

UNIVERSIDADE TIRADENTES – UNIT
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PROCESSOS - PEP

**MODELAGEM HÍBRIDA NEURAL EM SISTEMA DE SECAGEM POR LEITO DE
JORRO**

Autor: Yago Matheus da Silva Veloso

Orientadoras: Prof^a. Manuela Sousa Leite, Dr^a.

Prof^a. Odelsia Leonor Sanchez de Alsina, Dr^a.

ARACAJU, SE - BRASIL

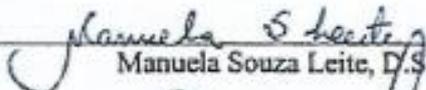
FEVEREIRO DE 2018

MODELAGEM HÍBRIDA NEURAL EM SISTEMA DE SECAGEM POR LEITO DE
JORRO

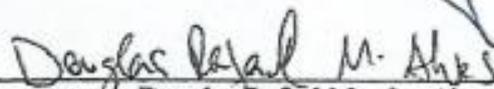
Yago Matheus da Silva Veloso

DISSERTAÇÃO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PROCESSOS DA UNIVERSIDADE TIRADENTES COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM
ENGENHARIA DE PROCESSOS

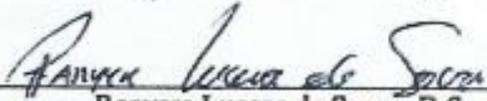
Aprovada por:


Manuela Souza Leite, D.Sc.


Odelsia Leonor Sanchez de Aisina, D.Sc.


Douglas Rafael Mendes Alves, D.Sc.


Gabriel Francisco da Silva, D.Sc.


Ranyere Lucena de Souza, D.Sc.


Maria de Fátima Dantas de Medeiros, D.Sc.

ARACAJU, SE - BRASIL

FEVEREIRO DE 2018

FICHA CATALOGRÁFICA

V432m Veloso, Yago Matheus da Silva
Modelagem híbrida neural em sistema de secagem por leite de jorro /
Yago Matheus da Silva Veloso; orientação [de] Prof^a. Dr^a. Manuela Sousa
Leite, Prof^a. Dr^a. Odelsia Leonor Sanchez de Alsina – Aracaju: UNIT, 2018.

106 f. : il.; 30cm

Dissertação (Mestrado em Engenharia de Processos) - Universidade
Tiradentes, 2018
Inclui bibliografia.

1. Goiaba. 2. Propriedades físicas. 3. Leite de jorro. 4. Regime de fluxo. 5.
Modelagem. 6. Redes neurais artificiais. I. Veloso, Yago Matheus da Silva. II.
Leite, Manuela Sousa. (orient.) III. Alsina, Odelsia Leonor Sanchez de. (co-
orient.). III. Universidade Tiradentes. V. Título.

CDU: 66. 047:634.42

“O início da sabedoria é a admissão da própria ignorância.

Todo o meu saber consiste em saber que nada sei.”

Sócrates

Agradecimentos

Quero agradecer a essa energia maravilhosa que é Deus, O Criador, O Pai, pelos caminhos que caminhei até esse momento. Obrigado pelos ensinamentos de cada dia e por ter me dado a oportunidade de subir mais esse degrau em minha vida.

A minha família, em especial a minha vó, meus pais e meu tio Lauro que sempre me apoiaram e me incentivaram.

A minha namorada Endira pelo apoio, carinho e compreensão em todos os momentos dessa jornada.

Aos meus colegas de curso, pelas horas de estudos, risadas e conversas que fizeram esses anos mais agradáveis.

Ao Professor Marcello Maia de Almeida, pelo fornecimento dos dados experimentais necessários para o desenvolvimento desse trabalho.

As minhas orientadoras Manuela e Odelsia pela dedicação, apoio e orientação compartilhando o conhecimento.

À Universidade Tiradentes (UNIT) pelo apoio financeiro e ao ITP pela infraestrutura concedida.

Resumo da Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Processos da Universidade Tiradentes como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Processos.

