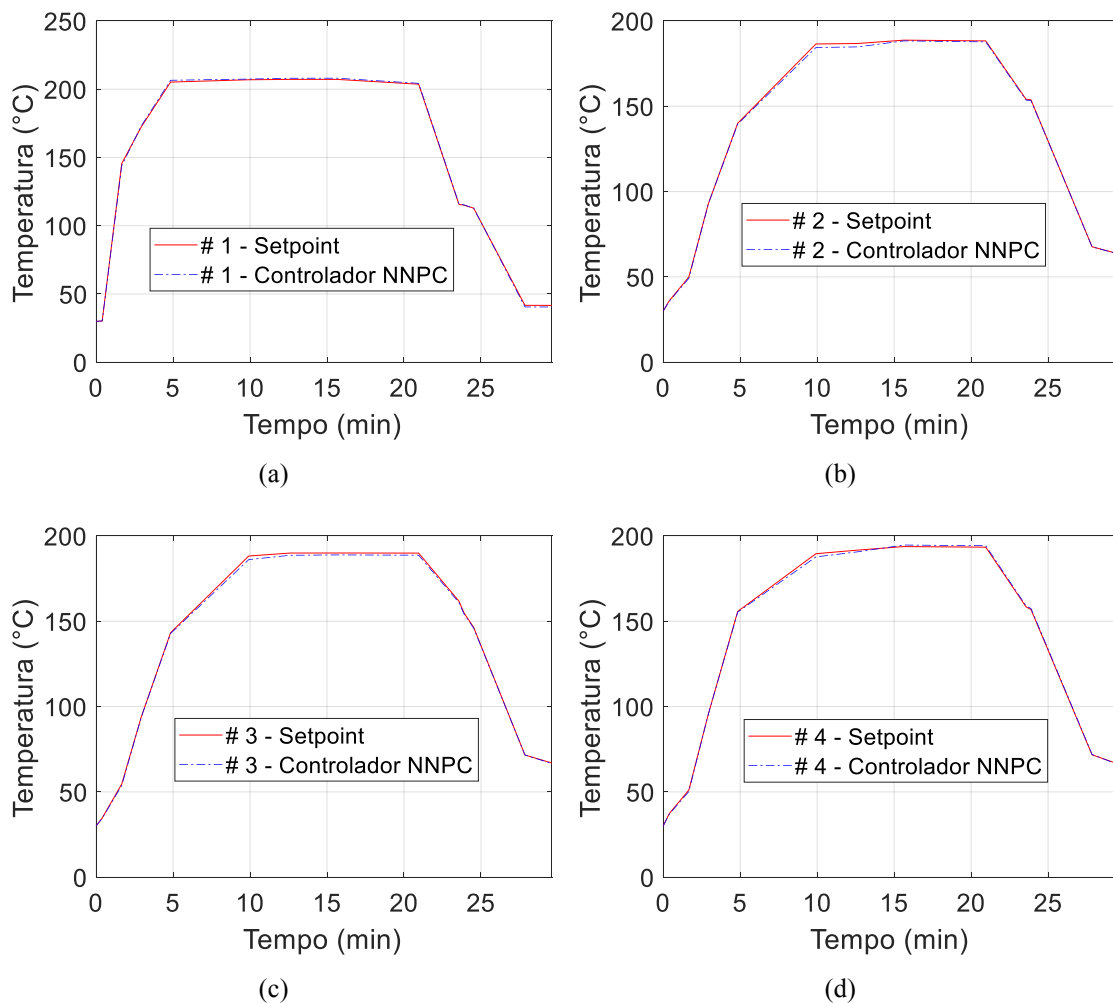
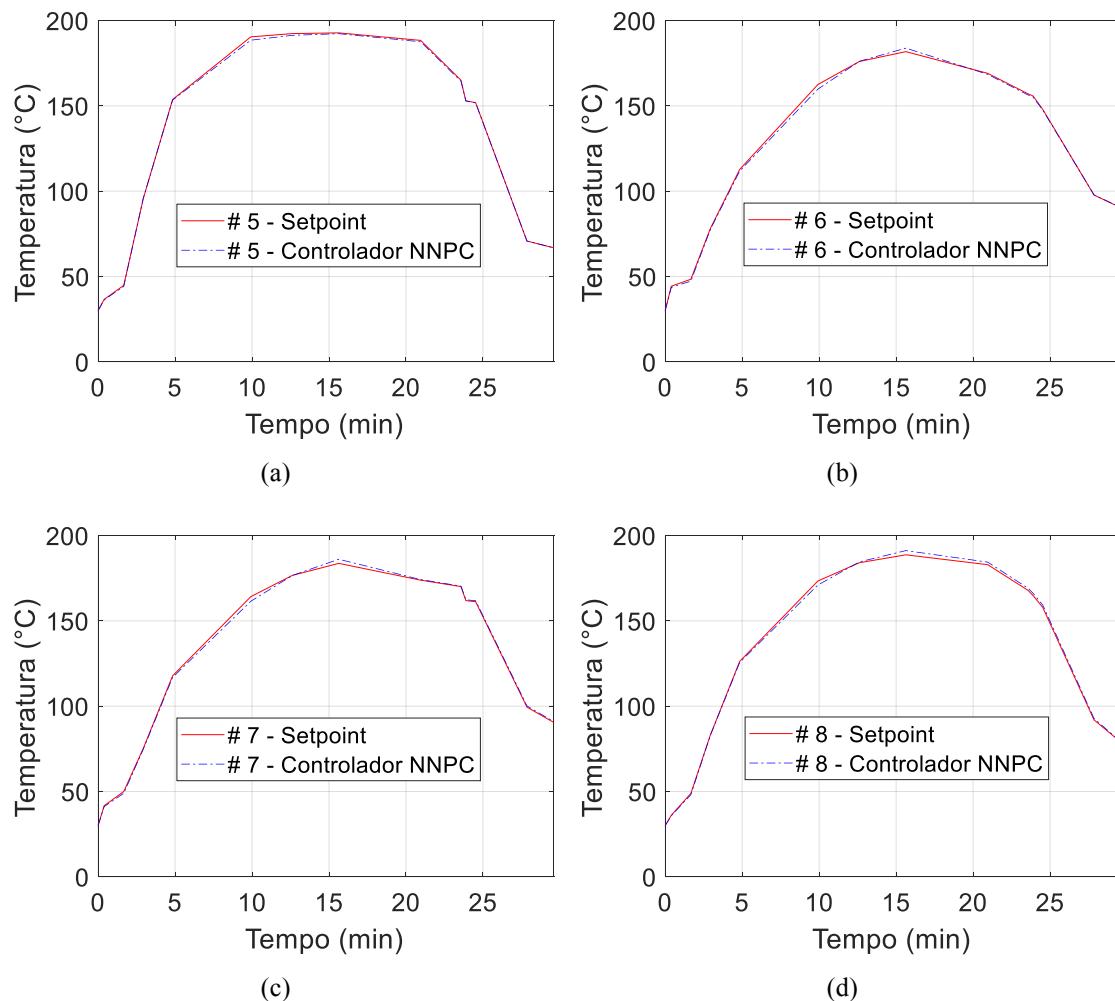


Figura 41: Desempenho do controlador NNPC no Cenário 1 - Distúrbio de +5% na velocidade do transportador: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.



A Tabela 11 apresenta a comparação entre as condições operacionais da estufa Elpo para o caso base e para o Cenário 1 com controlador NNPC (*Distúrbio de +5% na velocidade do transportador*), onde é possível verificar os novos valores de temperaturas das zonas, obtidos pelo otimizador do controlador neural preditivo.

Por fim, a Tabela 12 apresenta os valores de erro médio absoluto percentual (MAPE) e de erro médio absoluto (MAE) para cada uma das partes de medições, calculados através da comparação dos valores de *setpoints* das temperaturas das partes (objetivados) e os valores de temperaturas obtidos através da utilização do controlador NNPC, conforme Equações 30 e 31, onde é possível observar que o controlador apresentou resultados bastante satisfatórios, com valores de MAPE abaixo de 1,4439 % e de MAE abaixo de 2,4429, os quais foram verificados na posição #1, Temperatura do ar próxima ao capô.

Tabela 11: Condições operacionais da estufa Elpo: Caso base x Cenário 1 com controlador NNPC - Distúrbio de +5% na velocidade do transportador.

Zona	Caso base		Cenário 1 com controlador NNPC	
	Temperatura das zonas (°C)	Velocidade do transportador (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio +5% (m/min)
Entrada da estufa	40	4,8	43,31	5,04
Cortina de entrada	73	4,8	79,57	5,04
Zona 1	200	4,8	217,64	5,04
Zona 2	220	4,8	217,80	5,04
Zona 3	240	4,8	257,67	5,04
Zona 4	235	4,8	255,72	5,04
Zona 5	220	4,8	213,00	5,04
Zona 6	215	4,8	207,77	5,04
Zona 7	215	4,8	207,77	5,04
Zona 8	175	4,8	159,25	5,04
Cortina de saída	72	4,8	65,65	5,04
Saída da estufa (Região 1)	40	4,8	36,40	5,04
Saída da estufa (Região 2)	40	4,8	36,55	5,04

Tabela 12: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 1 com controlador NNPC - Distúrbio de +5% na velocidade do transportador.

Posição de medição	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)
#1 Temperatura do ar próxima ao capô	1,4439	2,4429
#2 Teto dianteiro esquerdo	0,6346	0,5757
#3 Teto dianteiro direito	0,5903	0,5627
#4 Meio teto esquerdo	0,7477	0,8190
#5 Meio teto direito	0,6317	0,6755
#6 Coluna do meio esquerda	0,8091	0,7979
#7 Coluna do meio direita	0,7143	0,6619
#8 Porta dianteira esquerda	0,6099	0,5525

5.3.2.2. CENÁRIO 2 - DISTÚRBO DE -5% NA VELOCIDADE DO TRANSPORTADOR

Para o segundo cenário, *Cenário 2 - Distúrbio de -5% na velocidade do transportador*, os comportamentos das temperaturas das posições da carroceria ao longo das zonas (variáveis controladas) são apresentados nas Figura 42 e Figura 43.

De forma análoga ao cenário anterior, a utilização do NNPC possibilitou controlar as temperaturas das posições da carroceria próximas aos seus valores de *setpoints* ao longo de todo o tempo de simulação, após as definições das temperaturas ótimas das zonas

(variáveis manipuladas $x_{2,j}$), conforme pode ser observado nas linhas tracejadas na cor azul.

É importante ressaltar que, uma vez que os *setpoints* operacionais para as temperaturas das partes da carroceria permanecem fixos, e o controlador NNPC-1 demonstra excelente desempenho nos cenários 1 e 2, as distribuições dos gráficos mostrados nas Figuras 40-43 são semelhantes, havendo apenas uma mudança no eixo x (tempo), devido às aplicações de $\pm 5\%$ na velocidade do transportador.

Figura 42: Desempenho do controlador NNPC no Cenário 2 - Distúrbio de -5% na velocidade do transportador: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.

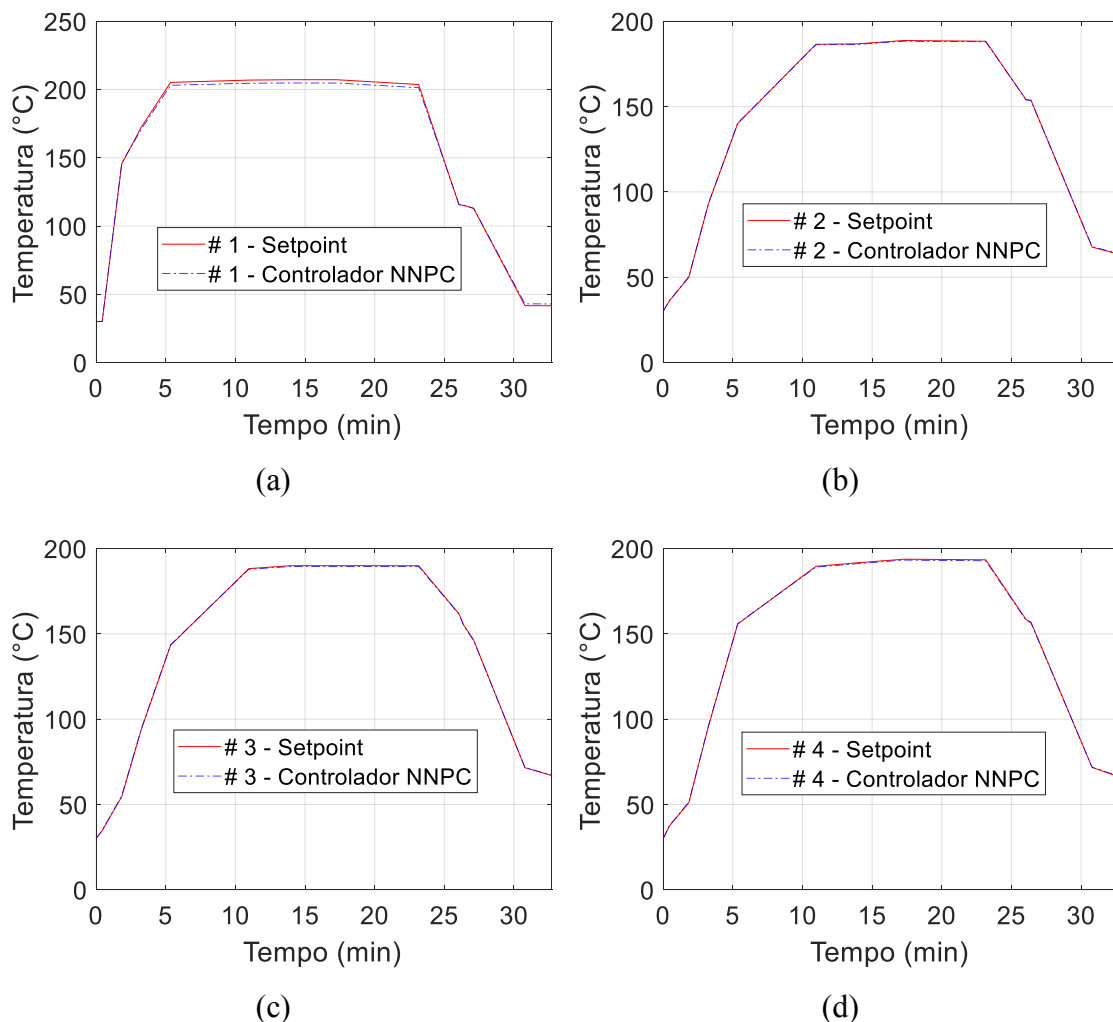



Figura 43: Desempenho do controlador NNPC no Cenário 2 - Distúrbio de -5% na velocidade do transportador: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.



Com isso, a Tabela 13 apresenta a comparação entre as condições operacionais do caso base e as condições operacionais do *Cenário 2* com controlador NNPC (*Distúrbio de -5% na velocidade do transportador*), onde é possível verificar os valores de temperaturas ótimas das zonas que foram definidos de forma preditiva pelo controlador neural NNPC.

Por fim a Tabela 14 apresenta os valores de erro médio absoluto percentual (MAPE) e de erro médio absoluto (MAE) para a aplicação do controlador NNPC em cada uma das variáveis controladas, onde conclui-se mais uma vez o que o controlador neural preditivo apresentou resultados eficientes, com valores de MAPE e MAE abaixo de 1,0008% e 1,2050, respectivamente (#1 Temperatura do ar próxima ao capô).

Tabela 13: Condições operacionais da estufa Elpo: Caso base x Cenário 2 com controlador NNPC - Distúrbio de -5% na velocidade do transportador.

Zona	Caso base		Cenário 2 com controlador NNPC	
	Temperatura das zonas (°C)	Velocidade do transportador (m/min)	Temperatura das zonas (°C)	Velocidade do transportador: Distúrbio -5% (m/min)
Entrada da estufa	40	4,8	38,58	4,56
Cortina de entrada	73	4,8	67,23	4,56
Zona 1	200	4,8	198,00	4,56
Zona 2	220	4,8	211,40	4,56
Zona 3	240	4,8	218,40	4,56
Zona 4	235	4,8	221,97	4,56
Zona 5	220	4,8	221,40	4,56
Zona 6	215	4,8	221,06	4,56
Zona 7	215	4,8	197,60	4,56
Zona 8	175	4,8	190,43	4,56
Cortina de saída	72	4,8	65,52	4,56
Saída da estufa (Região 1)	40	4,8	43,60	4,56
Saída da estufa (Região 2)	40	4,8	43,60	4,56

Tabela 14: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 2 com controlador NNPC - Distúrbio de -5% na velocidade do transportador.

Posição de medição	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)
#1 Temperatura do ar próxima ao capô	1,0008	1,2050
#2 Teto dianteiro esquerdo	0,2982	0,3357
#3 Teto dianteiro direito	0,3706	0,4092
#4 Meio teto esquerdo	0,4717	0,5978
#5 Meio teto direito	0,3922	0,3622
#6 Coluna do meio esquerda	0,5715	0,6297
#7 Coluna do meio direita	0,8176	0,9835
#8 Porta dianteira esquerda	0,8087	1,0403

5.3.3 ESTRATÉGIA DE CONTROLE 2 (NNPC-2)

5.3.3.1. CENÁRIO 3 - DISTÚRBIOS DE + 5% NAS TEMPERATURAS NAS ZONAS


Os resultados do terceiro cenário, que consistiu na aplicação de um distúrbio com amplitude positiva de 5% nas temperaturas das zonas (variáveis manipuladas $x_{2,j}$) são apresentados na Figura 44 e Figura 45. Analisando os resultados verifica-se que os desvios nas temperaturas das variáveis controladas foram mais acentuados, quando comparados aos desvios observados no *Cenário 2 - Distúrbio de -5% na velocidade do*

transportador, indicando que os distúrbios de +5% nas temperaturas das zonas (variáveis manipuladas $x_{2,j}$) apresentaram maior influência nas temperaturas das posições da carroceria, do que os distúrbios de -5% na velocidade do transportador.

Todavia, com a utilização do controlador neural preditivo neural (linhas tracejadas na cor azul), observa-se que as temperaturas das posições da carroceria são mantidas próximas de seus valores de *setpoints* durante a maior parte da simulação, com exceção dos tempos superiores a 23 minutos (entrada da carroceria na zona 11 da estufa), onde verifica-se maiores desvios nos valores de temperaturas das posições da carroceria.

Isso ocorre devido ao fato de que a obtenção realizada pelo otimizador do controlador de apenas uma velocidade do transportador (ótimo global) sempre irá penalizar a dinâmica do processo em zonas específicas, que neste caso estão sendo as zonas 11, 12 e 13. Ou seja, os resultados aparentemente piores para os valores de temperatura das posições da carroceria nas 3 últimas zonas não representa uma ineficiência do controlador NNPC, mas está relacionado a complexidade do problema de otimização operacional, que necessita encontrar uma única velocidade de transportador, que ajuste as temperaturas de todas as partes (8 partes), e em todas as zonas (13 zonas).

Figura 44: Desempenho do controlador NNPC no Cenário 3 - Distúrbio de +5% nas temperaturas das zonas: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.




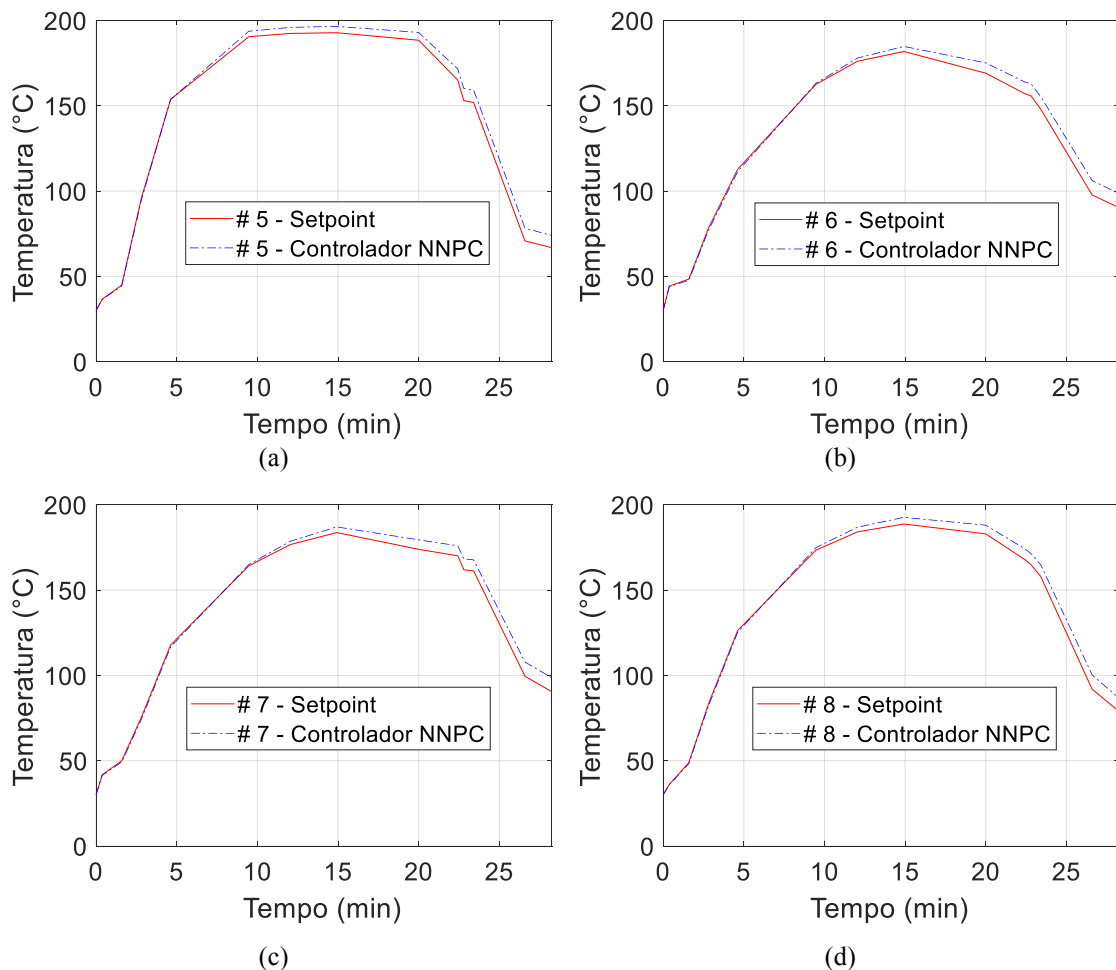


Figura 45: Desempenho do controlador NNPC no Cenário 3 - Distúrbio de +5% nas temperaturas das zonas: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.



A Tabela 15 apresenta a comparação entre as condições operacionais da estufa Elpo para o caso base e para o terceiro cenário com controlador NNPC (*Cenário 3* -

Distúrbio de +5% nas temperaturas das zonas), onde é apresentado o valor da velocidade do transportador nas zonas determinado pelo otimizador para o *Cenário 3*.

A Tabela 16 apresenta os valores de erro médio absoluto percentual (MAPE) e de erro médio absoluto (MAE), calculados para cada uma das partes de medições no Cenário 3, os quais apresentaram valores abaixo de 4,0428% e de 4,8220, respectivamente (#1 Temperatura do ar próxima ao capô), demonstrando que o controlador NNPC atuou no geral de forma satisfatória.

Tabela 15: Condições operacionais da estufa Elpo: Caso base x Cenário 3 com controlador NNPC - Distúrbio de +5% nas temperaturas das zonas.