MODELAGEM HÍBRIDA NEURAL EM SISTEMA DE SECAGEM POR LEITO DE JORRO

Yago Matheus da Silva Veloso

O objetivo desse trabalho foi aplicar técnicas de modelagem ao processo de secagem de pedaços cúbicos de goiaba em leito de jorro. Utilizando-se da técnica de modelagem de Redes Neurais Artificiais (RNA) foram desenvolvidos dois modelos: um para a predição das propriedades físicas (densidade, diâmetro da partícula e a umidade) da goiaba (*Psidium Guajava L.*) durante a secagem em leito de jorro (modelo MN-1), e um segundo modelo neural, desenvolvido com o intuito de classificar os regimes de fluxo durante a secagem (modelo MN-2). O tipo de modelo neural utilizado foi o *feedforward Backpropagation*, que foi otimizado através do algoritmo de PSO (*Particle Swarm Optimization*). Para descrever o comportamento da transferência de calor e massa entre os pedaços de goiaba e o ar de secagem no leito de jorro foi desenvolvido um modelo híbrido (fenomenológico/Rede Neural), levando em consideração a variação das propriedades físicas e do encolhimento das partículas durante a secagem. Tal modelo híbrido foi obtido através do acoplamento do modelo MN-1 a um modelo fenomenológico, obtido através do balanço de massa e energia entre a fase sólida (pedaços de goiaba) e a fase gasosa (ar de secagem), o modelo neural nessa estratégia de modelagem, forneceu os efeitos da variação das propriedades físicas dos pedaços de goiaba durante a secagem. Os resultados obtidos pelas RNA's mostraram boa concordância com os dados experimentais, apresentando o modelo MN-1, RMSE igual a 0,066 e R^2 0,99, o modelo MN-2 obteve uma precisão de reconhecimento dos regimes de leito fixo, fluidização, leito de jorro e *slugging* iguais a 86,3%, 85,7%, 99% e 100% respectivamente. A partir da simulação do modelo híbrido, pode-se constatar que este pode ser aplicado para descrever as variações da temperatura do ar e do leito de partículas, bem como da umidade na secagem de partículas deformáveis, tais como a goiaba.

Palavras-chave: Goiaba; propriedades físicas; leito de jorro; regimes de fluxo; modelagem; redes neurais artificiais.

Abstract of the Dissertation presented to the Process Engineering Post-graduate program of the Universidade Tiradentes as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc).

NEURAL HYBRID MODELING IN A DRYING SYSTEM FOR SPOUTED BED

Yago Matheus da Silva Veloso

The objective of this study was to apply different types of modelling techniques for the drying process of cubic pieces of guava in spouted bed dryer. Using the ANN modelling technique were developed 2 models: to predict the physical properties (density, particle diameter and the moisture content) of the guava (*Psidium Guajava L.*) during the drying in the spouted bed dryer (MN-1 model), and a second neural model was developed in order to classify the flow regimes during the drying (MN-2 model). The feedforward Backpropagation model was used as a neural model and was optimized by the Particle Swarm Optimization algorithm. To describe the behavior of the heat and mass transfer between the pieces of guava and the drying air presented in the spouted bed was developed a hybrid model (phenomenological/ Neural Network), taking into account the variation of the physical properties and shrinkage of the particles during the drying. The hybrid model was obtained by the coupling of the MN-1 model and the phenomenological model, obtained through the global balance of the heat and mass between the solid phase (pieces of guava) and the gas phase (drying air). In this strategy of modeling, the neural model provided physical properties variation of the guava pieces during the drying to the phenomenological model. The results obtained by the ANN's model showed good agreement with the experimental data. The MN-1 model present RMSE equal to 0,066 and R^2 equal to 0,99, The MN-2 model obtained recognition accuracies equal to 86,3%, 85,7%, 99% and 100% to the fixed bed, fluidization, spouted bed and slugging regime respectively. Throughout the simulations of the hybrid model, it can be concluded that this model can be applied to describe the temperature variations in the air drying and the particle bed as well as the moisture in the deformable particles such as the guava pieces.

Keywords: Guava; physical properties; spouted bed; flow regimes; modeling; artificial neural network.

SUMÁRIO

1. INTRODUÇÃO	16
1.1. Objetivo geral	18
1.2. Objetivos específicos	18
2. REVISÃO BIBLIOGRÁFICA	19
2.1. A Goiaba e sua produção no Brasil	19
2.2. Secagem	20
2.3. Leito de Jorro	22
2.3.1. <i>Fluidodinâmica do leito (Curvas características)</i>	23
2.3.2. <i>Regimes fluidodinâmicos no leito de jorro</i>	25
2.3.3. <i>Evolução das propriedades físicas dos materiais durante a secagem e sua influência na fluidodinâmica do leito</i>	28
2.4. Redes Neurais Artificiais	31
2.4.1. <i>Modelos híbridos</i>	37
2.5. Otimização por enxame de partículas	39
3. MATERIAIS E MÉTODOS	43
3.1. Matéria prima utilizada	43
3.2. Preparo das amostras e pré-secagem em leito fixo	43
3.3. Ensaio de secagem no leito de jorro	44
3.4. Caracterização física das partículas	46
3.4.1. <i>Umidade em base seca</i>	46
3.4.2. <i>Densidade aparente</i>	47
3.4.3. <i>Diâmetro dos pedaços de goiaba</i>	47
3.4.4. <i>Classificação dos regimes fluidodinâmicos</i>	48
3.5. Construção dos modelos baseados em Redes Neurais	48
3.5.1. <i>Processamento e separação dos bancos de dados</i>	49
3.5.2. <i>Definição da arquitetura da RNA</i>	51
3.5.3. <i>Treinamento e análise de desempenho da RNA</i>	53
3.6. Desenvolvimento do modelo híbrido	54
3.6.1. <i>Proposta de resolução do modelo híbrido</i>	61
4. RESULTADOS E DISCUSSÕES	62