Zona	Caso base		Cenário 3 com controlador NNPC	
	Temperatura das zonas (°C)	Velocidade do transportador (m/min)	Temperatura das zonas: Distúrbio +5% (°C)	Velocidade do transportador (m/min)
Entrada da estufa	40	4,8	42,00	5,23
Cortina de entrada	73	4,8	76,65	5,23
Zona 1	200	4,8	210,00	5,23
Zona 2	220	4,8	231,00	5,23
Zona 3	240	4,8	252,00	5,23
Zona 4	235	4,8	246,75	5,23
Zona 5	220	4,8	231,00	5,23
Zona 6	215	4,8	225,75	5,23
Zona 7	215	4,8	225,75	5,23
Zona 8	175	4,8	183,75	5,23
Cortina de saída	72	4,8	75,60	5,23
Saída da estufa (Região 1)	40	4,8	42,00	5,23
Saída da estufa (Região 2)	40	4,8	42,00	5,23

Tabela 16: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 3 com controlador NNPC - Distúrbio de +5% nas temperaturas das zonas.

Posição de medição	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)
#1 Temperatura do ar próxima ao capô	4,0428	4,8220
#2 Teto dianteiro esquerdo	3,3411	3,8089
#3 Teto dianteiro direito	3,2369	3,8049
#4 Meio teto esquerdo	3,5626	4,2688
#5 Meio teto direito	3,4515	4,1546
#6 Coluna do meio esquerda	3,2753	4,1191
#7 Coluna do meio direita	3,0543	3,9402
#8 Porta dianteira esquerda	3,1792	4,0563

5.3.3.2. CENÁRIO 4 - DISTÚRBIOS DE -5% NAS TEMPERATURAS DAS ZONAS

Por fim, nas Figura 46 e Figura 47 são apresentados os resultados do cenário com distúrbios com amplitude negativa de 5% nas temperaturas das zonas (variáveis manipuladas x_{2j}), *Cenário 4 - Distúrbio de -5% nas temperaturas das zonas*. Conforme esperado, observa-se que a diminuição de 5% nas temperaturas das zonas resultou em diminuições nas temperaturas das posições da carroceria (variáveis controladas).

Figura 46: Desempenho do controlador NNPC no Cenário 4 - Distúrbio de -5% nas temperaturas das zonas: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.

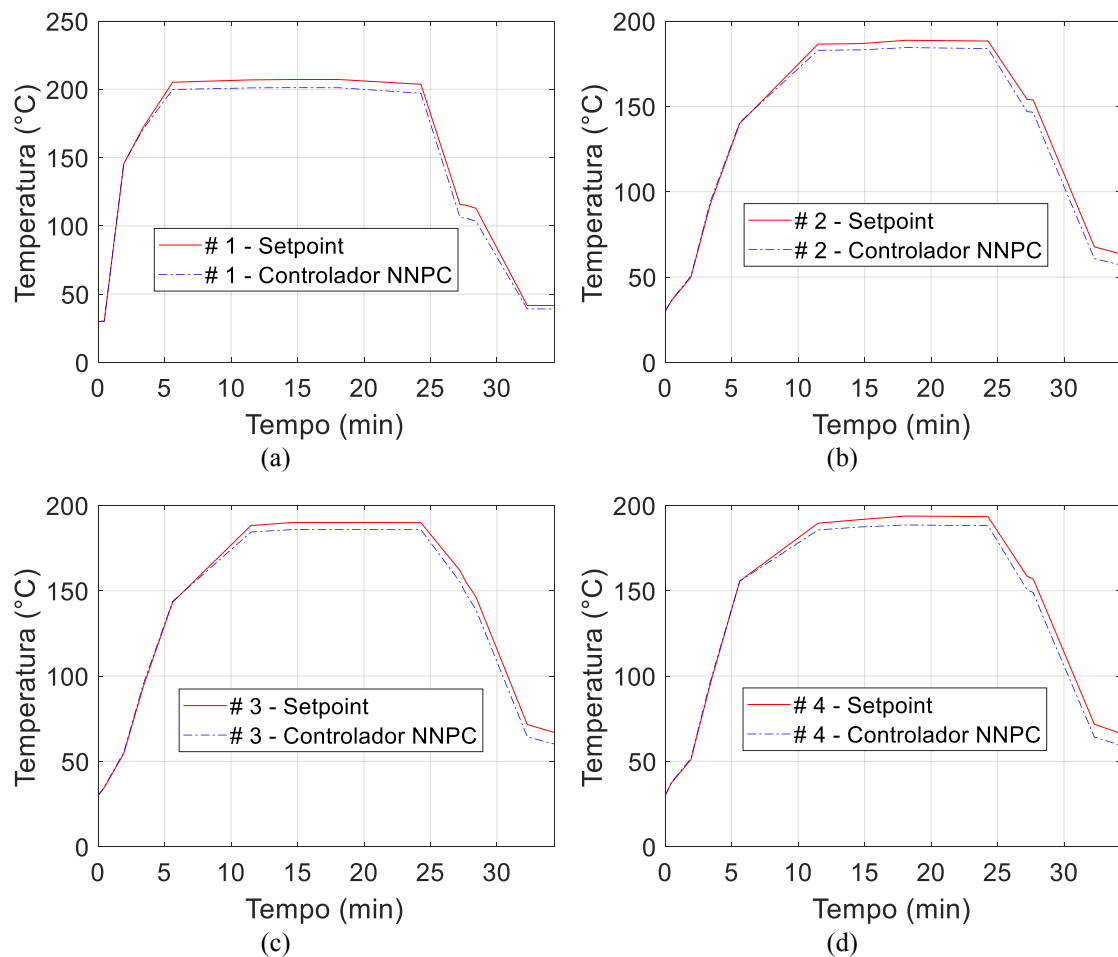
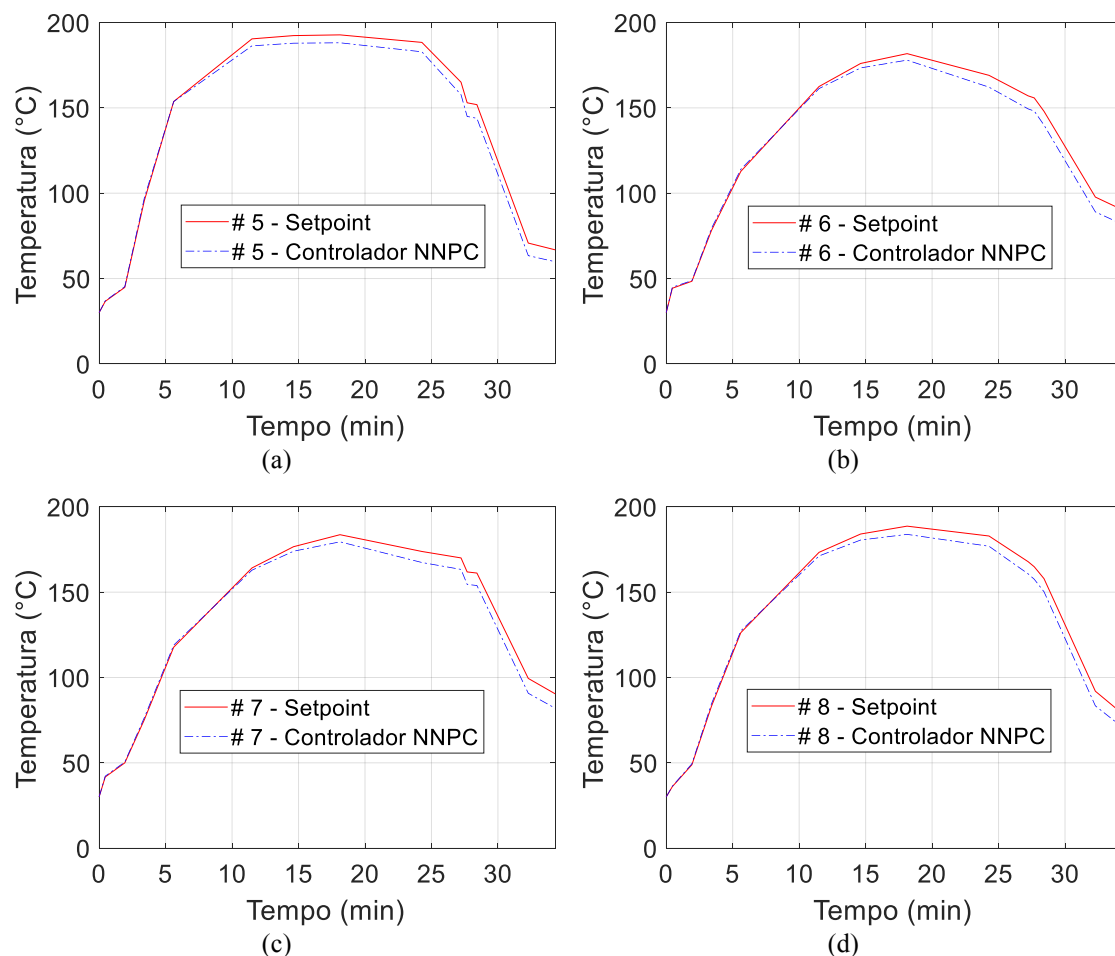


Figura 47: Desempenho do controlador NNPC no Cenário 4 - Distúrbio de -5% nas temperaturas das zonas: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.



Os resultados da utilização do controlador NNPC, representados pelas linhas tracejadas na cor azul nas Figura 46 e 47 demonstram que após a obtenção do valor ótimo de velocidade do transportador (4,3593 m/min presente na Tabela 17), as temperaturas das posições da carroceria são melhor controladas durante a maior parte da simulação, com exceção dos tempos superiores a 23 minutos (zonas 11-13).

Porém, de forma análoga ao Cenário 3, os resultados nas zonas 11, 12 e 13 não refletem em uma diminuição expressiva na eficiência do controlador, visto que a aplicação do NNPC no controle das temperaturas das posições da carroceria ao longo das zonas da estufa apresentou valores de MAPE e MAE menores que 4,0278% e 5,0094, conforme pode ser verificado na Tabela 18. Além disso, os maiores desvios são observados nas últimas zonas da estufa (resfriamento - zonas 11-13), e nesse sentido, não comprometem o foco principal do processo, de realizar a secagem e cura da pintura.

Tabela 17: Condições operacionais da estufa Elpo: Caso base x Cenário 4 com controlador NNPC - Distúrbio de -5% nas temperaturas das zonas.

Zona	Caso base		Cenário 4 com controlador NNPC	
	Temperatura das zonas (°C)	Velocidade do transportador (m/min)	Temperatura das zonas: Distúrbio -5% (m/min)	Velocidade do transportador (m/min)
Entrada da estufa	40	4,8	38,00	4,3593
Cortina de entrada	73	4,8	69,35	4,3593
Zona 1	200	4,8	190,00	4,3593
Zona 2	220	4,8	209,00	4,3593
Zona 3	240	4,8	228,00	4,3593
Zona 4	235	4,8	223,25	4,3593
Zona 5	220	4,8	209,00	4,3593
Zona 6	215	4,8	204,25	4,3593
Zona 7	215	4,8	204,25	4,3593
Zona 8	175	4,8	166,25	4,3593
Cortina de saída	72	4,8	68,40	4,3593
Saída da estufa (Região 1)	40	4,8	38,00	4,3593
Saída da estufa (Região 2)	40	4,8	38,00	4,3593

Tabela 18: Erro Médio Absoluto Percentual (MAPE) e Erro Médio Absoluto (MAE) do Cenário 4 com controlador NNPC - Distúrbio de -5% nas temperaturas das zonas.

Posição de medição	Erro Médio Absoluto Percentual (MAPE)	Erro Médio Absoluto (MAE)
#1 Temperatura do ar próxima ao capô	4,0278	5,0094
#2 Teto dianteiro esquerdo	3,6508	4,1938
#3 Teto dianteiro direito	3,5570	4,1916
#4 Meio teto esquerdo	3,8602	4,6421
#5 Meio teto direito	3,7520	4,5313
#6 Coluna do meio esquerda	3,5656	4,4965
#7 Coluna do meio direita	3,3754	4,3444
#8 Porta dianteira esquerda	3,5401	4,4916

A Tabela 19 apresenta a comparação entre os valores da Integral do Erro Absoluto (IAE) para os quatro cenários avaliados, calculado com base nas Equações 31 e 32.

$$IAE_k = \int_{i=1}^m |y_{k,i} - \widehat{y}_{k,i}| \quad (31)$$

$$IAE_T = \sum IAE_k \cdot \Delta t \quad (32)$$

Onde m é a quantidade de zonas (13 zonas), $y_{k,i}$ são os valores objetivados de temperaturas das partes da carroceria (*setpoints*), $\widehat{y}_{k,i}$ são os valores de temperaturas

obtidos através da utilização do controlador NNPC, para cada k posição de medição (8 partes de medições), e para cada zona m (13 zonas).

Conforme esperado, observa-se na Tabela 19 que os cenários da estratégia de controle NNPC 1 apresentaram resultados melhores quando comparados a estratégia de controle NNPC 2, demonstrando que a definição de novas temperaturas de *setpoints* para todas as zonas apresenta-se como uma estratégia com melhor resolução.

Isso deve-se primordialmente ao fato de que o problema de otimização da estratégia NNPC 2 apresenta uma maior complexidade, pois o controlador necessita encontrar uma única velocidade de transportador que ajuste as temperaturas de todas as partes (8 partes), e em todas as zonas (13 zonas), ou seja, 1 variável de decisão para ajustar 104 variáveis. Mesmo assim, nos dois cenários avaliados, observa-se que o controlador conseguiu encontrar as velocidades ideais para manter as partes da carroceria dentro das especificações de temperaturas das partes, sem comprometer o processo de secagem e cura.

Tabela 19: Integral do Erro absoluto (IAE) para os cenários avaliados com as estratégias de controle NNPC.

	Integral do Erro absoluto (IAE)			
	Estratégia NNPC 1		Estratégia NNPC 2	
	+5% na velocidade do transportador	-5% na velocidade do transportador	5% nas temperaturas do ar nas zonas	-5% nas temperaturas do ar nas zonas
Posição de medição	31,7583	15,6654	62,6859	65,1223
#1 Temperatura do ar próxima ao capô	7,4845	4,3637	49,5152	54,5195
#2 Teto dianteiro esquerdo	7,3155	5,3191	49,4638	54,4904
#3 Teto dianteiro direito	10,6475	7,7711	55,4946	60,3477
#4 Meio teto esquerdo	8,7811	4,7088	54,0103	58,9073
#5 Meio teto direito	10,3721	8,1867	53,5486	58,4548
#6 Coluna do meio esquerda	8,6046	12,7849	51,2225	56,4776
#7 Coluna do meio direita	7,1819	13,5238	52,7323	58,3913
#8 Porta dianteira esquerda	31,7583	15,6654	62,6859	65,1223
TOTAL	92,1454	72,3236	428,6732	466,7109

6 CONCLUSÕES

Este trabalho apresentou uma metodologia para o desenvolvimento e implementação de um sistema de Controle Preditivo Neural (NNPC) para uma estufa de secagem e cura de pintura automotiva. O estudo foi aplicado a estufa que é utilizada durante a etapa de pintura por eletrodeposição (*Elpo*), buscando melhorias no controle de temperatura das partes da carroceria automotiva ao longo da estufa, resultando na minimização dos problemas na pintura.

Um modelo fenomenológico rigoroso de cura e secagem de tinta automotiva foi implementado, e utilizando um procedimento de otimização multidimensional, foi possível ajustá-lo e validá-lo, com base na determinação dos coeficientes de transferência de calor, a partir de dados industriais de temperatura em locais específicos da carroceria ao longo das 13 zonas da estufa *Elpo*.

Com o modelo fenomenológico implementado, ajustado e validado, foi possível utilizá-lo para obter os dados necessários para a obtenção do modelo neural do processo na Estufa *Elpo*, através de aplicações de distúrbios nas variáveis de processo. Após os treinamentos, validações e testes das redes neurais artificiais para todas as zonas da estufa, observou-se que os modelos neurais obtidos apresentaram valores de coeficientes de ajuste R^2 acima de 0,98, demonstrando ótimas respostas das redes neurais nas previsões das temperaturas das partes da carroceria ao longo da estufa.

Nos testes de performance do modelo neural global como *soft sensor*, observou-se que este foi capaz de prever com bastante acurácia os valores de *setpoint* (caso base) das temperaturas das partes da carroceria, com valores de MAPE menores que 3,6155%.

Com posse do modelo neural global, foi implementada a estratégia de controle preditivo neural - NNPC, baseada no modelo de controle preditivo generalizado (GPC), cuja função objetivo do controlador foi resolvida, zona por zona, através da aplicação do método de otimização de colônia de formigas (ACO).

Com isso, utilizando o modelo fenomenológico para representar o processo real de cura e secagem que ocorre na estufa *Elpo* (Caso base), o desempenho do controlador NNPC foi avaliado por meio da realização de simulações de quatro cenários operacionais da estufa *Elpo*, através da aplicação de distúrbios do tipo degrau nas variáveis manipuladas, velocidade do transportador ($x_{1,j}$) e temperaturas do ar nas zonas ($x_{2,j}$).

Para distúrbios de $\pm 5\%$ na velocidade do transportador (cenários 1 e 2), a atuação do NNPC-1 conseguiu manter as temperaturas das posições da carroceria próximas aos seus valores de *setpoints* ao longo de todo o processo. O MAPE e o MAE calculados para

cada uma das partes da carroceria apresentaram respectivamente os seguintes valores: cenário 1, valores abaixo de 1,44% e 2,44, e cenário 2, valores abaixo de 1,00% e 1,21.

Para os distúrbios de $\pm 5\%$ nas temperaturas do ar nas zonas (cenários 3 e 4), também se observou que as temperaturas das posições da carroceria foram controladas, apresentando-se próximas aos seus valores de *setpoints* ao longo de todo o tempo de simulação, indicando que o controlador NNPC-2 também foi eficiente na definição dos valores ótimos de velocidades do transportador nas zonas. O MAPE e o MAE calculados para cada uma das partes da carroceria apresentaram os seguintes valores, respectivamente: cenário 3, valores abaixo de 4,04% e 4,82 e cenário 4, valores abaixo de 4,03% e 5,01.

A performance superior da configuração NNPC-1 deve-se ao fato de que o problema de otimização da configuração NNPC-2 apresenta maior complexidade, pois o controlador necessita encontrar uma única velocidade de transportador que ajuste as temperaturas de todas as partes e em todas as zonas da estufa.

Desta forma, o modelo neural global obtido e o sistema de controle preditivo neural implementado na estufa *Elpo* foram capazes de realizar de forma satisfatória a *i*) predição em tempo real dos valores futuros das temperaturas das partes da carroceria (variáveis controladas), podendo atuar como um *Soft Sensor* e *ii*) determinar os valores ótimos de temperatura das zonas ou de velocidade nas zonas (variáveis manipuladas), capazes de manter as temperaturas das partes da carroceria em valores iguais ou próximos de seus *setpoints* operacionais, e com isso, mantendo-as controladas ao longo de todo o processo.

Por se tratar de uma metodologia pautada em modelagem e simulação, é importante comentar alguns pontos em relação aos requisitos computacionais e tempos de respostas:

- O treinamento do modelo de RNAs demandou certo esforço computacional, porém o tempo de treinamento foi aceitável, dada a complexidade da tarefa;
- Uma vez treinado, o modelo de RNA funcionou de maneira eficiente e teve tempos de execução mais rápidos, quando em comparado ao modelo fenomenológico, por exemplo;
- A rotina de otimização do NNPC também foi executada dentro de um intervalo de tempo condizente, com respostas que poderiam ser utilizadas de forma online, durante o processo transiente da estufa *Elpo*.

Com isso, conclui-se que a metodologia proposta pode ser aplicada para desenvolver estratégias inovadoras de controle operacional de estufas de secagem e cura de pintura automotiva, baseadas na utilização da técnica de redes neurais artificiais, podendo ser adotada em outros equipamentos, tais como as estufas de Vedação, Primer e Base/Verniz.

7 SUGESTÕES PARA TRABALHOS FUTUROS

- I. Adicionar nos modelos de redes neurais, e conseqüentemente no sistema de controle preditivo neural NNPC, outras variáveis que possam influenciar diretamente na qualidade da pintura automotiva, tais como a espessura da camada de tinta ou a conversão da reação de polimerização (cura);
- II. Aplicar a técnica de separações de sinais (ICA) antes de efetuar a identificação dos modelos neurais;
- III. Avaliar a utilização de outras estruturas de rede neurais artificiais, tais como redes neurais recorrentes;
- IV. Desenvolver um sistema de controle baseado em algoritmo do tipo DMC - Controle por Matriz Dinâmica (QDMC, LDMC, DMCL), e comparar com os resultados do NNPC;
- V. Aplicar a metodologia deste trabalho para o desenvolvimento e implementação de sistemas de Controle Preditivo Neural (NNPC) para outras etapas do processo de pintura automotiva, tais como as etapas de Vedação, Primer e Base/Verniz;
- VI. Aplicar a metodologia deste trabalho em etapas reais de cura e secagem de pintura automotiva, com a utilização dos modelos desenvolvidos durante as fases de validação e teste sem atuação direta, e posteriormente com atuação direta, para o controle online do processo.

8 REFERÊNCIAS

- Alghazzawi, A.; Iennox, B. **Model Predictive Control Monitoring Using Multivariate Statistics**. *Journal of Process Control*, 2009, v.19, p. 314-327.
- Akafuah, N. K.; Poozesh, S.; Salaimah, A.; Patrick, G.; Lawler, K. Saito, K. **Evolution of the Automotive Body Coating Process - A Review**. *Coatings*, 2016, v. 6, p. 2-24.
- Ashrafizadeh, A.; Mehdipour, R.; Aghanajafi, C. **A Hybrid Optimization Algorithm for the Thermal Design of Radiant Paint Cure Ovens**. *Applied Thermal Engineering*, 2012, v. 40, p. 56-63.
- Blandin, H. P.; David, J. C.; Vergnaud, J.M. **Modelling the Drying of Coatings: Effect of the Thickness, Temperature and Concentration of Solvent**. *Prog. Org. Coat.* 1987, 15, p. 163-172.
- Camacho, E. F.; Bordons, C. **Model Predictive Control**. London: Springer, 1998. 280p.
- Chapra, S.C. **Applied Numerical Methods with MATLAB for Engineers and Scientists**. McGraw Hill, 2012.
- Cussler, E. *Diffusion: Mass Transfer in Fluid Systems*; Cambridge University Press: New York, 2009, p. 211-243.
- Despotovic, M.; Babic, M. **Analysis of Different Scenarios of Car Paint Oven Redesign to Achieve Desired Indoor Air Temperature**. *Energy Efficiency*, 2018, v. 11, Issue 4, p. 877-891.
- Dickie, R. A.; Bauer, D. R.; Ward, S. M.; Wagner, D. A. **Modeling Paint and Adhesive Cure in Automotive Applications**. *Progress in Organic Coatings*, 1997, v. 31, p. 209-216.
- Doerre, M.; Hibbitts, L.; Patrick, G.; Akafuah, N. K. **Advances in Automotive Conversion Coatings during Pretreatment of the Body Structure: A Review**. *Coatings*, 2018, v. 8, p. 405.
- Elahi, M. M. L.; Záruba, G. V.; Rosenberg, J.; Rajpurohit, K. **Modeling and Simulation of a General Motors Conveyor System using a Custom Decision Optimizer**. Master's Thesis. Department of Computer Science and Engineering, University of Texas at Arlington, Arlington, Texas, 2009.
- Ferramosca, A.; Limon, D.; González, A.H.; Odloak, D., E.F. **MPC for Tracking Zone Regions**. *Journal of Process Control*, 2010, v. 20, p. 506-516.
- Haykin, S. **Neural Networks: A Comprehensive Foundation**. New York: MacMillan College Publishing Co., 1999.

- Haykin, S. **Redes Neurais: Princípios e Prática**. 2a ed. Ed. Bookmann, Porto Alegre, RS, 2001.
- Ion, L.; Vergnaud, J. **Process of Drying a Polymeric Paint by Diffusion-Evaporation and Shrinkage. Determination of the Concentration Dependent Diffusivity**. Polym. Test. 1995, v. 14, p. 479-487.
- King, J. **Separation Processes**; McGraw-Hill, Inc.: New York, 1980, pp. 508–583.
- Lagarias, J. C., J. A. Reeds, M. H. Wright, and P. E. Wright. **Convergence Properties of the Nelder-Mead Simplex Method in Low Dimensions**. SIAM Journal of Optimization. 1998, v. 9, Number 1, p. 112-147.
- Lou, H. H.; Huang, Y. L. **Integrated Modeling and Simulation for Improved Reactive Drying of Clearcoat**. Ind. Eng. Chem. Res., 2000, v. 39, p. 500-507.
- Ma, S., Jiang, Z. & Liu, W. **Modeling Drying-Energy Consumption in Automotive Painting Line Based on ANN and MLR for Real-Time Prediction**. Int. J. of Precis. Eng. and Manuf.-Green Tech. 2019, v. 6, p. 241-254.
- Marcolla, R. F. **Investigação e Aplicação de Técnicas de Modelagem e Controle de Processo Baseadas em Redes Neurais com Ajuste em Linha Utilizando Algoritmos Genéticos**. Dissertação de mestrado, Universidade Federal de Santa Catarina. Florianópolis, SC, 2005.
- Dorigo, M. **Optimization, Learning and Natural Algorithms**. Ph.D Thesis Dip. Electronico, Politecnico di Milano, Italy, 1992.
- Mark, L.; darby, N.; nikolaou, M. **MPC: Current Practice and Challenges**. Control Engineering Practice, 2012, v. 20, p. 328-342.
- Mathworks. **Neural Network Toolbox User's Guide**. Version 4. MathWorks Inc. 2002.
- Matsunaga, V. Y. **Curso de Redes Neurais Utilizando o MATLAB**. Belém, PA, 2012.
- Mehdipour, R; Baniamerian, Z.; Sattar, S. **Evaluation of Continuous Convection and Radiation Ovens in Automobile Cure Industry**. International Journal of Automotive Engineering, 2015, v. 5, p. 1054-1066.
- Popoff, L. H. G. **Controle Preditivo Neural Aplicado à Processos Petroquímicos**. Dissertação de mestrado, Universidade Federal do Rio Grande do Norte. Natal, RN, 2009.
- Prottes, S. M. **Controlador Neural Preditivo Multivariável Aplicado à Uma Planta Piloto de Neutralização de Ph**. Dissertação de mestrado, Centro Universitário do Leste de Minas Gerais. Coronel Fabriciano, MG, 2009.
- Qin, S. J.; Thomas A. B. **A Survey of Industrial Model Predictive Control Technology**. Control Engineering Practice, 2003, v. 11, p. 733-764.

- Radfar, R.; Jassbi, J.; Ghoreishi, F.; Khanmohammadi, S.; Alborzi, M. **Proactive Quality Paint Thickness Control Using ANFIS**. IEEE - International Conference on Systems, Man and Cybernetics, 2010.
- Rao, P.P.; Gopinath, A. **Energy Savings in Automotive Paint Ovens: A New Concept of Shroud on The Carriers**. Journal of Manufacturing Science and Engineering, 2013, v. 135, p. 1-9.
- Rao, S. S. **Engineering Optimization. Theory and Practice**. 4th ed. Ed. John Wiley & Sons, Inc. 2009.
- Rumelhart. D. E.; mclelland, J. L. **Parralled Distributed Processing: Explorations in The Microstructure of Cognition. Vol.1: Foundation**. Cambridge: The Mit Press, 1986.
- Seborg, D. E.; edgar, T. F.; mellichamp, D. A. **Process Dynamics and Control. 2nd ed**. New York: John wiley & Sons, Inc., 2004, v. 2.
- Soloway. D; haley, P. **Neural Generalized Predictive Control**. IEE Symposium on Intelligent Control. Dearborn. MI, 1996.
- Song, H.; Xiao, J.; Huang.Y. **Multiscale Modeling and Optimization of Nano Clearcoat Curing for Energy Efficient and Quality Assured Coating Manufacturing**. Ind. Eng. Chem. Res., 2015, v. 55, p. 3351-3359.
- Stephanopoulos, G. **Chemical Process Control**. Englewood Cliffs: Prentice Hall, 1984.
- Vasudevan, M. **Numerical Modelling off Paint Curing in Convective Ovens**. Master's Thesis. Mechanics and Maritime Sciences. Chalmers University of Technology. Goteborg, Sweden, 2018.
- Xiao, J.; Li, J; Lou, H. H.; Huang.Y. **Cure-Window-Based Proactive Quality Control in Topcoat Curing**. Ind. Eng. Chem. Res., 2006, v. 45, p. 2351-3360.
- Xu, Z.; zhu Y.; han, K.; zhao, J.; Qian, J. **A Multi-Iteration Pseudo-Linear Regression Method and an Adaptive Disturbance Model For MPC**. Journal of Process Control, 2010, v. 20, p. 384-395.
- Zelder, G.; Steinbeck-Behrens, C. **Simulation on Car Body Painting Processes**. 4th European Automotive Simulation Conference. July 2009.
- Zuhua Xu, Yucai Zhu, Kai Han, Jun Zhao, Jixin Qian. **A multi-iteration pseudo-linear regression method and an adaptive disturbance model for MPC**. Journal of Process Control, 2010, v.20, p. 384-395

APÊNDICES


APÊNDICE 1: ARTIGO 1 (PUBLICADO EM REVISTA A1)

Progress in Organic Coatings 140 (2020) 105479



Contents lists available at ScienceDirect

Progress in Organic Coatings

journal homepage: www.elsevier.com/locate/porgcoat

Automotive painting process: Minimizing energy consumption by using adjusted convective heat transfer coefficients



Esley Silva Cavalcante, Luís Gonzaga Sales Vasconcelos, Gilvan Wanderley de Farias Neto, Wagner Brandão Ramos, Romildo Pereira Brito*

Federal University of Campina Grande, Department of Chemical Engineering, Campina Grande, PB, 58109-970, Brazil

ARTICLE INFO

Keywords:
Automotive industry
Drying process
Painting oven
Modelling
Optimization

ABSTRACT

The process of drying/curing automobile painting is characterized as one of the main stages in automobile assembly. To guarantee the final painting quality, optimal operating conditions (mainly the temperature profile in the painting chamber) must be satisfied, and they are empirically defined in most cases. The availability of a mathematical model in transient regime enables the prediction of the drying/curing process behavior and consequences of possible operational changes on the final quality of the paint. However, obstacles continue to exist with respect to the implementation of the aforementioned types of models given the large number of parameters and complexity involved in their determination among which convection heat transfer coefficients are notable. Thus, the study presents a methodology to adjust the mathematical model of a paint-curing oven via determining convection heat transfer coefficients based on industrial data. The adjusted model was used to predict new operational scenarios for the most commonly used oven in automobile painting processes, namely the Elpo oven. The results indicate that the proposed methodology can be applied as a tool to develop operational optimization strategies that result in decreasing rework and energy costs without compromising painting quality.

1. Introduction and problem statement

An increasingly difficult task in the automobile industry corresponds to improving the efficiency of processes to maximize results because it is necessary for companies to survive in the current globalized competitive market. Production, quality, costs, environment, social responsibility, and safety are vectors that are present in any process, and maximizing results implies positioning these variables to obtain optimal synergy among them. Moreover, energy consumption is a major concern of companies because it is directly related to costs and environmental issues (for e.g., greenhouse gas emissions).

According to Dickie et al. [6], automotive assembly operations can be divided into the following three stages: fairing construction, painting operations, and final assembly. Painting operations typically involve pretreatment, application, drying, and curing three or more organic coatings.

The painting process commences with pretreatment. Currently, common treatments involve phosphate process where body-in-white (BIW) of the vehicle is cleaned and coated with phosphate solution [8]. However, non-phosphated zirconium-based conversion coatings are

increasingly common in the pretreatment process. According to Doerre [7], zirconium oxide conversion coatings offer several advantages relative to phosphating. Sludge reduction can be as high as 95 %, processing at ambient temperature is possible, thereby decreasing energy consumption, and zirconium exhibits good environmental characteristics due to its low toxicity.

In certain automotive industries, application, drying, and curing are performed in a step by electrodeposition (Elpo: booth and oven) and in two steps by spraying (Primer and Clearcoat: booths and ovens) [8]. However, a modern coating strategy is already successfully established in a few automotive industries, such as the wet-on-wet-on-wet-system (3-wet). As revealed by Akafuah [1], the automobile industry seeks to eliminate or minimize the extent of spray application processes, space, and baking ovens, given the significant savings in material and energy. The 3-wet paint systems eliminate the primer oven in the coating process and also decrease volatile organic compounds (VOC) and carbon dioxide (CO₂) emissions.

As indicate by Ashrafzadeh et al. [2], the painting quality of an automobile's fairing depends on the intensity, duration, and mechanism of heat transfer in the painting unit ovens. The main heat transfer

* Corresponding author.

E-mail address: romildo.brito@ufcg.edu.br (R.P. Brito).<https://doi.org/10.1016/j.porgcoat.2019.105479>Received 20 August 2019; Received in revised form 22 November 2019; Accepted 3 December 2019
0300-9440/ © 2019 Elsevier B.V. All rights reserved.

Nomenclature			
A	Surface area of the substrate covered by the film (m^2)	T_w	Oven wall temperature (K)
BIW	Body-in-white	T_o	Measured body-in-white (BIW) parts temperature (K)
C	Solvent concentration (kg solvent/kg solid)	T_m	Calculated body-in-white (BIW) parts temperature by the model (K)
C_o	Initial Solvent concentration (kg solvent/kg solid)	V_s	is the volumes of polymeric materials in solvent (m^3)
C_{pm}	Heat capacity of metal substrate ($J/(kg.K)$)	Z_m	Thickness of metal substrate (m)
D_n	Solvent diffusivity coefficient (m^2/s)	Z_s	Thickness of solids in paint (m)
E_d	Activation energy for diffusion (J/mol)		
E_c	Activation energy for cross-linker (J/mol)	Greek	
h_v	Convective heat transfer coefficient ($W/(m^2.K)$)	a	Conversion of cross-linking reaction (cure)
P_{is}	Solvent partial vapor pressure at the coating-air interface (Pa)	γ	Constant
P_{ib}	Solvent partial vapor pressure in the circulating medium (Pa)	σ	Stefan Boltzmann constant ($5,67 \times 10^{-8} W/(m^2.K^4)$)
R	Ideal gas constant ($8314 Pa.m^3/(mol.K)$)	ϵ	Emissivity
t	Time (s)	ζ	Polymerization reaction frequency factor (1/s)
T_a	Air temperature (K)	η	Pre-exponential constant for diffusivity (m^2/s)
$T(t)$	body-in-white (BIW) temperature (K)	ρ_l	Solvent density (kg/m^3)
		ρ_m	Metal substrate density (kg/m^3)
		ρ_s	Solid in paint density (kg/m^3)

mechanisms involved in the curing process correspond to radiation and convection. Radiation heat transfer is due to the use of radiation panels near the entrance while convective heat transfer occurs via hot air blowers in the oven. The steps involving the convective mechanism are responsible for high energy consumption.

Failures in painting involve rework, which means an increase in production cost, thereby indicating that a recall for painting failure can result in delivering a new vehicle to the customer. To maintain a scenario that guarantees painting quality, engineers typically empirically manipulate the temperature of each chamber in the painting unit because the quality of the painting is significantly affected by the uniform distribution of temperature inside the oven and conveyor speed (directly related to production). Thus, the relationship between production, energy consumption, and quality is fundamental to ensure that decisions are made safely.

Generally, manipulations in the chamber temperatures are performed in a conservative manner, which implies greater energy consumption. Therefore, it is crucial to examine and develop a representative model of the drying/curing process to understand and optimize the process, thereby avoiding the occurrence of failures and promoting energy cost reduction.

The literature proposes mathematical models for the automotive paint drying/curing process [12,15]. The authors specify heat transfer coefficients as a function of the air velocity at the BIW surface and consider that the coefficients are constant for a certain zone in the oven. However, they correspond to fragile considerations because air velocity varies with respect to the BIW position.

Vasudevan [16] used experimental measurements to develop a method to optimize the heat transfer coefficient in the heat transfer solver and a model parameter that represents evaporation at the paint layer-air interface in the mass transfer solver. The study indicated that the heat transfer coefficient is a weak function of concentration of the solvent.

As indicated by Zelder et al. [18], it is necessary to predict the effect of design changes or process changes on quality, and thus the simulation of car body painting processes is increasingly important to evaluate paint processes and car body design. The authors used computational fluid dynamics (CFD) techniques as offered by the VPS/DRY module (CADFEM GmbH) to analyze the temperature profile of the BIW during drying in an oven, and the results can be used to plot an oven curve for each location in BIW.

Mehdipour et al. [13] compared radiation and convection ovens applying computational fluid dynamics (CFD) techniques and moving boundary method, and the results revealed that 50 % energy savings are

achieved by using radiation ovens as opposed to convection ovens.

Rao et al. [14] used a semi-computational method (i.e., CFD solver and thermal network solver) to predict BIW part temperatures in an automotive paint oven bake process and proposed a concept of using a shroud to cover carriers and partially protecting them from hot air emitted by the oven. This significantly decreased the energy consumption of the oven.

The findings by [13,14], and [18] are extremely accurate although they are computationally expensive and time-consuming, given the use of CFD techniques [5]. Additionally, they are applied in the design phase and more specifically in structural changes or steady state operational changes.

This study aims to propose a methodology to adjust the paint drying model via determining convection heat transfer coefficients for different vehicle BIW parts in different zones of the studied oven via minimizing the difference between the values obtained from the model and plant data. Temperature data were used at specific vehicle locations to minimize errors.

When adjusted and validated, the model can be used for operational control of the oven wherein the main feature involves providing quick responses and can be used to provide inputs for transient operating disturbances or steady state operational changes. To represent the application of the model, studies were then performed to answer the following questions:

- What constitutes the limit at which production can be increased and how much does this represent in terms of energy consumption via modifying the speed of the conveyor without compromising paint quality?
- Given that production must remain unchanged (conveyor speed must not change), how can energy consumption be reduced by modifying the temperature profile without compromising painting quality?

To the best of the authors' knowledge, an extensive literature survey indicated the lack of studies that focus on the procedure proposed in the present study that is applied to automotive paint drying, and especially in relation to the multi-objective optimization strategy and objective function developed to determine convection heat transfer coefficients.

The procedure was applied to an Elpo oven, which is the largest consumer of energy of the considered industrial plant. In Elpo (Electrophoretic Priming Operation) the BIW is covered with e-coat to provide corrosion protection [8]. Subsequently, BIW should be heated and baked to complete the Elpo process such that the cars remain in the

Elpo oven at 170°–180 °C for 20–30 min.

2. Mathematical modelling

Fig. 1 illustrates a sequence of the painting process in automotive industry under study. The painting process commences with a pre-treatment (phosphate process). Subsequently, the BIW is moved by a conveyor via the process at a constant speed, being subjected to the application, drying, and curing of organic coatings.

Blocks in gray represent the ovens responsible for the drying and curing stages in the painting process. Fig. 2 depicts the oven scheme where the ovens are divided into zones. The heat transfer mechanisms occur by radiation and convection in zones 1 and 2, whereas the convective heating mechanism of the BIW occurs in the following zones. Finally, the last zones correspond to the cooling step of the BIW where the process ends.

Fig. 3 represents the transport phenomena and reaction that occur in the film during the curing process. The mathematical model of the drying process in the oven contemplates several phenomena. Radiation heat transfer occurs between the oven wall and substrate, which is formed by a base, primer, phosphate, and metal. The convective heat transfer occurs between the air and substrate while heat is transported by conduction inside the substrate.

Heat transport by radiation and convection also occurs on the film surface, and this is similar to what occurs in the substrate. Conversely, heat transport occurs inside the film by conduction and mass transport by diffusion between the interfaces. A chemical polymerization reaction of the ink components is performed in the film, and this is followed by the curing process via forming a polymer network. Mass transfer of the solvent into the middle stock occurs through evaporation at the film-air interface.

The film surface and substrate thicknesses are very low, and thus the conduction phenomenon is insignificant when compared to the radiation and convection phenomena, and thereby can be neglected in the model. Thus, the heat transfer model presented in Equation (1) characterizes the contribution of heat transfer mechanisms based on the operational conditions of the zones [15].

$$\frac{dT(t)}{dt} = \begin{cases} \frac{\sigma \varepsilon}{\rho_m C_{pm} Z_m} (T_w^4 - T(t)^4) + \frac{h_v}{\rho_m C_{pm} Z_m} (T_a - T(t)), & \text{radiation and} \\ \text{convection} \\ \frac{h_v}{\rho_m C_{pm} Z_m} (T_a - T(t)), & \text{convection} \end{cases} \quad (1)$$

In Eq. (1), $T(t)$ denotes the BIW temperature, T_w denotes the temperature of the oven wall, T_a denotes the air temperature, ρ_m denotes the metal substrate density, C_{pm} denotes the metal substrate heat capacity, Z_m denotes the metal substrate thickness, σ denotes the Stefan Boltzmann constant, ε denotes the emissivity, and h_v denotes the convective heat transfer coefficient.

The solvent moves towards the film surface during the drying




Fig. 1. Block flow diagram of the painting process.

process, and mass solvent transfer on the surface occurs via evaporation at the interface between air and film. Thus, two mass transfer models must be used wherein the first model refers to the mass diffusion of the solvent inside the film, and the second model refers to the mass transfer that occurs in the film–air interface.

The model of solvent mass diffusion within the film is given by Eq. (2) as follows [12,15]:

$$\frac{\partial C(z, t)}{\partial t} = \frac{\partial C}{\partial z} \left(D_n(t) \frac{\partial C(z, t)}{\partial z} \right) \quad (2)$$

Here, $C(z, t)$ denotes the mass concentration of the solvent, D_n denotes the solvent diffusivity coefficient, and z denotes the film thickness. The coefficient of diffusivity in Eq. (2) is calculated by Eq. (3) as follows [3,9,12,15]:

$$D_n(t) = \eta \exp \left(-\frac{\gamma}{C} - \frac{E_d}{RT(t)} \right) \quad (3)$$

Here, η denotes a pre-exponential constant for diffusivity, γ denotes a constant, E_d denotes the activation energy for diffusion, and R denotes the ideal gas constant.

Thus, the resolution of Eq. (2) is obtained by applying the initial conditions and boundary conditions. As an initial condition, we obtain the following equation:

$$C(z, 0) = C_0 \quad (4)$$

As boundary conditions, the condition expressed by Eq. (5) with $z = 0$ is adopted, while the boundary condition represented by Eq. (6) is adopted for the mass transfer that occurs to the film–air interface ($z = Z$) through the evaporation process as follows [4,10].

$$\frac{\partial C(0, t)}{\partial t} = 0 \quad (5)$$

$$\frac{\partial C(z, t)}{\partial t} = \frac{D_n(t)}{Z_s} \frac{\partial C(z, t)}{\partial z} - \frac{K(P_s(t) - P_b)}{\rho_s Z_s} \quad (6)$$

In Eq. (6), Z_s denotes the solid thickness in the film, ρ_s denotes the solid in paint density, K is mass transfer coefficient, $P_s(t)$ denotes the solvent partial vapor pressure at the coating–air interface, and P_b denotes the solvent partial vapor pressure in the circulating medium.

The decrease in the film thickness ($Z(t)$) with the drying time, which results from the mass transfer of the solvent at the film–air interface is given by Eq. (7) as follows [15]:

$$Z(t) = \frac{\rho_l V_s (1 - C(t)) + \rho_s V_s C(t)}{A \rho_l (1 - C(t))} \quad (7)$$

Here, ρ_l denotes the density of the solvent, ρ_s denotes the solid in paint density, A denotes the surface area of the substrate covered by the film, and V_s denotes the volumes of polymeric materials in solvent.

Finally, the model that represents the curing process is given by Eq. (8) where α denotes the conversion of cross-linking reaction (cure conversion), ζ denotes the polymerization reaction frequency factor, E_c denotes the cross-linker activation energy, and m and n are constants [15]. The expression is as follows:




Fig. 2. Typical scheme of an oven (adapted from Lou and Huang et al. [12]).

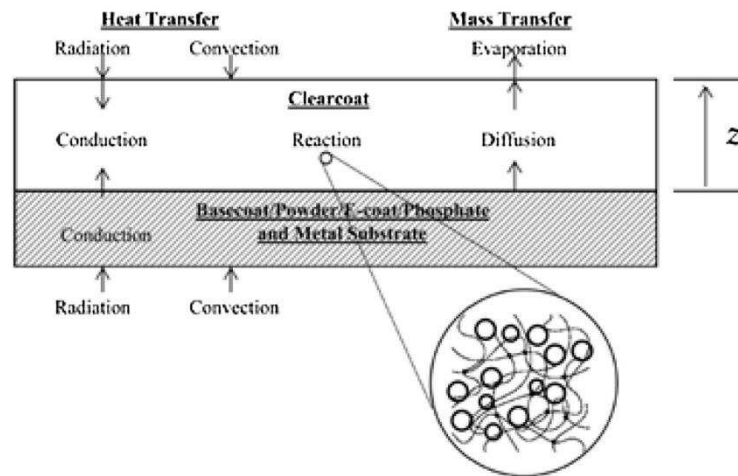


Fig. 3. Transport phenomena and reaction occurring in the coating film during curing process (adapted from Song et al. [15]).

$$\frac{d\alpha(t)}{dt} = \zeta \exp\left(-\frac{E_C}{RT(t)}\right) \alpha(t)^m (1 - \alpha(t))^n \quad (8)$$

zones, it is observed that convection has a significant influence in all the zones. Therefore, adjusting the model to the plant data involves an

The mathematical model described by Eqs. (1)–(8) was implemented using the MATLAB® platform. The Finite Difference Method for space discretization was used to solve the model, and the partial differential equations are transformed into a system of ordinary differential equations as a function of time, which were then solved by a method proposed by Adam Smith using the ode15s routine.

3. Optimization procedure for model adjustment

Fig. 4 depicts the locations of the BIW parts that were studied in the Elpo oven. The ovens used in the process under study (Fig. 1) differ in their layouts and number of zones. The Elpo oven was divided into 13 zones of different lengths; the oven zones design and their operational specification are presented in Table 1.

Zones 1, 12, and 13 of the Elpo oven correspond to the entrance and exit, and do not belong to the internal structure. However, these regions were considered in the simulations and in the parameter adjustments because these regions are part of the heating curves.

When analyzing the heat transfer mechanisms that occur in the oven




Fig. 4. Vehicle BIW parts studied.

Table 1
Elpo oven design and operational specification.

j	Zone	Length (m)	Air temperature (C)
1	Oven inlet	2.0	40
2	Entrance curtain	6.4	73
3	Zone 1	6.4	200
4	Zone 2	9.6	220
5	Zone 3	25.6	240
6	Zone 4	13.6	235
7	Zone 5	15.2	220
8	Zone 6	26.8	215
9	Zone 7	12.8	215
10	Zone 8	2.0	175
11	Exit curtain	3.2	72
12	Oven outlet (first region)	16.8	40
13	Oven outlet (second region)	8.8	40

optimization problem, and the solution involves determining the convective heat transfer coefficients for each part of the BIW, in each zone, that minimize the difference between the measured temperatures and temperatures calculated by the model. The constraints of the optimization problem are the decision variables (convective heat transfer coefficients) that do not exhibit negative values.

Several objective functions are available in extant studies to determine the convective coefficients. In the study, the optimization problem consists of minimizing the following objective function:

$$F_{objk} = \sum_{j=1}^m \left(\left(\sum_{i=1}^n (T_{o,i,j,k} - T_{m,i,j,k})^2 \right) - wh_{j,k} \right) \quad (9)$$

s.t.

$$h(j, k) > 0 \quad (10)$$

Here,

k denotes the number of BIW parts;

$j = 1, 2, \dots, m$, and m represent the number of zones of each oven;

$i = 1, 2, \dots, n$, where n denotes the number of points throughout the oven;

T_o denotes the temperature measured in each part of the BIW;

T_m denotes the temperature calculated by the model in each part of the BIW;

h denotes the convective heat transfer coefficient;

w is an adjustable weighting coefficient that expresses the contribution to the objective function.

Since the model must be adjusted for different BIW parts in the studied oven, determining the convective heat transfer coefficients consists of a multi-objective optimization problem, and each part of the BIW has an objective function to be minimized. Additionally, the number of oven zones and the number of points in the heating curves further increase the size of the problem. Table 2 presents the details of the optimization problem specifications.

Eq. (9) was structured using the least squares criterion, focusing on minimizing the sum of squares of the differences between the values calculated by the model and the experimental values. Additionally, it was used a weighting coefficient w , to represents the contribution of each individual objective functions to the overall objective function (Eq. (9)). In fact, the term $wh_{j,k}$ represents a penalty and the w value was determined empirically in order to force the optimization method to seek always to positive values (constraints) for the convective heat transfer coefficients (decision variables); for positive values for the convective heat transfer coefficients, it was used a command to negligible the term $wh_{j,k}$.

It is important to emphasize that the proposed optimization procedure is applicable for all parts where there is temperature measurement; however, it is observed that in critical areas of the BIW, such as pillars and rockers, temperature data are difficult to obtain.

4. Base-case simulation

In the case under study, In the case under study, the coating material corresponded to Ecoat. The metal substrate thickness corresponded to 0.001 m, the metal substrate density corresponded to 2,700 kg/m³ and the metal substrate heat capacity corresponded to 840 J/(Kg.K).

The optimization procedure was performed from initial estimates for the convection heat transfer coefficients, and thus, it was possible to validate the model for the base case of the oven. The characteristic of the formulated optimization problem makes it necessary to use a robust and efficient optimization method. Thus, the Nelder–Mead Simplex, which is a derivative-free algorithm as described in Lagarias et al. [11], using `fminsearch` routine was employed.

Initial estimates for the heat transfer coefficient values during the optimization corresponds to 5 W/(m².K) for 10, 100, and 1000 iterations, respectively. It was observed that the results generated by the model fit better with the plant data after 1000 iterations, and thus it corresponded to the established value to adjust the heating curves.

Fig. 5 shows a comparison between plant data (dotted) and simulation results (continuous) for position 1 shown in Fig. 4 (air temperature near hood) using 1000 iterations. It is possible to verify a satisfactory performance of the optimization procedure because a good agreement exists between the model and measured data. The convective heat transfer coefficients of the model that were determined using industrial data for the Elpo oven are presented in Table 3.

Fig. 6 depicts the simulated heating curves for the 8 positions along the Elpo oven zones using convective heat transfer coefficients as determined by the optimization procedure where it is possible to observe the occurrence of different heating conditions based on the BIW position.

It should be noted that the air temperature was measured at the exit of the heaters between 5 and 22 min, and therefore, the value practically did not oscillate. Conversely, the presence of the BIW completely changed the fluid dynamics inside the oven, which resulted in an uneven temperature distribution.

Fig. 7 shows the curing percentage for the eight BIW positions. It is possible to observe that the curves are in the form of a sigmoid, which are explained by the low difference between the solvent evaporation rate and polymerization reaction. The sigmoid changed based on the BIW position due to the difference between the evaporation rates.

As shown in Fig. 7, a 100 % cure is achieved in all positions. However, instead of evaluating the conversion rate, it is more important to observe how long the curing reaches a level close to 100 %. In any oven, or even when leaving the BIW drying in the environment, the conversion reaches a value of 100 % even if a significantly longer time period is necessary to reach this condition. Evidently, the paint quality is not the same, and the productivity is low. According to Lou and Huang [12], one of the factors that directly influence the quality of the paint is the solvent evaporation rate. A fast solvent removal may cause popping and orange peels, formation of blisters, crinkling, and bubbling. On the other hand, if the solvent evaporation rate is too low, a desired degree of cross-linking reaction may be not reached.

Thus, Fig. 7 highlights the importance of a model that can be used to search for a temperature profile for the oven that decreases the required time to reach the desired curing level; more specifically, left center

Table 2
Details of optimization problem specifications.

Parameter	Value
k objective functions	8
m zones	13
n points in the heating curves	366
Number of search variables	104
Number of points used to calculate the objective function	2,928




Fig. 5. Plant data and simulation results for position 1 after 1000 iterations.

pillar (# 6) and right center pillar (# 7), to attempt to decrease the operating time, and to provide higher productivity.

In summary, the cure difference in each region depends on the cure kinetics, which depends on a series of factors including temperature reached in the region, heat transfer coefficient, velocity of air, and position of each region within the oven.

To better illustrate the curing inequality in BIW positions, Fig. 8 shows the curing window recommended by the paint manufacturer for the process (region bounded by the black line), and heating curves of each BIW part for the Elpo oven. Based on Dickie et al. [6], the cure windows provided by the material supplier to guide the development of processing conditions displayed ranges of time and temperature over which generally acceptable performance properties can be achieved.

The mathematical model used in the development of curing window graphics was based on Xiao et al. [17]. As indicated in the study, the use of the curing window and a temperature time panel makes it possible to conclude that the paint curing quality is satisfactory and within specification.

In Fig. 8, the region bounded by the blue color represents the region where the heating curves are closest to the optimum curing point. The cure window also provided the nominal cure condition, which in the case under study is represented by the point 25 min and 165 °C (symbolized by a star symbol). Curing outside the recommended region can result in the formation of bubbles on the BIW surface due to uneven solvent evaporation.

5. Simulations of new operating scenarios

Simulations of new operating scenarios were performed with the

validated model by always focusing on decreasing energy consumption and maintaining paint quality. Numerous situations are possible such as individually changing the temperature of each zone. Thus, only two situations were used to demonstrate the model versatility. The air flowrate remained unchanged, and thus energy consumption is only related to temperature and residence time. Thus, the new scenarios were evaluated for changes in the conveyor speed and in the temperature profile.

5.1. Increasing conveyor speed

The first scenario consisted of increasing the conveyor speed by 10 %, which represents a decrease in the residence time in the oven and consequently the curing time. For comparison purposes, the results obtained for the new scenarios are presented in conjunction with those obtained for the base case. The heating curves and curing curves are shown in Fig. 9 and, as expected, there is a small decrease in the BIW part temperature values relative to the base case for all ovens. This is caused by the shorter time of the bodies inside the oven.

Based on Fig. 9, heating curves and the curing process in the Elpo oven are slightly affected by the increase in conveyor speed, so it is possible to increase the production up to 10 % without compromising the paint's curing conditions. However, it is important to note that the #6 (left center pillar) to almost go beyond the recommended region.

5.2. Decreasing temperature of all zones

The second scenario consisted of decreasing the temperature of each oven zone by 10 %, which indicates a decrease in energy consumption.

Table 3 Convective heat transfer coefficients.

	Oven inlet	Entrance curtain	Zone 1	Zone 2	Zone 3	Zone 4	Zone 5	Zone 6	Zone 7	Zone 8	Exit curtain	Oven outlet (first region)	Oven outlet (second region)
Air temperature near the hoof of the BIW	2.6539	13.1972	16.499	11.6916	3.9851	0.6735	0.0604	0.1484	17.9268	1.4905	6.1516	532.725	0.2827
Left front roof	1.0532	0.7943	5.5645	9.3063	6.3453	0.37	1.9687	2.1538	7.0193	1.39	7.0083	2.3144	3.9628
Right front roof	3.4785	1.9952	6.5373	8.055	5.7692	1.5042	2.0662	2.5956	5.2674	3.0899	5.5053	0.8548	1.6945
Left middle roof	2.8036	1.2986	5.6813	10.2343	5.4971	2.5546	3.0343	2.6756	5.9769	2.898	4.0767	2.1454	3.4887
Right middle roof	2.2468	1.3607	5.5087	10.1315	5.9965	2.0998	0.7259	5.0295	5.2369	5.5785	2.8092	0.5177	1.007
Left center pillar	4.3603	0.4483	3.7114	5.7618	4.1909	3.6928	2.9639	5.0093	1.5933	4.5527	3.3309	1.4976	3.4536
Right center pillar	3.2724	0.7755	2.1312	6.0133	3.2586	2.6875	3.107	3.5794	1.6925	4.611	3.2375	9.8725	49.6115
Left front door	2.8794	1.6981	6.7052	9.4117	5.3979	2.376	1.6879	1.7741	5.2927	3.3879	6.6184	6.859	11.8637




Fig. 6. Temperature profiles (heating curves).

The heating and curing curve behavior are shown in Fig. 10. In a manner different from the previous analysis, the linear decrease in the temperature profile for the Elpo oven resulted in two BIW parts outside the recommended region, namely the left center pillar (#6) and the right center pillar (#7), as shown in Fig. 10(b2). The result shows the need to evaluate the temperature decrease in specific zones of the oven to maintain all the curves within the curing conditions.

Specifically, it is possible to evaluate numerous operational conditions using the validated model. These include modifying the temperature profile in the oven via increasing and decreasing set-points to seek curve displacement outside the curing region nearer to the region recommended by the paint manufacturer while always focusing on decreasing energy consumption.

The results are only presented for the Elpo oven because it corresponds to the largest and most complex in a painting process. However, it is possible to predict the behavior of other ovens using the methodology (for e.g., Primer and Clearcoat ovens).

6. Concluding remarks

The study presented a methodology to adjust the heat transfer parameters of the automotive paint drying model based on industrial data for the Elpo oven. By using a multidimensional optimization procedure that developed an objective function, it was possible to determine the heat transfer coefficients from temperature data at specific locations of the car bodies in the oven zones. The optimization procedure was developed for Elpo oven although it can be used for simulation of other ovens, such as Prime and Clearcoat.

The adjusted model can be used to propose new operational scenarios that focus on energy efficiency because the increase in conveyor speed can imply a significant decrease in energy consumption and an increase in productivity, without loss in quality.

The model can be used to generate fast responses to operational disturbances and evaluate changes in curing times, changes in oven structure (such as increasing its length), or changes in operating parameters (such as temperatures of the zones).

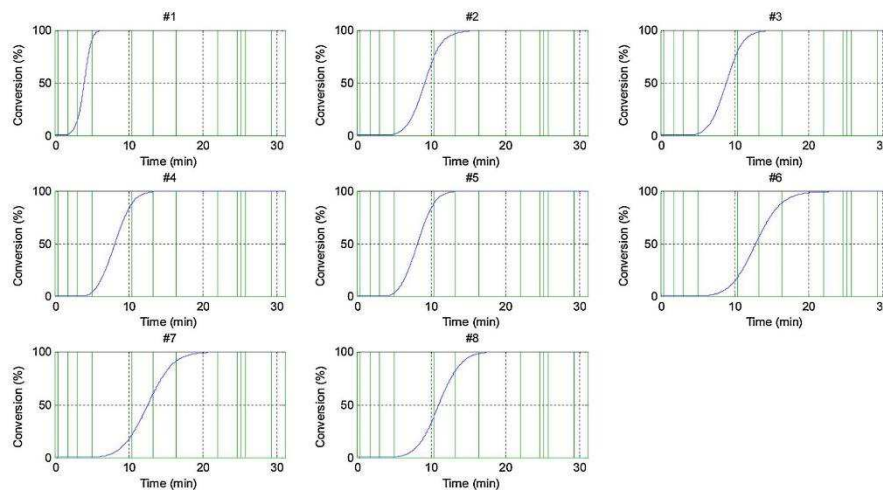


Fig. 7. Curing conversion (cross-linking reaction) in the Elpo oven.

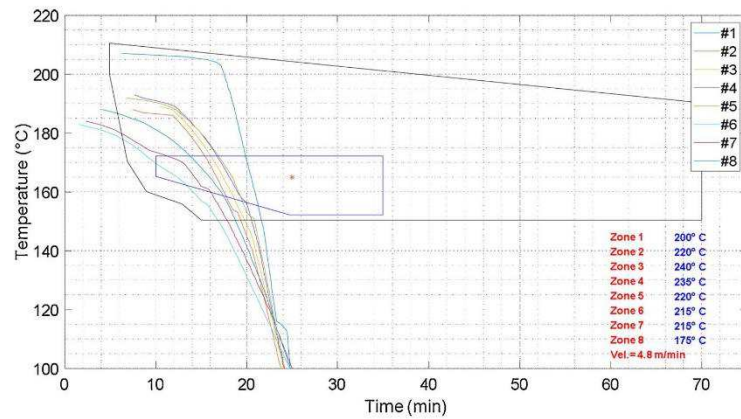


Fig. 8. Transformed temperature profiles in the curing window for the Elpo oven.

Intellectual property

We confirm that we have given due consideration to the protection of intellectual property associated with this work and that there are no impediments to publication, including the timing of publication, with respect to intellectual property. In so doing we confirm that we have followed the regulations of our institutions concerning intellectual property.

Authorship

All listed authors meet the ICMJE criteria. We attest that all authors contributed significantly to the creation of this manuscript, each having fulfilled criteria as established by the ICMJE.

We confirm that the manuscript has been read and approved by all named authors.

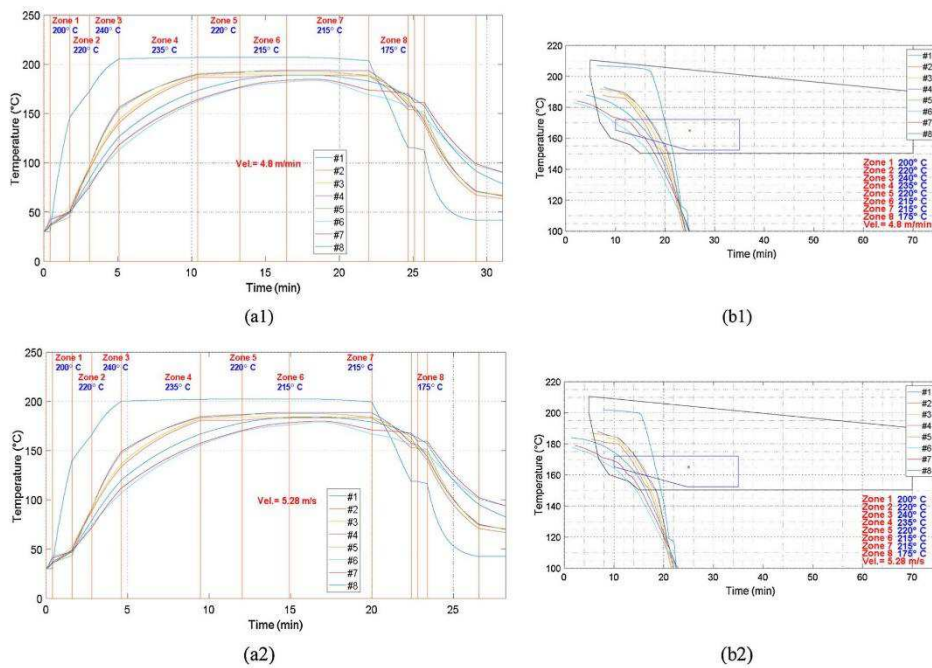


Fig. 9. Elpo oven temperature profiles and transformed temperature profiles in the curing window: (a1) and (b1) base case; (a2) and (b2) conveyor speed increased by 10 %.

APÊNDICE 2: ARTIGO 2 (PUBLICADO EM REVISTA A4)



REVISTA DE GESTÃO E SECRETARIADO
MANAGEMENT AND ADMINISTRATIVE
PROFESSIONAL REVIEW
 ISSN: 2178-9010

Revista GeSec
 São Paulo, SP, Brasil
 v. 14, n.4, p. 5540-5555,
 2023

DOI: <http://doi.org/10.7769/gesec.v14i4.2000>

Soft sensor baseado em redes neurais artificiais para a predição de temperaturas de partes da carroceria em estufas de secagem e cura de pintura automotiva

Soft sensor based on artificial neural networks for predicting temperatures of body parts in automotive paint drying and curing ovens

Esley Silva Cavalcante¹

Luis Gonzaga Sales Vasconcelos²

Romildo Pereira Brito³

Karoline Dantas Brito⁴

Resumo

Dentre os processos que compõem a pintura automotiva, a secagem/cura em estufas caracteriza-se como uma das principais etapas para garantir a qualidade final da pintura. Nesta etapa, as condições ideais de operação das estufas devem ser mantidas rigorosamente, principalmente o perfil de temperatura de partes da carroceria. A obtenção de um modelo representativo permite a previsão e o melhor controle do comportamento do processo. Com o grande avanço da tecnologia, são desenvolvidas novas estratégias de identificação de modelos, dentre as quais destaca-se a utilização de redes neurais artificiais (RNA) para a identificação e controle de processos dinâmicos não-lineares. Este estudo apresentou uma metodologia para o desenvolvimento e implementação de um modelo utilizando RNA para representar o processo que ocorre em uma estufa de secagem/cura de pintura automotiva

¹ Mestre em Engenharia Química, Universidade Federal de Campina Grande (UFCG), R. Aprígio Veloso, 882, Universitário, Campina Grande - PB, CEP: 58429-900. E-mail: esley.cavalcante@eq.ufcg.edu.br
 Orcid: <https://orcid.org/0009-0008-1318-5493>

² Doutor em Engenharia Química, Universidade Federal de Campina Grande (UFCG), R. Aprígio Veloso, 882, Universitário, Campina Grande - PB, CEP: 58429-900. E-mail: luis.vasconcelos@eq.ufcg.edu.br
 Orcid: <https://orcid.org/0000-0001-6660-8906>

³ Doutor em Engenharia Química, Universidade Federal de Campina Grande (UFCG), R. Aprígio Veloso, 882, Universitário, Campina Grande - PB, CEP: 58429-900. E-mail: brito.romildo@outlook.com
 Orcid: <https://orcid.org/0000-0001-9576-2363>

⁴ Doutora em Engenharia Química, Universidade Federal de Campina Grande (UFCG), R. Aprígio Veloso, 882, Universitário, Campina Grande - PB, CEP: 58429-900. E-mail: karolineufcg@gmail.com
 Orcid: <https://orcid.org/0000-0003-2458-359X>



utilizada durante a etapa de pintura por eletrodeposição (Elpo). Para a predição dos valores futuros das temperaturas nas posições de medição na carroceria (partes da carroceria), foi desenvolvido um modelo neural global, compostos por um conjunto das RNA das 13 zonas que formam a estufa. Após a avaliação do desempenho do modelo neural global, verificou-se que o modelo foi capaz de prever, de forma satisfatória, o valor das temperaturas das partes da carroceria ao longo de todo o processo, o que ficou evidenciado nos valores obtidos de coeficientes de ajustes R^2 e de erros médios absolutos percentuais (MAPE). Dessa forma, conclui-se que a metodologia proposta neste trabalho pode ser aplicada para desenvolver estratégias inovadoras de modelagem e predição de condições do processo de secagem e cura de pintura automotiva em estufas, e que o modelo neural global obtido pode ser utilizado como um Soft Sensor baseado na aplicação da técnica de RNA.

Palavras-chave: Redes Neurais Artificiais. Soft Sensor. Indústria Automotiva. Processo de Pintura. Estufas de Cura e Secagem.

Abstract

Among the processes that make up automotive painting, drying/curing in ovens is characterized as one of the main steps to guarantee the final quality of the painting. At this stage, the ideal operating conditions for the stoves must be rigorously maintained, especially the temperature profile of body parts. Obtaining a representative model allows prediction and better control of process behavior. With the great advancement of technology, new strategies for model identification are being developed, among which stands out the use of artificial neural networks (ANN) for the identification and control of non-linear dynamic processes. This study presents a methodology for the development and implementation of a model using ANN to represent the process that occurs in an automotive paint drying/curing oven used during the electrodeposition painting step (Elpo). For the prediction of future values of temperatures at measurement positions on the bodywork (parts of the bodywork), a global neural model was developed, composed of a set of ANNs from the 13 zones that form the greenhouse. After evaluating the performance of the global neural model, it was verified that the model was able to predict, in a satisfactory way, the temperature value of the bodywork parts throughout the entire process, which was evidenced in the obtained values of coefficients of R^2 fits and mean absolute percentage errors (MAPE). Thus, it is concluded that the methodology proposed in this work can be applied to develop innovative strategies for modeling and predicting the conditions of the drying and curing process of automotive paint in greenhouses, and that the global neural model obtained can be used as a Soft Sensor based on the application of the ANN technique.



Keywords: Artificial Neural Networks. SoftSensor. Automotive Industry. Painting Process. Curing and Drying Ovens.

Introdução e Contextualização

Durante o processo de pintura na indústria automotiva, a carroceria é movida por um transportador a uma velocidade constante, sendo submetido à aplicação, secagem e cura de três ou mais revestimentos orgânicos (Dickie et al, 1997). As etapas de aplicação dos revestimentos orgânicos são realizadas em cabines de pintura, enquanto as etapas de secagem e cura são realizadas em estufas, que apresentam dimensionamento específicos (comprimento, largura, altura) e operam a temperaturas específicas.

Segundo Elahi 2009, na maioria das indústrias automotivas, a aplicação, secagem e cura são realizadas em uma etapa por eletrodeposição (etapa Elpo) e em três etapas por pulverização (Primer, Basecoat e Clearcoat).

O estudo e desenvolvimento de modelos representativos é vital para compreensão e otimização desses processos, evitando a ocorrência de falha e promovendo a redução do custo com energia. A literatura aberta apresenta diversos trabalhos que propõem modelos matemáticos e estudos utilizando técnicas de fluidodinâmica computacional (CFD), com foco no processo de secagem e cura de pintura automotiva (Lou e Huang, 2000; Zelder et al., 2009; Rao et al., 2013; Song et al., 2015; Mehdipour et al., 2015; Vasudevan et al., 2018).

Estes modelos são precisos, embora existam empecilhos para suas implementações, devido à grande quantidade de parâmetros e complexidade envolvida na determinação dos mesmos. No que diz respeito especificamente aos estudos em CFD, estes são em sua maioria computacionalmente demorados, demandando a utilização de equipamentos com alto custo de aquisição, além de tipicamente serem aplicados na fase de projeto, em mudanças estruturais ou mudanças operacionais em estado estacionário.

Neste contexto, com o avanço da tecnologia, são desenvolvidas novas estratégias de identificação de sistemas, e a utilização de RNA na identificação de processos dinâmicos não-lineares vem ganhando grande espaço, visto que é possível obter um modelo neural capaz de representar rigorosamente os processos analisados.

As RNA são sistemas de inteligência artificial baseados em redes neurais biológicas, capazes de realizar o aprendizado e estimar condições futuras com base em um conjunto de dados. Entretanto, na literatura consultada não se encontrou trabalhos com a utilização de

RNA para a previsão das temperaturas das partes da carroceria automotiva, variáveis estas que influenciam diretamente na qualidade da pintura.

Na busca por alternativas de melhorias no controle de temperatura das partes da carroceria automotiva ao longo de uma estufa de secagem e cura de pintura automotiva, a proposta deste trabalho consiste em desenvolver e implementar um Soft Sensor para o processo em questão, o qual irá utilizar um modelo baseado em RNA para prever os valores futuros das temperaturas das partes da carroceria.

O estudo foi aplicado a estufa utilizada durante a etapa de pintura por eletrodeposição (estufa Elpo), a qual é uma das maiores consumidoras de combustíveis da planta industrial considerada. A estufa Elpo, representada pela Figura 1, é dividida em zonas, e os mecanismos de transferência de calor ocorrem por convecção nas zonas de “Entrada” e “Cortina de Entrada”, por radiação e convecção nas zonas 1 e 2, enquanto o mecanismo de aquecimento convectivo ocorre nas zonas seguintes.

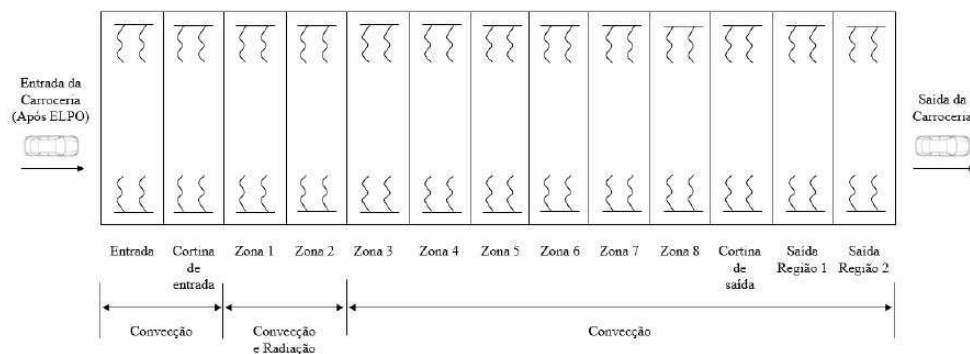



Figura 1 - Representação da estufa Elpo.

Treinamento e Validação do Modelo Global de Redes Neurais Artificiais

Para a implementação do Soft Sensor com base em RNA, é necessário realizar a identificação do sistema; ou seja, encontrar um modelo que represente o sistema que se pretende controlar, que neste trabalho é representado pelo processo de cura e secagem na estufa Elpo. Neste sentido, a identificação do sistema será obtida através da aplicação do treinamento das RNA. O treinamento, também conhecido como aprendizado, é a etapa onde se codificam as informações referentes ao processo, através da utilização de dados de entrada e saída coletados.

Neste trabalho, a arquitetura das RNA utilizadas foi do tipo *feedforward* de múltiplas camadas, com apenas uma camada oculta, e o treinamento foi realizado através da utilização do algoritmo *Backpropagation*.

Inicialmente foram escolhidas quais variáveis do processo seriam consideradas como variáveis manipuladas (variáveis de entradas) e variáveis controladas (variáveis de saídas). Desta forma, avaliando as necessidades operacionais de controle da qualidade de secagem e cura de pintura na estufa Elpo, foram definidas como variáveis de entrada (manipuladas) a velocidade do transportador da carroceria ($x_{1,j}$) e as temperaturas das zonas ($x_{2,j}$), enquanto como variáveis de saída (controladas) foram definidas as temperaturas das posições de medições na carroceria, em cada uma das zonas ($y_{k,j}$), com k variando até o total de posições de medições na carroceria (8 posições) e j variando até o total de zonas (13 zonas). A Figura 2 apresenta a localização das partes da carroceria (posições de medição) que foram estudadas na estufa Elpo.



Legenda:

- #1 Temperatura do ar próxima ao capô;
- #2 Teto dianteiro esquerdo;
- #3 Teto dianteiro direito;
- #4 Meio teto esquerdo;
- #5 Meio teto direito;
- #6 Coluna do meio esquerda;
- #7 Coluna do meio direita;
- #8 Porta dianteira esquerda;

Figura 2 - Partes monitoradas da carroceria.

Pela característica dinâmica do processo, aliado ao fato da estufa Elpo apresentar 13 zonas com condições operacionais e dimensionais distintas, verificou-se que o modelo neural dever ser configurado para realizar a predição por zona, na medida que a carroceria é transportada ao longo da estufa.

Desta forma, para cada uma das zonas foi necessário treinar e identificar uma RNA para considerar a velocidade do transportador da carroceria e a temperatura da zona como variáveis de entrada ($x_{1,j}$ e $x_{2,j}$), e as temperaturas das posições de medições na carroceria ($y_{k,j}$) como variáveis de saída.

Para tornar os modelos neurais mais precisos, adicionou-se como variáveis de entrada para o treinamento, a partir da segunda zona da estufa (Cortina de entrada), as temperaturas das posições de medições na carroceria da zona anterior. Desta forma, a partir da segunda zona da estufa, a configuração das RNA é constituída de 10 variáveis de entrada e 8 variáveis de saída. A Figura 3 apresenta a representação da configuração geral das RNA da estufa Elpo.

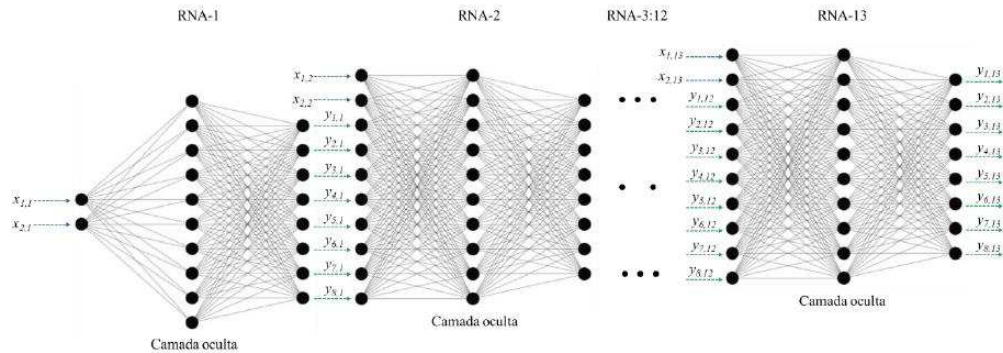


Figura 3 - Representação da configuração geral das RNA das zonas da estufa Elpo.

Após a definição das variáveis de entrada e de saída, foi necessário efetuar a aplicação de perturbações sobre cada variável de entrada, de modo a ser possível obter as respostas dinâmicas do processo à estas perturbações, com o objetivo de gerar o banco de dados para os treinamentos das RNA.

Deste modo, utilizando o modelo fenomenológico implementado e validado da estufa Elpo em Cavalcante et al. 2020, através da utilização da função “*rand*” do Matlab®, aplicou-se distúrbios do tipo randômicos na velocidade do transportador e nas temperaturas das zonas, conforme a Equação (1):

$$R = X \{1 + [a + (b - a)rand(1,1)]\} \quad (1)$$

Onde R é a matriz com valores randômicos das variáveis de entrada, X é a matriz com os valores nominais das variáveis de entrada, a é a variação negativa, b é a variação positiva. Para o treinamento, foram definidas variações de -10% (a) e 10% (b) nas variáveis de entrada. Vale salientar que foram definidas tais variações (-10% e 10%) pois após consultar os dados disponíveis, verificou-se que as variáveis manipuladas normalmente não variam tanto no processo, e com isso, as variações especificadas apresentam um range aceitável para o treinamento.

Com o objetivo de verificar o desempenho do treinamento das RNA com o aumento da quantidade de dados, foram gerados bases de dados com 100, 200, 300, 400, 500 e 1000 casos simulados, com cada caso simulado sendo gerado através da utilização de uma matriz randômica das variáveis de entrada com valores diferentes. O Algoritmo para a geração do banco de dados para o treinamento das RNA é apresentado na Figura 4.

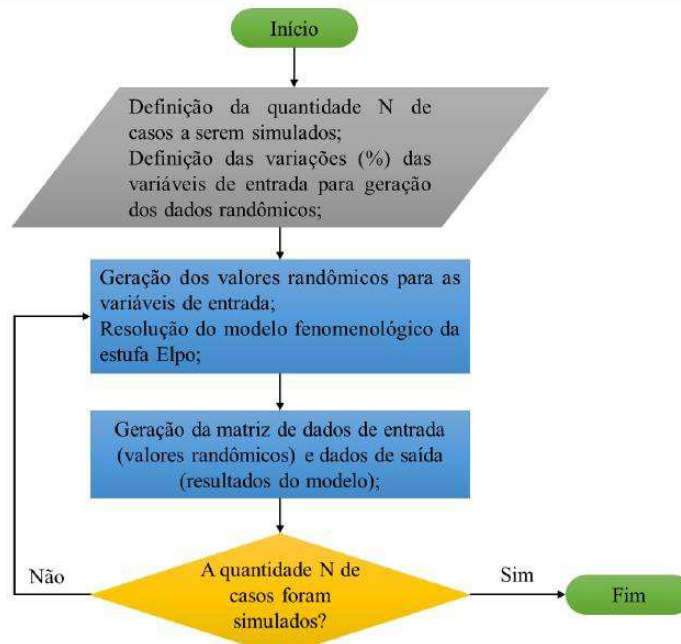


Figura 4 - Algoritmo para a geração do banco de dados para o treinamento.

Após a obtenção do banco de dados para os treinamentos formados pelas variáveis de entradas randômicas e as variáveis de saída (respostas do modelo), iniciou-se os procedimentos de treinamentos das RNA. Os treinamentos foram realizados de forma separada para cada uma das bases de dados com 100, 200, 300, 400, 500 e 1000 casos, através da utilização da função “*trainlm*” do Matlab[®]. É importante destacar que para todos os treinamentos realizados, os dados disponíveis (100, 200, 300, 400, 500 e 1000) foram separados em dados de treinamento (80% dos dados), dados de validação (10% dos dados) e dados de teste (10% dos dados).

Após os treinamentos, comparou-se os resultados dos treinamentos, validações e testes das RNA, para cada uma das bases de dados com 100, 200, 300, 400, 500 e 1000 casos simulados.

As comparações dos resultados para as 13 zonas da estufa mostraram que a utilização da base de dados com 500 casos simulados gerou resultados mais satisfatórios quando comparados as demais bases de dados, no que diz respeito a predição das temperaturas das 8 partes da carroceria nas 13 zonas.

Quando os resultados treinamento realizado com a base de dados com 500 casos são comparados com os resultados dos treinamentos realizados com quantidade de dados menores (100, 200, 300 e 400), observa-se que aumento de dados de treinamento proporcionou a obtenção de modelos neurais com melhores resultados de predição das temperaturas das 8 partes de medições. Entretanto, o aumento da base de dados para 1000 casos simulados não



resultou em melhorias tão significativas nos resultados de predição, além do treinamento ter sido computacionalmente mais demorado, quando comparado ao treinamento com 500 casos.

Desta forma, com base na identificação das RNA para as 13 zonas com a utilização do banco de dados com 500 casos, a Tabela 1 apresenta os resultados dos coeficientes de ajustes R^2 para o treinamento (80% dos dados = 400 casos), validação (10% dos dados = 50 casos), teste (10% dos dados = 50 casos) e global das RNA. É possível observar que as RNA obtidas para todas as zonas apresentaram valores de coeficientes de ajuste R^2 acima de 0,99, demonstrando ótimos ajustes dos modelos neurais durante as etapas de treinamento, validação e testes de predições das temperaturas das partes da carroceria.

Zona	Treinamento	Validação	Teste	Global
Entrada da estufa	0,9948	0,9949	0,9967	0,9949
Cortina de entrada	0,9995	0,9962	0,9996	0,9996
Zona 1	0,9996	0,9996	0,9996	0,9996
Zona 2	0,9984	0,9985	0,9983	0,9984
Zona 3	0,9931	0,9907	0,9919	0,9927
Zona 4	0,9989	0,9985	0,9981	0,9988
Zona 5	0,9989	0,9986	0,9985	0,9988
Zona 6	0,9997	0,9995	0,9995	0,9996
Zona 7	0,9998	0,9998	0,9997	0,9998
Zona 8	0,9999	0,9999	0,9999	0,9999
Cortina de saída	0,9999	0,9999	0,9999	0,9999
Saída da estufa (Região 1)	0,9984	0,9986	0,9979	0,9984
Saída da estufa (Região 2)	1,0000	1,0000	1,0000	1,0000

Tabela 1 - Coeficientes R^2 para o treinamento, validação, teste e global das RNAs.

A Figura 5 apresenta os gráficos com os resultados dos coeficientes de ajustes R^2 para o treinamento, validação, teste e global para as duas primeiras zonas da estufa. Vale salientar que para as outras zonas, os gráficos apresentam os mesmos comportamentos, conforme os valores apresentados na Tabela 1. A Tabela 2 apresenta o resumo dos resultados das análises de performance das RNA com base em diferentes quantidades de épocas, onde foi realizada a seleção da quantidade de épocas que apresentaram os melhores ajustes, com base no cálculo do erro médio quadrático (MSE).

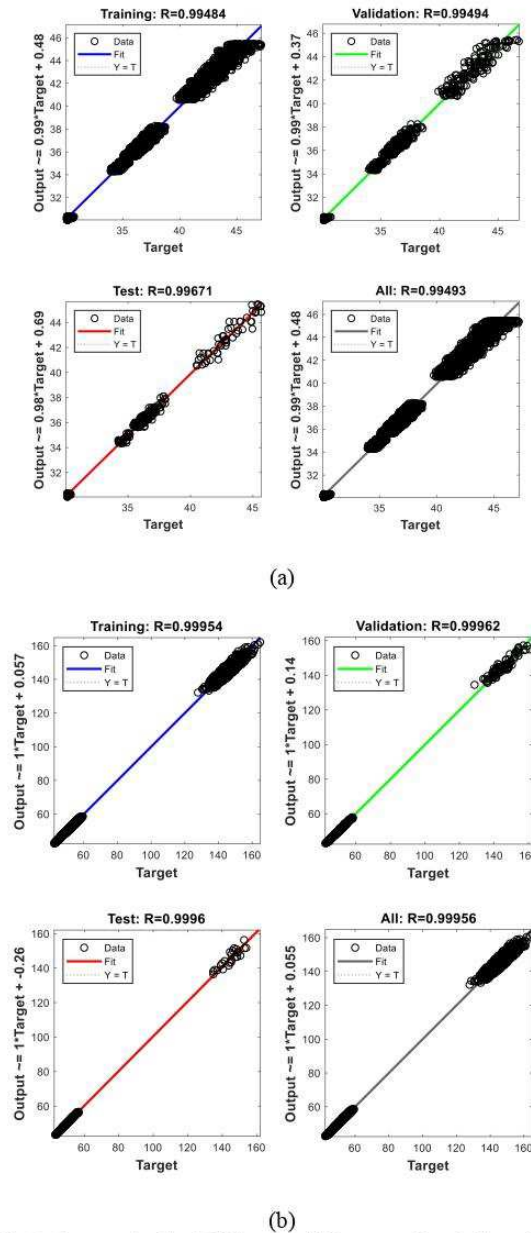


Figura 5 - Resultados do treinamento das RNA com 500 casos simulados: (a) Estrada da Estufa e (b) Cortina de Entrada.

Zona	Quantidade de Épocas	Erro médio quadrático (MSE)
Entrada da estufa	1	0,165
Cortina de entrada	4	0,775
Zona 1	7	0,702
Zona 2	8	2,425
Zona 3	14	4,478
Zona 4	20	0,385
Zona 5	38	0,249
Zona 6	37	0,137
Zona 7	29	0,107
Zona 8	10	0,008



Cortina de saída	52	0,014
Saída da estufa (Região 1)	9	0,966
Saída da estufa (Região 2)	65	0,001

Tabela 2 - Resultados para os testes com diferentes quantidades de épocas para as RNA.

Análise de Performance do Soft Sensor

Para avaliar o desempenho do modelo neural obtido como Soft Sensor para a predição das temperaturas das partes da carroceria, o modelo formado pelas RNA identificadas para as 13 zonas da estufa Elpo foi utilizado para simular o cenário do caso base (*setpoints* operacionais), utilizando os valores das variáveis de entrada apresentados na Tabela 3.

Zona	Temperatura das zonas (°C)	Velocidade do transportador (m/min)
Entrada da estufa	40	4,8
Cortina de entrada	73	4,8
Zona 1	200	4,8
Zona 2	220	4,8
Zona 3	240	4,8
Zona 4	235	4,8
Zona 5	220	4,8
Zona 6	215	4,8
Zona 7	215	4,8
Zona 8	175	4,8
Cortina de saída	72	4,8
Saída da estufa (Região 1)	40	4,8
Saída da estufa (Região 2)	40	4,8

Tabela 3 - Condições operacionais da estufa Elpo: Caso base.

As Figuras 6 e 7 apresentam as comparações entre os valores de temperaturas das partes da carroceria do caso base e os valores preditos pelo modelo neural, onde é possível observar que as temperaturas das posições da carroceria preditas pelo modelo neural apresentam-se bem ajustadas aos valores de *setpoints* ao longo de todo o processo, conforme apresentado nas linhas na cor azul.

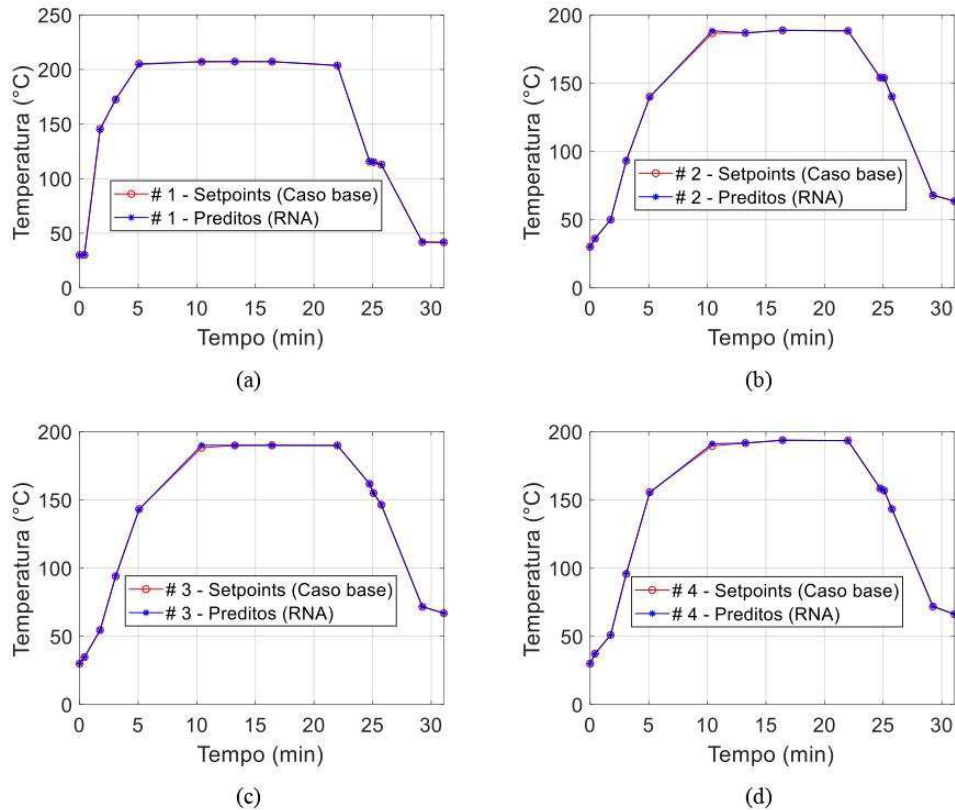



Figura 6 - Resultados de predição: (a) #1 Temperatura do Ar próxima ao capô, (b) #2 Teto dianteiro esquerdo, (c) #3 Teto dianteiro direito e (d) #4 Meio teto esquerdo.






Figura 7 - Resultados de predição: (a) #5 Meio teto direito, (b) #6 Coluna do meio esquerda, (c) #7 Coluna do meio direita e (d) #8 Porta dianteira esquerda.

Como uma segunda forma de avaliar o desempenho do Soft Sensor, o modelo também foi utilizado para prever as temperaturas das partes, para os casos utilizados na validação (10% dos dados) e no teste (10% dos dados), totalizando 100 casos simulados, sendo posteriormente realizado o cálculo do erro médio absoluto percentual (MAPE) para cada uma das partes de medições, em cada zona, através da comparação entre os valores presentes na base de dados e os valores calculados pelas RNA, com base na utilização da Equação (2):

$$MAPE_k = \frac{\sum_{i=1}^q \left(\frac{|y_{i,k,j} - \widehat{y}_{i,k,j}|}{y_{i,k,j}} \right)}{q} \cdot 100 \quad (2)$$

Onde q é a quantidade de simulações realizadas (100 casos simulados), $y_{i,k,j}$ são os valores de temperaturas presentes na base de dados, e $\widehat{y}_{i,k,j}$ são os valores de temperaturas preditos pelos modelos de RNA, para cada k posição de medição, em cada zona j , com j variando até o total de zonas m (13 zonas). É possível observar na Tabela 4 que em todas as zonas da estufa, as predições das temperaturas das partes da carroceria apresentaram valores de MAPE menores que 3,6155%, o que reafirma os ótimos desempenhos das RNA obtidas.



	Entrada da estufa	Cortina de entrada	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 6	Zona 7	Zona 8	Cortina de saída	Saída da estufa (região 1)	Saída da estufa (região 2)
Temperatura do Ar próxima ao capô	0,2621	1,5634	0,6109	1,1282	0,2262	0,0548	0,0449	0,0460	0,5576	0,1212	0,0321	3,6155	0,0316
Teto dianteiro esquerdo	0,6386	0,5086	0,8450	0,9366	1,1350	0,0568	0,1535	0,0333	0,1862	0,0477	0,1108	1,2376	0,0605
Teto dianteiro direito	0,5181	0,6665	0,7783	0,9711	1,1246	0,1037	0,0346	0,0476	0,1587	0,0219	0,0563	1,1307	0,0583
Meio teto esquerdo	0,7296	0,5009	0,8685	1,1261	0,9616	0,1225	0,2159	0,0489	0,1701	0,0376	0,0982	1,1008	0,0521
Meio teto direito	0,6859	0,3575	0,9592	1,0999	1,0646	0,1176	0,0601	0,0823	0,1128	0,0671	0,1029	1,2027	0,0673
Coluna do meio esquerda	1,2152	0,2850	0,6978	0,7439	1,0195	0,4216	0,2881	0,3351	0,0888	0,0119	0,0547	0,5077	0,0335
Coluna do meio direita	1,0600	0,3910	0,6245	0,8663	0,9742	0,3948	0,3624	0,2489	0,0380	0,0572	0,0692	0,5677	0,0378
Porta dianteira esquerda	0,6426	0,4645	0,7429	0,8738	1,0469	0,4023	0,3125	0,1211	0,0820	0,0099	0,0387	0,6563	0,0286

Tabela 4 - Erro médio absoluto percentual (MAPE) dos valores calculados pelas RNAs para cada uma das partes de medições, em cada zona.



Conclusões

Este trabalho apresentou uma metodologia para o desenvolvimento e implementação de um Soft Sensor para o processo de uma estufa de secagem e cura de pintura automotiva. O estudo foi aplicado para a estufa que é utilizada durante a etapa de pintura por eletrodeposição (Elpo), buscando melhorias na predição e controle de temperatura das partes da carroceria automotiva ao longo da estufa, resultando na minimização dos problemas na pintura.

A partir do modelo fenomenológico implementado, ajustado e validado foi possível utilizá-lo para obter o banco de dados necessários para a obtenção do modelo neural do processo da Estufa Elpo, através de aplicações de distúrbios nas variáveis de entrada (manipuladas) do processo.

Com os dados obtidos, foi possível realizar os treinamentos, validações e testes das RNA para todas as zonas da estufa, obtendo modelos neurais (13 RNA; uma para cada zona da estufa Elpo) que apresentaram valores de coeficientes de ajustes R^2 acima de 0,99, demonstrando ótimas respostas das RNA nas predições das temperaturas das partes da carroceria ao longo da estufa.

Nos testes de performance do Soft Sensor, o modelo neural global foi capaz de prever com alta acurácia os valores de *setpoint* (caso base) das temperaturas das partes da carroceria, e após realizar as predições com os dados de testes e validação (100 casos no total), o cálculo do erro médio absoluto percentual (MAPE) para cada uma das partes da carroceria para demonstrou que em todas as zonas da estufa, as predições das temperaturas apresentaram valores de MAPE menores que 3,6155%.

Desta forma, conclui-se que o modelo baseado em RNA implementado para a estufa Elpo foi capaz de realizar de forma satisfatória a predição em tempo real das temperaturas das partes da carroceria ao longo do processo, indicando que o modelo proposto pode ser aplicado como uma ferramenta *Soft Sensor*, podendo a metodologia desenvolvida neste trabalho ser aplicada também em outros equipamentos, tais como as estufas de Vedação, Primer e Base/Verniz.

Agradecimentos

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro para este estudo.



Nomenclatura

Símbolo	Significado	Unidade
y_i	Saída objetivada do neurônio artificial i	°C
\hat{y}_i	Saída calculada pela rede neural artificial para o neurônio artificial i	°C
y_m	Sinal de saída predito pelo modelo neural	°C
$x_{1,j}$	Velocidade do transportador da carroceria nas zonas (Variáveis de entrada 1)	m/min
$x_{2,j}$	Temperaturas das zonas (Variáveis de entrada 2)	°C
$y_{k,j}$	Temperaturas das partes da carroceria medidas (Variáveis de saída)	°C
$\widehat{y}_{k,j}$	Temperaturas das partes da carroceria preditos pelos modelos de RNA	°C
R	Matriz com valores randômicos das variáveis manipuladas	-
X	Matriz com os valores nominais das variáveis manipuladas	-
a	Varição negativa de distúrbio para geração de valores randômicos, -10%	-
b	Varição positiva do distúrbio para geração de valores randômicos, +10%	-
MAPE	Erro médio absoluto percentual	%
MAE	Erro médio absoluto	-
MSE	Erro médio Quadrático	-

Referências

- Cavalcante, E. S.; Vasconcelos, L. G. S.; Neto, G. W. de F.; Ramos, W. B.; Brito, R. P. Automotive Painting Process: Minimizing Energy Consumption by Using Adjusted Convective Heat Transfer Coefficients. *Progress in Organic Coatings*, Vol 140, 2020.
- Dickie, R. A.; Bauer, D. R.; Ward, S. M.; Wagner, D. A. Modeling Paint and Adhesive Cure in Automotive Applications. *Progress in Organic Coatings*, 1997, vol-31, pp. 209-216.
- Elahi, M. M. L.; Záruba, G. V.; Rosenberg, J.; Rajpurohit, K. Modeling and Simulation of a General Motors Conveyor System using a Custom Decision Optimizer. Master's Thesis. Department of Computer Science and Engineering, University of Texas at Arlington, Arlington, Texas, 2009.
- Lagarias, J. C., J. A. Reeds, M. H. Wright, and P. E. Wright. Convergence Properties of the Nelder-Mead Simplex Method in Low Dimensions. *SIAM Journal of Optimization*. Vol. 9, Number 1, 1998, pp. 112-147.
- Lou, H. H.; Huang, Y. L. Integrated Modeling and Simulation for Improved Reactive Drying of Clearcoat. *Ind. Eng. Chem. Res.*, 2000, vol-39, pp. 500-507.
- MATHWORKS. Neural Network Toolbox User's Guide. Version 4. MathWorks Inc. 2002.
- Mehdipour, R.; Baniamerian, Z.; Sattar, S. Evaluation of Continuous Convection and Radiation Ovens in Automobile Cure Industry. *International Journal of Automotive Engineering*, 2015, vol-5, pp. 1054-1066.
- Radfar, R.; Jassbi, J.; Ghoreishi, F.; Khanmohammadi, S.; Alborzi, M. Proactive Quality Paint Thickness Control Using ANFIS. *IEEE - International Conference on Systems, Man and Cybernetics*, 2010.



- Rao, P.P.; Gopinath, A. Energy Savings in Automotive Paint Ovens: A New Concept of Shroud on The Carriers. *Journal of Manufacturing Science and Engineering*, 2013, 135, pp. 1-9.
- Rao, S. S. *Engineering Optimization. Theory and Practice*. 4th ed. Ed. John Wiley & Sons, Inc. 2009.
- Song, H.; Xiao, J.; Huang.Y. Multiscale Modeling and Optimization of Nano Clearcoat Curing for Energy Efficient and Quality Assured Coating Manufacturing. *Ind. Eng. Chem. Res.*, 2015, vol-55, pag-3351-3359.
- Vasudevan, M. *Numerical Modelling off Paint Curing in Convective Ovens*. Master's Thesis. Mechanics and Maritime Sciences. Chalmers University of Technology, Goteborg, Sweden, 2018.
- Xiao, J.; Li, J; Lou, H. H.; Huang.Y. Cure-Window-Based Proactive Quality Control in Topcoat Curing. *Ind. Eng. Chem. Res.*, 2006, vol-45, pag-2351-3360.
- Zelder, G.; Steinbeck-Behrens, C. *Simulation on Car Body Painting Processes*. 4th European Automotive Simulation Conference, July 2009.

Submetido em: 17.03.2023

Aceito em: 20.04.2023

APÊNDICE 3: ARTIGO 3 (PUBLICADO EM REVISTA A1)


Progress in Organic Coatings 183 (2023) 107773



Contents lists available at ScienceDirect

Progress in Organic Coatings

journal homepage: www.elsevier.com/locate/porgcoat



Neural network predictive control applied to automotive paint drying and curing processes

Esley Silva Cavalcante, Luís Gonzaga Sales Vasconcelos, Karoline Dantas Brito*, Romildo Pereira Brito

Federal University of Campina Grande, Department of Chemical Engineering, Campina Grande, PB 58109-970, Brazil

ARTICLE INFO

Keywords:

Automotive industry
Painting process
Drying and curing ovens
Artificial neural networks
Neural predictive control

ABSTRACT

In the automotive painting process, maintaining optimal operating conditions in drying and curing ovens is crucial to ensure high-quality paint finishes, particularly for specific car body-in-white (BIW) parts' temperature profiles. This paper presents a methodology for developing and implementing a Neural Network Predictive Control (NNPC) system for painting drying and curing processes in an automotive oven used in the electrodeposition stage (Elpo oven). The objective is to enhance temperature control for BIW parts. To train the Artificial Neural Networks (ANN) in the various zones of the Elpo oven, a dataset was generated using a phenomenological model based on first principles. Random disturbances were applied to the input variables (conveyor speed and zone temperatures) to capture the dynamic response of the output variables (temperature in specific BIW parts). The dataset was split into training (80%), validation (10%), and test (10%) sets, and the ANN training was performed using the backpropagation algorithm. The implemented NNPC utilizes the trained ANNs to predict future temperature values in specific BIW parts (controlled variables). To determine the optimal control signals (manipulated variables), an optimizer based on the Generalized Predictive Control (GPC) model was employed, and the objective function was minimized using the Ant Colony Optimization Algorithm (ACO). Through simulations of four operational scenarios with applied disturbances, the results demonstrate satisfactory performance of the NNPC, effectively maintaining controlled temperatures of BIW parts close to predefined setpoints. The utilization of NNPC offers improved temperature control for BIW parts, mitigating painting issues, reducing rework and operating costs, while ensuring painting quality is uncompromised.

1. Introduction and context

During the automotive painting process, the car body (BIW) is transported on a conveyor at a constant speed and undergoes the application, drying, and curing of three or more organic coatings [1]. The application of organic coatings are carried out in paint booths, while the drying and curing stages occur in ovens with specific dimensions (length, width, and height) and operate at predetermined temperatures. According to Elahi [2], in most automotive industries, after the initial paint layer is applied, drying and curing are combined in a single step through electrodeposition (Elpo), while the remaining paint layers are applied using spraying techniques in three stages (Primer, Basecoat, and Clearcoat).

In the literature, numerous well-established studies can be found, demonstrating significant advancements in the automotive painting process.

Poozesh et al. [3] discuss the importance of enhancing paint transfer efficiency in automotive spray painting to minimize costs, energy consumption, and environmental impacts. The review assesses various automotive spray coating technologies and their corresponding transfer efficiencies, focusing on the fundamental and operational parameters that influence them. It provides a comprehensive characterization of different paint spray applicators, including air sprayers, high-volume low-pressure sprayers, airless sprayers, and others. The article also addresses challenges associated with evaluating and improving paint transfer efficiencies, while considering the potential and technological requirements for the development of these applicators.

Pendar et al. [4,5] provide a comprehensive overview of the paint shop, encompassing paint film layers, spray applicators, and their advancements. The review delves into coating processes, curing ovens, and highlights significant factors such as surface durability, corrosion protection, paint consumption, and environmental impact. It places emphasis on understanding the physics of electrostatic spray-painting,

* Corresponding author.

E-mail address: karolineufcg@gmail.com (K.D. Brito).

<https://doi.org/10.1016/j.porgcoat.2023.107773>

Received 16 March 2023; Received in revised form 4 June 2023; Accepted 22 June 2023

Available online 27 June 2023

0300-9440/© 2023 Elsevier B.V. All rights reserved.

Nomenclature	
y_i	Objectified output of the artificial neuron i , °C
\hat{y}_i	Output calculated by the artificial neural network for artificial neuron i , °C
y_m	Output signal predicted by the neural model, °C
$x_{1,j}$	Car body conveyor speed in zones (Input variables 1), m/min
$x_{2,j}$	Zone temperatures (Input variables 2), °C
$y_{k,j}$	Temperatures of measured car body parts (Output variables), °C
$\hat{y}_{k,j}$	Temperatures of car body parts predicted by artificial neural network models, °C
R	Matrix with random values of manipulated variables
X	Matrix with nominal values of manipulated variables
a	Negative variation of the disturbance to generate random values, -10 %
b	Positive variation of the disturbance to generate random values, +10 %
J	Objective function of the generalized predictive control (GPC)
y_r	Controller output signal reference
y_m	Output signal predicted by the neural model
N_1	Minimum prediction horizon
N_2	Maximum prediction horizon
u	Control signal
Δu	Control action variation
MAPE	Mean absolute percentage error, %
MAE	Mean absolute error
MSE	Mean Square Error
IAE	Integral Absolute Error
BIW	Body-in-white

as well as the baking and drying processes. The review identifies knowledge gaps and aims to enhance sustainability and efficiency in automotive paint shop operations.

The development of mathematical models is essential for understanding and optimizing the aforementioned steps, mitigating the occurrence of failures, and enabling cost reduction in energy consumption. The existing literature includes numerous works proposing phenomenological models and studies utilizing computational fluid dynamics techniques.

In Lou and Huang [6], a simplified, first principles-based dynamic model is developed to characterize the clearcoat drying process in an oven. The model demonstrates its capability to provide accurate long-term predictions of film build, enabling a detailed analysis of drying/curing operations.

Zelder and Steinbeck-Behrens [7] employed computational fluid dynamics (CFD) techniques using the VPS/DRY module (CADFEM GmbH) to analyze the temperature profile of the car body-in-white (BIW) during the drying process in an oven. The obtained results can be utilized to generate an oven curve for each location on the BIW.

Rao and Gopinath [8] employed a semi-computational approach, combining a computational fluid dynamics (CFD) solver and a thermal network solver, to forecast the temperatures of car body-in-white (BIW) parts during the baking process in an automotive paint oven. They proposed the concept of using a shroud to cover carriers, providing partial protection against the hot air emitted by the oven. This innovative approach resulted in a substantial reduction in the oven's energy consumption.

Mehdipour et al. [9] conducted a comparative study between radiation and convection ovens using computational fluid dynamics (CFD) techniques and the moving boundary method. The findings indicated that the use of radiation ovens resulted in a remarkable 50 % energy savings compared to convection ovens.

Vasudevan [10] conducted an experimental study to develop a methodology for optimizing the heat transfer coefficient in the heat transfer solver, as well as a model parameter representing evaporation at the paint layer-air interface in the mass transfer solver. The findings of the study revealed that the heat transfer coefficient is only weakly dependent on the solvent concentration.

Despotovic and Babić [11] present a mathematical model aimed at simulating energy flows in car paint ovens. The model enables the analysis of various variables and their impact on operating parameters, such as air and car body temperature. This valuable information can assist designers in selecting optimal scenarios for designing new or reconfiguring existing car paint ovens, with the objective of attaining the desired indoor air temperature.

Cavalcante et al. [12] present a methodology to fine-tune the

mathematical model of a paint-curing oven. The authors achieve this by determining convection heat transfer coefficients through the analysis of industrial data. The adjusted model is then utilized to predict new operational scenarios for the Elpo oven.

Pendar et al. [4,5] conducted an evaluation of conjugate heat transfer in an automotive paint oven with the aim of optimizing performance and energy efficiency. The study utilized computational fluid dynamics (CFD) analysis to model the complex geometry of vehicles and capture the transient nature of the process. Through the optimization of intake flow rate and oven geometry, improvements in energy efficiency were achieved. The analysis examined fluid dynamics across different oven zones, the temperature distribution on the car body, and identified optimal arrangements of nozzles and panels. The findings of the study contribute to enhancing paint quality and improving manufacturability.

Although these models are accurate, their implementation is subject to certain restrictions, particularly in terms of optimization and control problems. This is primarily due to the need to determine a large number of parameters and the inherent complexity involved. Furthermore, computational fluid dynamics studies require significant computational effort, making them more suitable for the design phase, particularly for structural modifications or steady-state operational changes.

The utilization of Artificial Neural Networks (ANN) provides a feasible solution for identifying and controlling nonlinear dynamic processes, as it allows for the development of a neural model that accurately captures the process dynamics. With an ANN-based system, it becomes possible to learn from historical data and make estimations about future conditions. Neural Network Predictive Control (NNPC) is a control strategy that employs an ANN-based model to forecast the future response of the process and take appropriate actions to stabilize its output in accordance with a reference.

In a quality control study of paint thickness during the topcoat spray painting step (Basecoat and Clearcoat), Radfar [13] utilized an Adaptive Neuro-Fuzzy Inference System (ANFIS). The findings of the study demonstrated that the ANFIS model exhibited favorable performance, thus highlighting its effectiveness in this context.

In a study by Jassbi [14], an investigation was conducted to enhance the proactive control of paint thickness during the topcoat step using Artificial Neural Network (ANN) and regression techniques. The developed models exhibited satisfactory outcomes for most paint layers, except for the final layer, where the regression models did not yield acceptable results.

In a study conducted by Ma [15], multiple linear regression models and Artificial Neural Networks (ANN) were employed to forecast real-time heating energy demand and natural gas consumption in the curing and drying ovens of an automotive painting line. The ANN-based model demonstrated a prediction reliability exceeding 92 %, enabling

satisfactory prediction and control of the real-time natural gas demand in the ovens.

No works were found in the literature that employ Artificial Neural Networks (ANN) for temperature prediction and control of specific BIW parts. Although temperatures can be monitored using online measurement equipment, it is physically impossible and economically unfeasible to employ such equipment in all car bodies and all parts.

In this context, the objective of this study was to develop and implement a Neural Network Predictive Control (NNPC) system for the drying and curing process in automotive paint. The NNPC system was developed using information from an industrial electrodeposition oven

values of the car body positions in the preceding zone were incorporated as input variables for the model of the subsequent zone. Thus, beginning from the second zone onward, the ANN configuration encompasses 10 input variables and 8 output variables. Fig. 3 illustrates the architecture of the ANNs comprising the Elpo oven model, while Table 1 provides a summary of the neural network topologies.

The data set used for ANN training was obtained from the implemented and validated phenomenological model of the Elpo oven presented by Cavalcante et al. [12]. This article presents Eq. (1), which characterizes the contribution of heat transfer mechanisms based on the operational conditions of the oven zones.

$$\frac{dT(t)}{dt} = \begin{cases} \frac{\sigma \epsilon}{\rho_m C_{pm} Z_m} (T_w^4 - T(t)^4) + \frac{h_v}{\rho_m C_{pm} Z_m} (T_a - T(t)), & \text{radiation and convection zones;} \\ \frac{h_v}{\rho_m C_{pm} Z_m} (T_a - T(t)), & \text{convection zones;} \end{cases} \quad (1)$$

(Elpo oven - Fig. 1), which is one of the largest energy consumers in the plant mentioned above. As depicted in Fig. 1, the Elpo oven is partitioned into zones, and the heating of the car body follows a predefined temperature profile. The heat transfer mechanisms involve convection in the "Entrance" and "Entrance Curtain" zones, radiation and convection in zones 1 and 2, and convective heating in the remaining zones.

One of the main considerations in our methodology was the complexity of the problem we were addressing. We chose to use Artificial Neural Networks (ANN) instead of classical Machine Learning (ML) algorithms due to the ability of ANN to handle complex problem domains. This process exhibits complexities such as non-linearity, high-dimensional data, and intricate patterns, which required a robust and adaptable modeling technique. ANN has been proven to be highly effective in capturing and learning complex relationships and patterns, particularly in scenarios with non-linearities. By using ANN in our methodology, we aimed to showcase its capabilities and demonstrate its potential in addressing complex problems, thereby promoting its adoption in various domains.

All the modeling and simulations presented in this study were conducted on a notebook equipped with an Intel Core i7 7th generation processor, 8 GB of RAM, and a 1 TB hard drive.

2. Training and validation of the neural model

To develop and implement the NNPC, it is essential to acquire the ANN-based process model, which starts with the training phase of the ANN, also referred to as learning. ANN training involves establishing the correlation between input and output values by utilizing a historical dataset.

Initially, the process variables to be considered as manipulated variables (input variables) and controlled variables (output variables) were defined. By evaluating the available variables in each zone and considering the operational requirements for controlling the quality of paint drying and curing in the Elpo oven, the conveyor speed of the car body ($x_{1,j}$) and the ambient temperatures in the zones ($x_{2,j}$) were designated as manipulated variables. The temperatures of different car body positions in each zone ($y_{k,j}$) were defined as controlled variables, with j varying for each specific zone. Fig. 2 illustrates the locations of the car body parts (measurement positions) under investigation in the Elpo oven.

Due to the nature of the process and the presence of 13 zones with distinct operating conditions and dimensions in the Elpo oven, a zone-based control strategy was devised. For each zone, an ANN was employed as the control model. Starting from the second zone (entrance curtain), to enhance the robustness of the neural model, the temperature

where $T(t)$ is the car body temperature, T_w is the oven wall temperature, T_a is the temperature of the air circulating in the oven, ρ_m is the metallic substrate density, C_{pm} is the heat capacity of the metallic substrate, Z_m is the metallic substrate thickness, σ is the Stefan Boltzmann constant, ϵ is the emissivity and h_v is the heat transfer coefficient.

Once the input and output variables were determined, disturbances were introduced to each input variable in the phenomenological model to obtain the dynamic response of the process output variables. Random disturbances were applied to the conveyor speed and zone temperatures, utilizing the *rand* function in Matlab®, as illustrated in Eq. (2).

$$R = X \{1 + [a + (b - a)rand(1, 1)]\} \quad (2)$$

where R is the matrix with random values of input variables, X is the matrix with the nominal values of input variables, a is the negative variation, b is the positive variation. The *rand* function generates matrices of random numbers, whose elements are uniformly distributed over the interval (0,1). As shown in Eq. (2), to generate a uniform distribution of random numbers in a specified interval $[a,b]$, it is necessary to multiply the *rand* output (1,1) by $(b-a)$, and sum the result to the lower limit (a). For training, variations of $\pm 10\%$ were defined in input variables.

To assess the training performance of neural networks with an increasing amount of data, datasets consisting of 100, 200, 300, 400, 500, and 1000 simulated cases were generated. The process of generating datasets for ANN training is illustrated in Fig. 4.

After acquiring the training datasets, the subsequent step involves training the ANNs. In this study, the backpropagation algorithm was utilized for training. The training process was conducted individually for each available dataset using the Neural Network Training toolbox - *nnTool* in Matlab®.

The training of the ANNs was carried out using the *trainlm* function, which utilizes the Levenberg-Marquardt optimization algorithm to update the synaptic weights. The dataset was divided into three sets: training data (80%), validation data (10%), and test data (10%).

By comparing the training results with the available databases, it was observed that using the database with 500 simulated cases yielded satisfactory results in terms of predicting the temperatures of the 8 car body parts in the 13 oven zones. Increasing the database to 1000 simulated cases did not lead to significant improvements in prediction.

Table 2 displays the R^2 adjustment coefficients results for training, validation, testing, and global performance of the ANNs. It is evident that the ANNs developed for all zones achieved R^2 adjustment coefficient values above 0.99, indicating good model fit during the training, validation, and testing stages for predicting the temperatures of car body

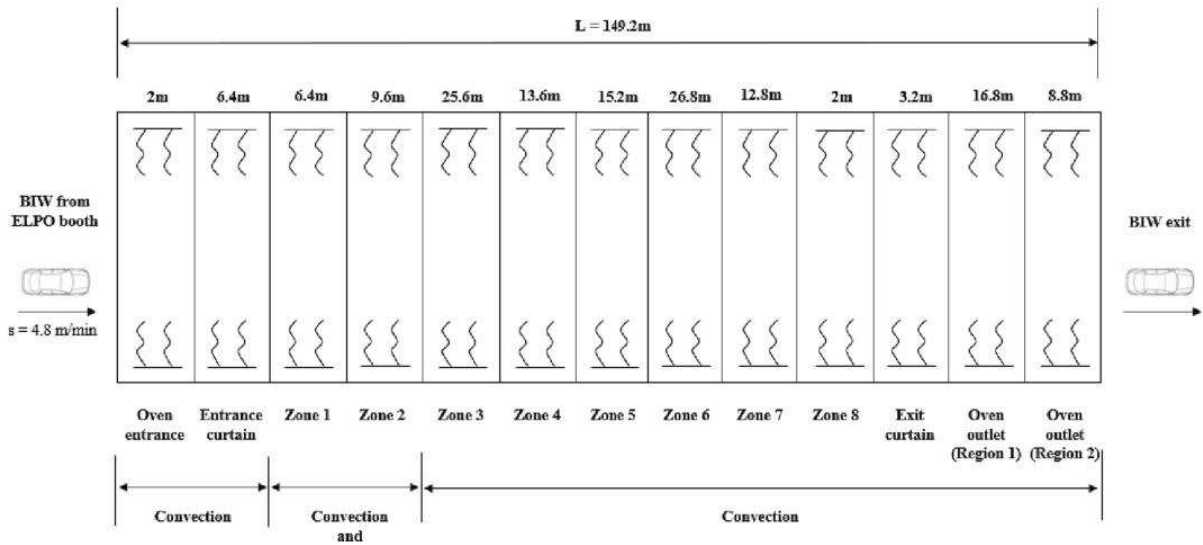



Fig. 1. Representation of the Elpo oven.



Legend:

1. Air temperature near the body
2. Left front roof
3. Right front roof
4. Left middle roof
5. Right middle roof
6. Left center pillar
7. Right center pillar
8. Left front door

Fig. 2. Monitored vehicle parts.

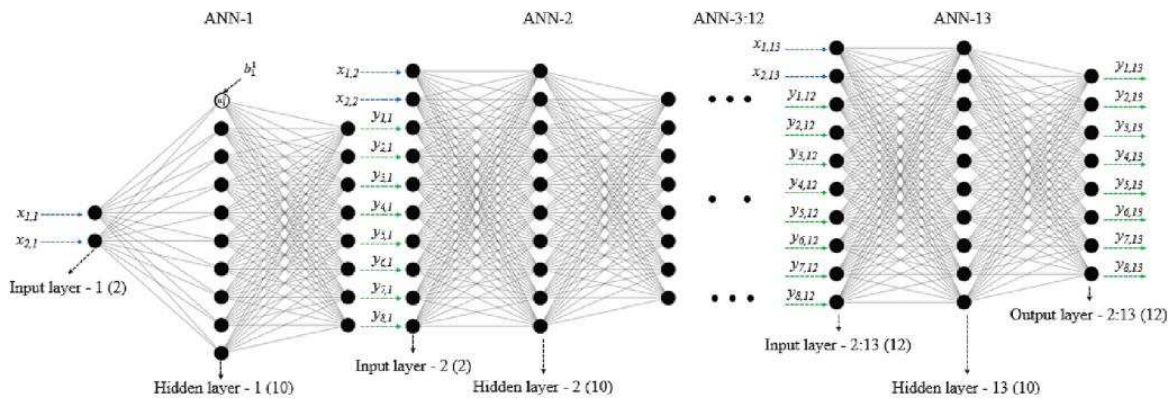


Fig. 3. Representation of the ANN configuration of the Elpo oven zones.

parts.

There are key justifications for the good fits observed in the model, which do not necessarily indicate overfitting. Firstly, extensive testing using a diverse range of simulated cases consistently yielded the best results with a dataset size of 500 cases, ensuring the model's reliability.

Secondly, meticulous experiments determined the optimal division of the dataset into training, validation, and test subsets, with carefully selected ratios that produced the most favorable overall performance. This approach enabled us to evaluate the model's generalization capabilities beyond the training set. Lastly, within the specific context of this

Table 1
Topology of ANNs of the Elpo oven zones.

Zones	Architecture	Neurons in the input layer	Neurons in the hidden layer	Neurons in the output layer	Activation Function
1	Multilayer	2	10	8	Hyperbolic tangent
2-13	feedforward	10	10	8	Hyperbolic tangent

model, the “cooling” zones in the oven (Oven outlet - Region 1 and Oven outlet - Region 2) exhibited limited temperature variations, allowing the neural network model to achieve highly accurate predictions. Even with changes to the training data or dataset division, the model is likely to continue producing favorable results in these zones due to the inherent limited temperature variations of the car parts.

The performance of the ANNs was further analyzed using Matlab®'s *nnTool* toolbox to evaluate different numbers of epochs, ranging from 0 to 1000 epochs, based on the calculation of the mean square error (MSE). Table 3 displays the number of epochs selected for each ANN, based on the best fits with the lowest MSE values.

3. Implementation of the neural network predictive control system

The goal of NNPC is to ensure process stability by predicting future values of process variables. Utilizing the global neural model composed of the validated ANNs from the 13 zones, the neural network predictive control strategy was implemented. This strategy is based on the generalized predictive control (GPC) model, where the objective function J is defined by Eq. (3):

Table 2
R² coefficients for training, validation, testing and global of ANNs.^a

Zone	Training	Validation	Test	Global
Oven entrance	0.9948	0.9949	0.9967	0.9949
Entrance curtain	0.9995	0.9962	0.9996	0.9996
Zone 1	0.9996	0.9996	0.9996	0.9996
Zone 2	0.9984	0.9985	0.9983	0.9984
Zone 3	0.9931	0.9907	0.9919	0.9927
Zone 4	0.9989	0.9985	0.9981	0.9988
Zone 5	0.9989	0.9986	0.9985	0.9988
Zone 6	0.9997	0.9995	0.9995	0.9996
Zone 7	0.9998	0.9998	0.9997	0.9998
Zone 8	0.9999	0.9999	0.9999	0.9999
Exit curtain	0.9999	0.9999	0.9999	0.9999
Oven outlet (Region 1)	0.9984	0.9986	0.9979	0.9984
Oven outlet (Region 2)	1.0000	1.0000	1.0000	1.0000

^a Database with 500 simulated cases, separated into training (80%), validation (10%) and test (10%) sets.

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_U} (\Delta u(t+j))^2 \quad (3)$$

where N_1 is the minimum prediction horizon; N_2 is the maximum prediction horizon; N_U is the control horizon; y_r is the output signal reference; y_m is the output signal predicted by the neural model; t is the current instant; Δu is the variation of the control action, defined by $u(t+j) - u(t+j-1)$; ρ is the control action weighting, used to determine the contribution of the sum of squares of control increments to the performance index.

Considering the requirements of the control problem, an additional term was introduced into the objective function to minimize the absolute value of the controlled variable, as described in Eq. (4):

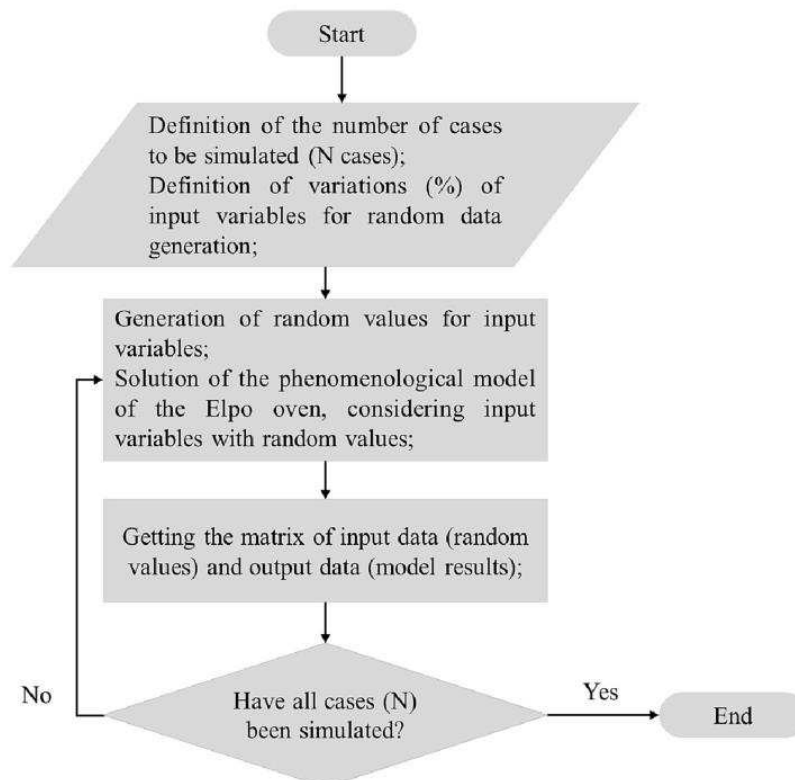


Fig. 4. Algorithm for the generation of the training database.

Table 3
Results for tests with different epochs for ANNs.

Zone	Number of epochs	Root mean squared error (MSE)
Oven entrance	1	0.165
Entrance curtain	4	0.775
Zone 1	7	0.702
Zone 2	8	2.425
Zone 3	14	4.478
Zone 4	20	0.385
Zone 5	38	0.249
Zone 6	37	0.137
Zone 7	29	0.107
Zone 8	10	0.008
Exit curtain	52	0.014
Oven exit (Region 1)	9	0.966
Oven exit (Region 2)	65	0.001

$$J = \sum_{j=1}^{N_T} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_T} (\Delta u(t+j))^2 + w y_m \quad (4)$$

where w is a weighting coefficient used to represent the contribution of the problem constraints to the general objective function; that is, the term $w y_m$ represents a penalty to distance the objective function from the global optimum. The w value was empirically determined to force the optimization method to always seek positive values (constraints) for decision variables (zone temperature or conveyor speed), based on the following strategy:

- ✓ For negative values of decision variables, the term $w y_m$ referring to the penalty is considered.
- ✓ For positive values of decision variables, the term $w y_m$ is discarded.

Therefore, the revised objective function consists of three components: the first component aims to minimize the error, the second component aims to minimize the variation of the manipulated variable (effort), and the third component represents a penalty to force the optimization method to always seek positive values (constraints) for decision variables (zone temperature or conveyor speed).

Fig. 5 illustrates the structure of the implemented NNPC, while Fig. 6 depicts the algorithm for resolving the control strategy. In general, as the car body progresses through the 13 oven zones, the ANN models predict the temperatures of car body parts (controlled variables $y_{k,j}$) in the

subsequent zones. These predictions are then utilized in the objective function J . By employing an optimization method, it becomes possible to determine the conveyor speed or zone temperature values (control signals, manipulated variables $x_{1,j}$ and $x_{2,j}$) that minimize the objective function. The optimization process is conducted zone by zone, resulting in the temperatures of car body parts reaching values equal to or close to their respective setpoints.

In order to address the multi-objective optimization problem within the control system, an examination of the most suitable optimization method was conducted. Simulations were carried out to assess the performance of three optimization methods: Simplex Nelder-Mead (SNM), Levenberg-Marquardt (LM), and Ant Colony Optimization (ACO).

Upon analyzing the results of the simulations using these optimization methods, it was observed that the employment of the SNM and LM methods led to abrupt behavior in the manipulated variables (zone temperature and conveyor speed), with the solutions converging towards values that were far from the operational ranges and training limits ($\pm 10\%$ of the base case values).

In contrast, the ACO method yielded satisfactory results, with the manipulated variables exhibiting consistent values within the training limits. This outcome can be attributed to the fact that the SNM and LM methods do not incorporate the search environment limits (bounds) in their algorithm formulations, whereas the ACO method allows for the inclusion of these limits, which correspond to the training limits of the manipulated variables. Consequently, the ACO method was employed to address the optimization problem implemented in the predictive neural controller.

4. Performance of the neural predictive controller

To assess the performance of the NNPC controller under disturbances in the manipulated variables, this section presents simulations of four distinct operational scenarios of the Elpo oven.

The first two scenarios, forming control configuration 1 (NNPC-1), involved the application of step-type disturbances to the conveyor speed of the oven. In this configuration, the optimizer of the NNPC controller adjusts the temperature values of the zones to keep the car body positions' temperatures close to their setpoints.

Control configuration 2 (NNPC-2) is tested in the last two scenarios by applying step-type disturbances to the temperatures of the oven zones. In NNPC-2 configuration, a single value for the conveyor speed is

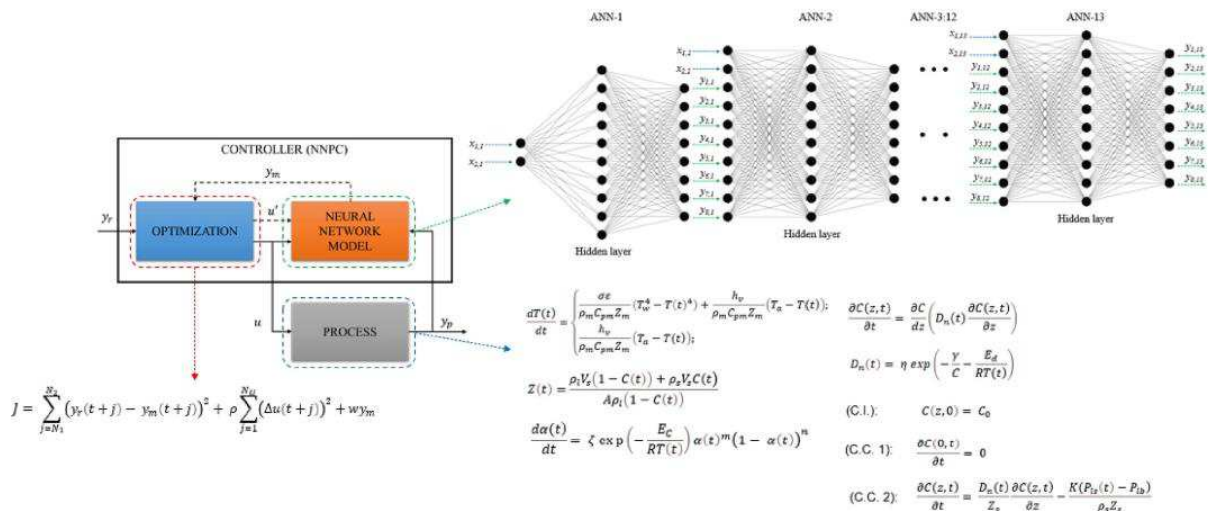


Fig. 5. Implemented NNPC structure.

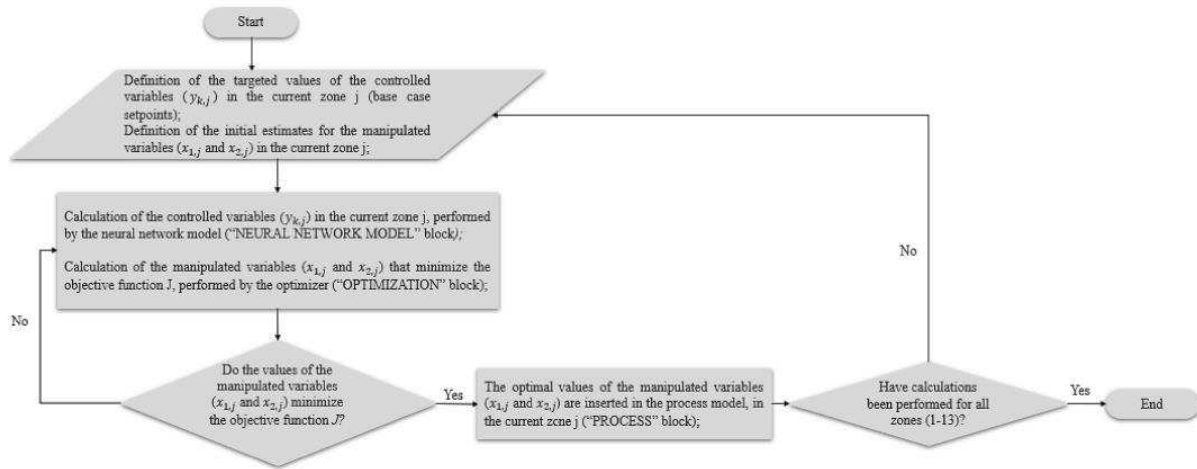


Fig. 6. Implemented NNPC resolution algorithm.

determined, as it is not advisable to make consecutive changes to the conveyor speed during the drying and curing process, as these changes can affect the temperature profile of subsequent car bodies.

In this context, to evaluate the performance of the two NNPC controller configurations, the following scenarios were simulated:

- ✓ NNPC-1 configuration (obtaining optimal zone temperatures):
 - Scenario 1 - Disturbance of +5 % in the conveyor speed.
 - Scenario 2 - Disturbance of -5 % in the conveyor speed.
- ✓ NNPC-2 configuration (obtaining optimum conveyor speed):
 - Scenario 3 - Disturbance of +5 % in zone air temperatures.
 - Scenario 4 - Disturbance of -5 % in zone air temperatures.

It is important to emphasize that in the actual process of the Elpo oven, in the NNPC-1 configuration, the effect will be on the airflows introduced into the oven zones (MV), which determine the air

temperatures in these zones. In the NNPC-2 configuration, disturbances in zone air temperatures are caused by manipulations of the airflows introduced into the zones; the action of NNPC-2 will be on the conveyor speed (MV).

4.1. Disturbance of +5 % in the conveyor speed

Fig. 7 shows the behavior of temperatures of car body positions (controlled variables) for disturbance of +5 % in the conveyor speed. The simulation results using the NNPC-1 controller show that, after defining the new zone temperature values, car body position temperatures are kept close to the desired values throughout the process, as shown by the blue dashed lines in Fig. 7.

Table 4 presents a comparison of the temperature operating conditions of the Elpo oven between the base case and scenario 1 with the NNPC-1 controller. It shows the new zone temperature values obtained

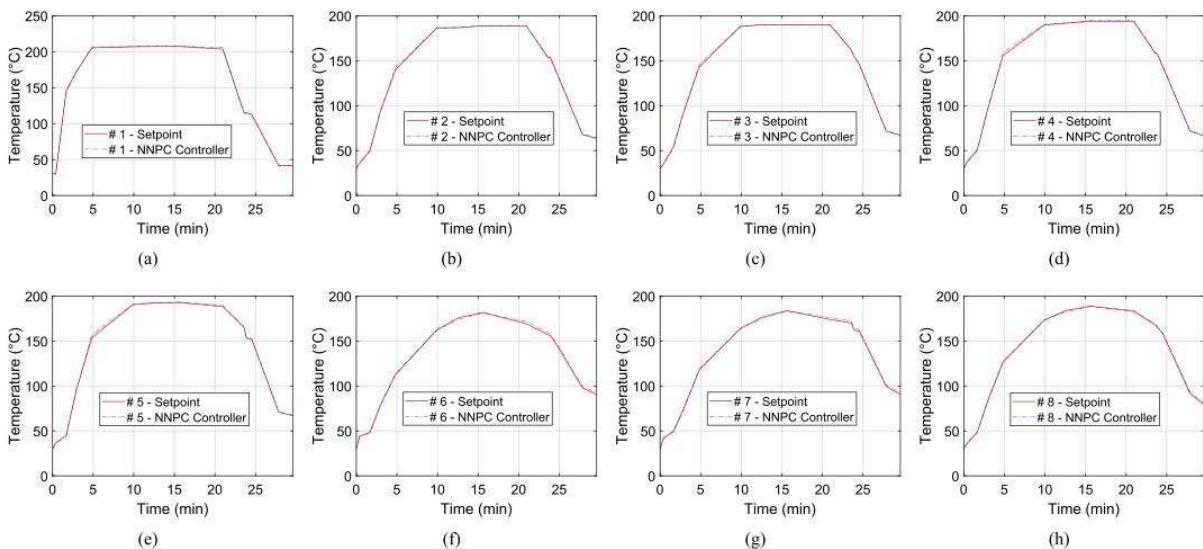


Fig. 7. NNPC-1 controller performance for disturbance of +5 % in the conveyor speed: (a) #1 Air temperature near the hood, (b) #2 Left front roof, (c) #3 Right front roof, (d) #4 Left Middle Roof. (e) #5 Right Middle Roof, (f) #6 Left Center Pillar, (g) #7 Right Center Pillar, and (h) #8 Left Front Door.

Table 4
Elpo oven operating conditions: Base case ($v = 4.8$ m/min) x scenario 1 with NNPC-1 controller for disturbance of +5 % in the conveyor speed ($v = 5.04$ m/min).

Zones	Zone temperatures Base case (°C)	Zone temperatures NNPC scenario 1 (°C)
Oven entrance	40	43.31
Entrance curtain	73	79.57
Zone 1	200	217.64
Zone 2	220	217.80
Zone 3	240	257.67
Zone 4	235	255.72
Zone 5	220	213.00
Zone 6	215	207.77
Zone 7	215	207.77
Zone 8	175	159.25
Exit curtain	72	65.65
Oven exit (Region 1)	40	36.40
Oven exit (Region 2)	40	36.55

Table 5
Mean Absolute Percentage Error (MAPE) and Mean Absolute Error (MAE) of scenario 1 with NNPC-1 controller for disturbance of +5 % in the conveyor speed.

Measurement position (Parts)	Mean Absolute Percentage Error (MAPE)	Mean Absolute Error (MAE)
#1 Air temperature near the hood	1.4439	2.4429
#2 Left front roof	0.6346	0.5757
#3 Right front roof	0.5903	0.5627
#4 Left middle roof	0.7477	0.8190
#5 Right middle roof	0.6317	0.6755
#6 Left center pillar	0.8091	0.7979
#7 Right center pillar	0.7143	0.6619
#8 Left front door	0.6099	0.5525

by the optimizer of the NNPC-1 controller.

Table 5 displays the mean absolute percentage error (MAPE) and mean absolute error (MAE) values for each measurement position. These values are computed by comparing the temperature setpoint values of the positions (target values) with the temperature values obtained using the NNPC-1 controller. The controller demonstrated satisfactory performance, as indicated by MAPE and MAE values below 1.44 % and 2.44 %, respectively. The equations for calculating MAPE and MAE are provided in Eqs. (5) and (6), respectively.

$$MAPE_k = \frac{\sum_{i=1}^m \left(\frac{|y_{k,i} - \hat{y}_{k,i}|}{y_{k,i}} \right)}{m} \cdot 100 \tag{5}$$

$$MAE_k = \frac{\sum_{i=1}^m |y_{k,i} - \hat{y}_{k,i}|}{m} \tag{6}$$

Table 6
Elpo oven operating conditions: base case ($v = 4.8$ m/min) x scenario 2 with NNPC-1 controller for disturbance of -5 % in the conveyor speed ($v = 4.56$ m/min).

Zones	Base case zone temperatures (°C)	Zone temperatures NNPC controller scenario 2 (°C)
Oven entrance	40	38.58
Entrance curtain	73	67.23
Zone 1	200	198.00
Zone 2	220	211.40
Zone 3	240	218.40
Zone 4	235	221.97
Zone 5	220	221.40
Zone 6	215	221.06
Zone 7	215	197.60
Zone 8	175	190.43
Exit curtain	72	65.52
Oven exit (Region 1)	40	43.60
Oven exit (Region 2)	40	43.60

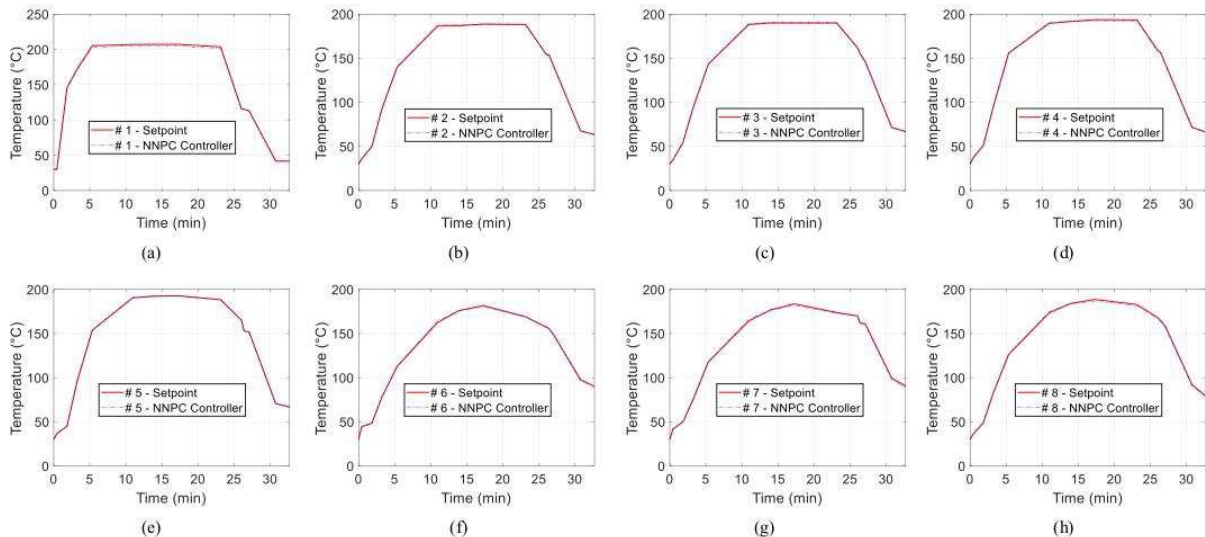


Fig. 8. Performance of the NNPC-1 controller for disturbance of -5 % in the conveyor speed: (a) #1 Air temperature near the hood, (b) #2 Left front roof, (c) #3 Right front roof, (d) #4 Left Middle Roof, (e) #5 Right Middle Roof, (f) #6 Left Center Pillar, (g) #7 Right Center Pillar, and (h) #8 Left Front Door.

Table 7
MAPE and MAE of scenario 2 with NNPC-1 controller for disturbance of -5% in the conveyor speed.

Measurement position (Parts)	Mean Absolute Percentage Error (MAPE)	Mean Absolute Error (MAE)
#1 Air temperature near the hood	1.0008	1.2050
#2 Left front roof	0.2982	0.3357
#3 Right front roof	0.3706	0.4092
#4 Left middle roof	0.4717	0.5978
#5 Right middle roof	0.3922	0.3622
#6 Left center pillar	0.5715	0.6297
#7 Right center pillar	0.8176	0.9835
#8 Left front door	0.8087	1.0403

where m is the number of zones (13 zones), $y_{k,i}$ are the objectified temperature values of car body parts (setpoints) and $\widehat{y}_{k,i}$ is the temperature values obtained through the use of the NNPC-1 controller, both for each k measurement position (8 measurement parts), and for each m zone.

In the second scenario, Fig. 8 illustrates the temperature behavior of car body positions across the zones (controlled variables). Similar to the previous scenario, the implementation of NNPC-1 successfully controlled the temperatures of car body positions, ensuring they remained close to their respective setpoint values. This control was achieved by determining optimal zone temperatures (manipulated variables $x_{2,j}$), as depicted by the blue dashed lines.

Table 6 compares the operating conditions of the base case with those of scenario 2, using the NNPC-1 controller with a conveyor speed of 4.56 m/min. The table shows the optimal zone temperature values determined by the predictive neural controller NNPC-1. Additionally, Table 7 presents the mean absolute percentage error (MAPE) and mean absolute error (MAE) values for each controlled variable when using the NNPC controller. Once again, the predictive neural controller demonstrated satisfactory performance, with MAPE and MAE values below 1.0008 % and 1.2050, respectively (#1 Air temperature near the hood).

It is important to note that since the operational setpoints for the temperatures of the BIW parts remain fixed, and the NNPC-1 controller demonstrates excellent performance in scenarios 1 and 2, the distributions of the two graphs shown in Figs. 7 and 8 are similar, with only a change in the x-axis (time) due to the application of step disturbances in the conveyor speeds.

4.2. Disturbance of $\pm 5\%$ in zone temperatures

The results of the third scenario, in which a disturbance with a positive amplitude of 5 % was applied to the zone temperatures (manipulated variables $x_{2,j}$), are depicted in Fig. 9.

It was observed that deviations in the controlled variable temperatures were more pronounced compared to those observed in scenario 2 (Fig. 8). This indicates that disturbances of $+5\%$ in zone temperatures (manipulated variables $x_{2,j}$) had a greater impact on the car body position temperatures compared to disturbances of -5% in the conveyor speed.

However, when using NNPC-2 (represented by the blue dashed lines), it can be observed that the car body position temperatures are maintained close to the setpoint values for the majority of the simulation duration. However, deviations in car body position temperature values become more pronounced after 23 min (when the car body enters oven zone 11).

These deviations occur because the optimizer of the NNPC-2 controller, which searches for a global optimum with a single conveyor speed, tends to penalize the dynamics of specific zones, particularly zones 11, 12, and 13. Therefore, the poorer results observed

for car body position temperature values in these last three zones do not indicate inefficiency of the NNPC-2 controller. Rather, these deviations are attributed to the complexity of the operational optimization problem, where the controller needs to find a single conveyor speed that adjusts the temperatures of all eight parts across all 13 zones.

Table 8 compares the operational conditions of the Elpo oven for the base case and the third scenario with the NNPC-2 controller. In the third scenario, the optimizer of the NNPC-2 controller determined a conveyor speed of 5.23 m/min for the zones.

Table 9 displays the mean absolute percentage error (MAPE) and mean absolute error (MAE) values calculated for each measurement part in Scenario 3. The NNPC-2 controller achieved MAPE values below 4.04 % and MAE values below 4.82, indicating satisfactory performance. Specifically, for #1 Air temperature near the hood, the controller produced accurate results.

Fig. 10 displays the results of scenario 4, while Table 10 compares the operational conditions of the Elpo oven. It is evident that a 5 % decrease in zone temperatures led to corresponding decreases in car body position temperatures (controlled variables). Furthermore, it is observed that the optimized conveyor speed value (4.35 m/min) effectively controls the car body position temperatures throughout most of the simulation, except for times beyond 27 min (at the entrance of zone 11).

Nevertheless, the performance of the NNPC-2 controller in zones 11, 12, and 13 does not show a significant decrease. This is evident from the MAPE and MAE values, which remained below 4.0278 % and 5.0094, respectively, as indicated in Table 11.

Table 12 compares the performance of the two control strategies by calculating the Integral Absolute Error (IAE) for the four evaluated scenarios. It was observed that the NNPC-1 control configuration scenarios exhibited better results compared to the NNPC-2 control configuration. Therefore, the configuration that involves defining new setpoint temperatures for all zones (NNPC-1) appears to be more effective. IAE is calculated using Eqs. (7) and (8).

$$IAE_k = \int_{t=1}^m y_{k,i} - \widehat{y}_{k,i} \quad (7)$$

$$IAE_T = \sum IAE_k \quad (8)$$

where m is the number of zones (13 zones), $y_{k,i}$ are the objectified temperature values of car body parts (setpoints) and $\widehat{y}_{k,i}$ is the temperature values obtained through the use of the NNPC controller, for each k measurement position (8 measurement parts), and for each m zone (13 zones).

The superior performance of the NNPC-1 configuration can be attributed primarily to the complexity of the optimization problem in the NNPC-2 configuration. In NNPC-2, the controller needs to find a single conveyor speed that adjusts the temperatures of all parts (8 parts) across all zones (13 zones), resulting in 104 variables to be adjusted by a single decision variable. However, in both evaluated scenarios, the NNPC-2 controller successfully determined the optimal speeds to maintain the process within the desired temperature specifications for the parts.

5. Conclusions

This study introduced a methodology for developing and implementing a Neural Network Predictive Controller (NNPC) for an automotive paint drying and curing oven. The methodology was applied to the electrodeposition painting stage oven (Elpo oven) with the aim of enhancing temperature control for car body parts throughout the oven. The implementation of the NNPC resulted in mitigating painting issues and improving overall performance.

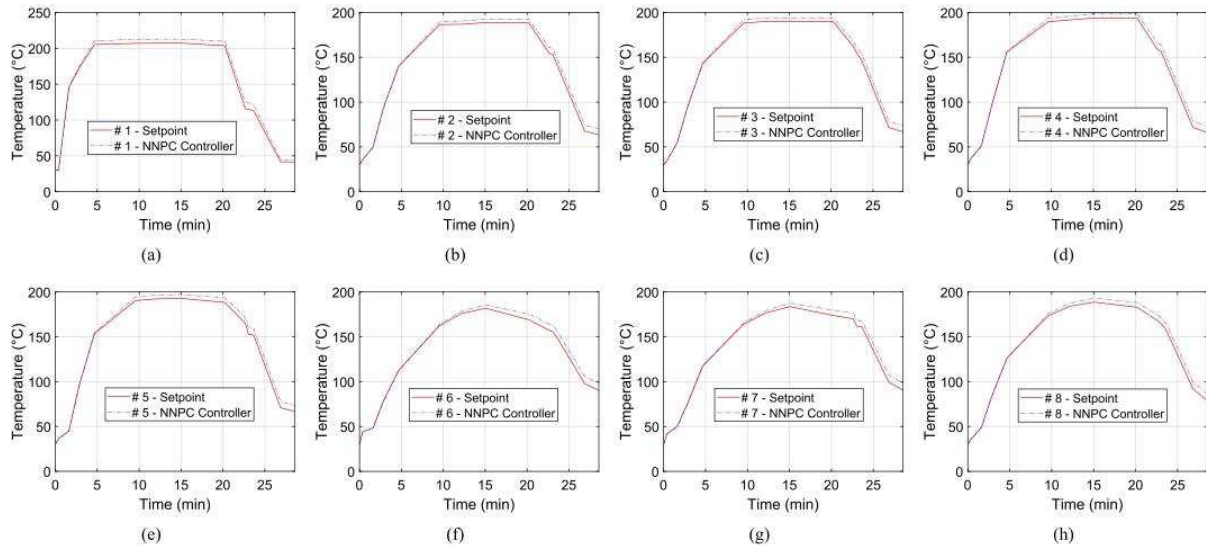


Fig. 9. Performance of the NNPC-2 controller in scenario 3 for disturbance of +5 % in zone temperatures: (a) #1 Air temperature near the hood, (b) #2 Left front roof, (c) #3 Right front roof, (d) #4 Left Middle Roof, (e) #5 Right Middle Roof, (f) #6 Left Center Pillar, (g) #7 Right Center Pillar, and (h) #8 Left Front Door.

Table 8

Elpo oven operating conditions: base case ($v = 4.8$ m/min) x scenario 3 with NNPC-2 controller for disturbance of +5 % in zone temperatures ($v = 5.23$ m/min).

Zones	Base case zone temperatures (°C)	Zone temperatures NNPC controller scenario 2 (°C)
Oven entrance	40	42.00
Entrance curtain	73	76.65
Zone 1	200	210.00
Zone 2	220	231.00
Zone 3	240	252.00
Zone 4	235	246.75
Zone 5	220	231.00
Zone 6	215	225.75
Zone 7	215	225.75
Zone 8	175	183.75
Exit curtain	72	75.60
Oven exit (Region 1)	40	42.00
Oven exit (Region 2)	40	42.00

Table 9

MAPE and MAE of scenario 3 with NNPC-2 controller for disturbance of +5 % in zone temperatures.

Measurement position (Parts)	Mean Absolute Percentage Error (MAPE)	Mean Absolute Error (MAE)
#1 Air temperature near the hood	4.0428	4.8220
#2 Left front roof	3.3411	3.8089
#3 Right front roof	3.2369	3.8049
#4 Left middle roof	3.5626	4.2688
#5 Right middle roof	3.4515	4.1546
#6 Left center pillar	3.2753	4.1191
#7 Right center pillar	3.0543	3.9402
#8 Left front door	3.1792	4.0563

After training, validating, and testing the ANNs, it was observed that the obtained neural models exhibited strong performance in predicting temperatures of car body parts across the oven. The R^2 adjustment coefficient values exceeded 0.99, indicating good accuracy and predictive

capability.

The performance of the NNPC control system, based on the GPC model, was evaluated by simulating four operational scenarios of the Elpo oven. These simulations involved the application of disturbances in the manipulated variables, specifically the conveyor speed ($x_{1,j}$) and zone air temperatures ($x_{2,j}$).

For disturbances of $\pm 5\%$ in the conveyor speed (scenarios 1 and 2), the NNPC-1 controller successfully maintained the car body position temperatures close to their setpoint values throughout the entire process. The Mean Absolute Percentage Error (MAPE) and Mean Absolute Error (MAE) values calculated for each car body part were as follows: in scenario 1, values below 1.44 % and 2.44, respectively; and in scenario 2, values below 1.00 % and 1.21, respectively.

On the other hand, when considering disturbances of $\pm 5\%$ in the zone air temperatures (scenarios 3 and 4), it was also observed that the car body position temperatures were well controlled and remained close to their setpoint values throughout the simulation time. This indicates the effectiveness of the NNPC-2 controller in determining the optimal conveyor speed values for the zones. The Mean Absolute Percentage Error (MAPE) and Mean Absolute Error (MAE) values calculated for each car body part were as follows: in scenario 3, values below 4.04 % and 4.82, respectively; and in scenario 4, values below 4.03 % and 5.01, respectively.

The superior performance of the NNPC-1 configuration can be attributed to the complexity of the optimization problem in the NNPC-2 configuration. In the NNPC-2 configuration, the controller has the task of finding a single conveyor speed that can effectively regulate the temperatures of all parts across all oven zones.

The methodology proposed in this study for the Elpo oven can be extended to develop control strategies for other ovens in the automotive industry, including Sealing, Primer, and Base/Varnish ovens.

Regarding computational requirements, the training of the Artificial Neural Network (ANN) model demanded some computational effort, but the training time was acceptable given the complexity of the task. Once trained, the ANN model ran efficiently and had faster execution times compared to other models. The Neural Network Predictive Control (NNPC) optimization routine also performed within the expected time frame. Although there is room for further optimization, such as fine-tuning the parameters of the Ant Colony Optimization (ACO) method, this falls within the scope of future work and would require dedicated

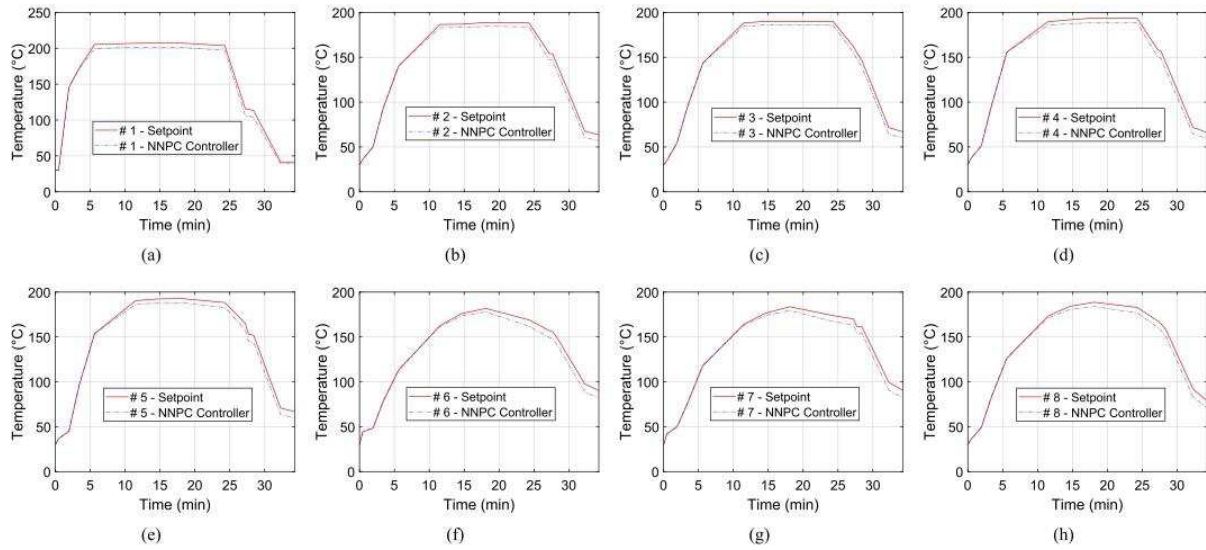


Fig. 10. Performance of the NNPC-2 controller in scenario 4 for disturbance of -5% in zone temperatures: (a) #1 Air temperature near the hood, (b) #2 Left front roof, (c) #3 Right front roof, (d) #4 Left Middle Roof, (e) #5 Right Middle Roof, (f) #6 Left Center Pillar, (g) #7 Right Center Pillar, and (h) #8 Left Front Door.

Table 10

Elpo oven operating conditions: base case ($v = 4.8$ m/min) x scenario 4 with NNPC-2 controller for disturbance of -5% in zone temperatures ($v = 4.35$ m/min).

Zones	Base case zone temperatures (°C)	Zone temperatures NNPC controller scenario 2 (°C)
Oven entrance	40	38.00
Entrance curtain	73	69.35
Zone 1	200	190.00
Zone 2	220	209.00
Zone 3	240	228.00
Zone 4	235	223.25
Zone 5	220	209.00
Zone 6	215	204.25
Zone 7	215	204.25
Zone 8	175	166.25
Exit curtain	72	68.40
Oven exit (Region 1)	40	38.00
Oven exit (Region 2)	40	38.00

Table 11

MAPE and MAE of scenario 4 with NNPC-2 controller for disturbance of -5% in zone temperatures.

Measurement position (Parts)	Mean Absolute Percentage Error (MAPE)	Mean Absolute Error (MAE)
#1 Air temperature near the hood	4.0278	5.0094
#2 Left front roof	3.6508	4.1938
#3 Right front roof	3.5570	4.1916
#4 Left middle roof	3.8602	4.6421
#5 Right middle roof	3.7520	4.5313
#6 Left center pillar	3.5656	4.4965
#7 Right center pillar	3.3754	4.3444
#8 Left front door	3.5401	4.4916

Table 12

IAE for scenarios evaluated with NNPC control configurations.

Measurement position	Integral Absolute Error (IAE)			
	NNPC-1 Configuration		NNPC-2 Configuration	
	+5 % on conveyor speed	-5 % on conveyor speed	5 % in zone air temperatures	-5 % in zone air temperatures
#1 Air temperature near the hood	31.7583	15.6654	62.6859	65.1223
#2 Left front roof	7.4845	4.3637	49.5152	54.5195
#3 Right front roof	7.3155	5.3191	49.4638	54.4904
#4 Left middle roof	10.6475	7.7711	55.4946	60.3477
#5 Right middle roof	8.7811	4.7088	54.0103	58.9073
#6 Left center pillar	10.3721	8.1867	53.5486	58.4548
#7 Right center pillar	8.6046	12.7849	51.2225	56.4776
#8 Left front door	7.1819	13.5238	52.7323	58.3913
TOTAL	92.1454	72.3236	428.6732	466.7109

research and experimentation to enhance the resolution time of the model.

CRedit authorship contribution statement

Esley Silva Cavalcante: Conceptualization, Methodology, Software, Validation, Formal analysis, Investigation, Data curation, Writing – original draft, Visualization. **Luís Gonzaga Sales Vasconcelos:** Conceptualization, Methodology, Validation, Formal analysis, Resources, Writing – original draft, Supervision, Project administration, Funding acquisition. **Karoline Dantas Brito:** Writing – review & editing. **Romildo Pereira Brito:** Writing – review & editing.

Declaration of competing interest

The authors of this publication agree with:

1. All authors have participated in (a) conception and design, or analysis and interpretation of the data; (b) drafting the article or revising it critically for important intellectual content; and (c) approval of the final version.
2. This manuscript has not been submitted to, nor is under review at, another journal or other publishing venue.
3. The authors have no affiliation with any organization with a direct or indirect financial interest in the subject matter discussed in the manuscript.

Data availability

Data will be made available on request.

Acknowledgments

The authors would like to thank the Coordination for the Improvement of Higher Education Personnel (CAPES) for financial support for this study.

References

- [1] R.A. Dickie, D.R. Bauer, S.M. Ward, D.A. Wagner, Modeling paint and adhesive cure in automotive applications, *Prog. Org. Coat.* 31 (1997) 209–216, [https://doi.org/10.1016/S0300-9440\(97\)00039-8](https://doi.org/10.1016/S0300-9440(97)00039-8).
- [2] M.M.L. Elahi, G.V. Záruba, J. Rosenberg, K. Rajpurohit, Modeling and Simulation of a General Motors Conveyor System Using a Custom Decision Optimizer, Master's Thesis, Department of Computer Science and Engineering, University of Texas at Arlington, Arlington, Texas, 2009.
- [3] S. Poozesh, N. Akafuah, K. Saito, Effects of automotive paint spray technology on the paint transfer efficiency – a review, *Proc. Inst. Mech. Eng. D J. Automob. Eng.* 232 (2017), <https://doi.org/10.1177/0954407017695159>.
- [4] M.R. Pendar, F. Rodrigues, J.C. Pascoa, L. Rui, Review of coating and curing processes: evaluation in automotive industry, *Phys. Fluids* (2022) Vol–34, <https://doi.org/10.1063/5.0109376>.
- [5] M.R. Pendar, J.C. Pascoa, Lima, Numerical investigation of automotive paint oven for improving the thermal efficiency, in: *Fluids Engineering Division Summer Meeting*, Toronto, Canada, August 3–5, 2022, <https://doi.org/10.1115/FEDSM2022-88044>.
- [6] H.H. Lou, Y.L. Huang, Integrated modeling and simulation for improved reactive drying of clearcoat, *Ind. Eng. Chem. Res.* 39 (2000) 500–507, <https://doi.org/10.1021/ie990171g>.
- [7] G. Zelder, C. Steinbeck-Behrens, Simulation on Car Body Painting Processes. 4th European Automotive Simulation Conference, July 2009.
- [8] P.P. Rao, A. Gopinath, Energy savings in automotive paint ovens: a new concept of shroud on the carriers, *J. Manuf. Sci. Eng.* 135 (2013) 1–9, <https://doi.org/10.1115/1.4024537>.
- [9] R. Mehdipour, Z. Baniamerian, S. Sattar, Evaluation of continuous convection and radiation ovens in automobile cure industry, *Int. J. Automot. Eng.* 5 (2015) 1054–1066.
- [10] M. Vasudevan, Numerical modelling of paint curing in convective ovens, in: *Master's Thesis, Mechanics and Maritime Sciences, Chalmers University of Technology, Goteborg, Sweden, 2018*.
- [11] M. Despotovic, M. Babić, Analysis of different scenarios of car paint oven redesign to achieve desired indoor air temperature, *Energy Efficiency* 11 (2018), <https://doi.org/10.1007/s12053-018-9612-1>.
- [12] E.S. Cavalcante, L.G.S. Vasconcelos, G.W. de F. Neto, W.B. Ramos, R.P. Brito, Automotive painting process: minimizing energy consumption by using adjusted convective heat transfer coefficients, *Prog. Org. Coat.* 140 (2020), <https://doi.org/10.1016/j.porgcoat.2019.105479>.
- [13] R. Radfar, J. Jassbi, F. Ghoreishi, S. Khanmohammadi, M. Alborzi, Proactive quality paint thickness control using ANFIS, in: *IEEE - International Conference on Systems, Man and Cybernetics, 2010*, <https://doi.org/10.1109/ICSMC.2010.5642189>.
- [14] J. Jassbi, M. Alborzi, F. Ghoreishi, Car paint thickness control using artificial neural network and regression method, *J. Ind. Eng. Int.* 7 (14) (2011) 1–6.
- [15] S. Ma, Z. Jiang, W. Liu, Modeling drying-energy consumption in automotive painting line based on ANN and MLR for real-time prediction, *Int. J. Precis. Eng. Manuf. Green Tech.* 6 (2019) 241–254, <https://doi.org/10.1007/s40684-019-00064-x>.