4.1. Resultados experimentais da secagem dos pedaços de goiaba no secador leito de jorro	62
4.2. Construção dos modelos neurais	65
4.2.1. <i>Divisão do banco de dados</i>	65
4.2.2. <i>Definição dos parâmetros do PSO</i>	67
4.2.3. <i>Desenvolvimento do modelo para predição da evolução das propriedades físicas (MN-1)</i>	68
4.2.3.1. <i>Definição da arquitetura da rede MN-1</i>	69
4.2.3.2. <i>Desempenho de treinamento do modelo MN-1</i>	71
4.2.3.3. <i>Equações do modelo MN-1 e análise da importância relativa das variáveis pela RNA</i>	73
4.2.3.4. <i>Aplicação do modelo MN-1 para a predição da cinética das propriedades físicas</i>	76
4.2.4. <i>Desenvolvimento do modelo para predição dos regimes de fluxo (MN-2)</i>	81
4.2.4.1. <i>Definição da arquitetura da rede MN-2</i>	81
4.2.4.2. <i>Desempenho de treinamento do modelo MN-2</i>	82
4.2.4.3. <i>Equações do modelo MN-2 e análise da importância relativa das variáveis pela RNA</i>	85
4.2.4.4. <i>Aplicação do modelo MN-2 para predição dos regimes de fluxo durante a secagem</i>	87
4.2.5. <i>Teste estatístico dos modelos desenvolvidos (MN-1 e MN-2)</i>	90
4.3. Análise da simulação numérica da transferência de calor e massa na secagem dos cubos de goiaba em leito de jorro	91
CONCLUSÕES	96
REFERÊNCIAS BIBLIOGRÁFICAS	99

LISTA DE FIGURAS

Figura 1: Curvas de secagem características de variação de umidade em base seca em função do tempo (a) e a taxa de secagem em função da umidade em base seca (b). Fonte: Adaptado de (FOUST, A. S.; CLAMP, A. S., 1982).....	20
Figura 2: Diagrama esquemático de um leito de jorro cônico-cilíndrico.....	23
Figura 3: Típico gráfico de queda de pressão no leito versus a velocidade do ar que entra no leito. Fonte: Adaptado de (ZHONG <i>et al.</i> , 2006).....	24
Figura 4: Etapas para a formação de um leito de jorro: (a) Formação de cavidades internas; (b) Desenvolvimento de um jorro interno; (c) Estabelecimento de um jorro estável. Fonte: Adaptado de (NASCIMENTO, 2014).....	24
Figura 5: Regimes de fluxo no leito de jorro na secagem de cubos de goiaba: a) leito fixo; b) Leito de jorro; c) Leito borbulhante; d) <i>Slugging</i> . Fonte: Adaptado de (NASCIMENTO, 2014).	26
Figura 6: Diagrama de regimes para materiais sólidos ($d_p = 3,2$ à $6,4$ mm) em função da variação da altura do leito e da velocidade do ar. Fonte: Adaptado de (MATHUR & EPSTEIN., 1974).....	27
Figura 7: Esquema do processo de aprendizagem de um neurônio. Fonte: Adaptado de (SITTON <i>et al.</i> , 2017).	32
Figura 8: Representação de uma RNA utilizando como algoritmo de treinamento um do tipo <i>backpropagation</i> . Fonte: SILVA <i>et al.</i> , (2010).	34
Figura 9: Representação das funções de ativação mais comumente utilizadas.....	35
Figura 10: Esquema de um enxame de partículas com dimensão n e cada partícula com sua determinada dimensão. Fonte: Adaptado de (Carvalho, 2007).	40
Figura 11: Fluxograma da construção do modelo baseado em RNA.....	49
Figura 12: Diagrama esquemático do fluxo de dados dos modelos de redes neurais artificiais (MN-1 e MN-2).....	50
Figura 13: Fluxograma do algoritmo PSO aplicado à otimização da arquitetura da RNA.	52
Figura 14: Diagrama de fluxo de dados do processo de resolução do modelo híbrido.....	61
Figura 15: Evolução das propriedades físicas dos pedaços de goiaba durante a secagem no leito de jorro e classificação dos regimes de fluxo para o ensaio sob as condições experimentais: ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s ⁻¹). Fonte: (ALMEIDA, 2004).	63
Figura 16: Distribuição dos dados experimentais para os 3 subconjuntos de treinamento, validação e teste para: a) massa específica, b) diâmetro da partícula, c) Umidade em base seca e d) Regimes de fluxo.....	66
Figura 17: <i>Performance</i> do algoritmo de otimização baseado no número de partículas do enxame e nos valores do coeficiente pessoal (c1) e global (c2) de aceleração.	67
Figura 18: Arquitetura do modelo neural (MN-1) otimizado.....	71
Figura 19: <i>Performance</i> do modelo MN-1 durante a fase de treinamento, teste e validação do modelo.	72
Figura 20: Regressão linear feita para os dados de treinamento, validação, teste e o conjunto global para o modelo neural para predição das propriedades físicas dos pedaços de goiaba...73	73
Figura 21: Comparação entre os valores preditos pelo modelo MN-1 e os valores experimentais das cinéticas de variação da densidade dos pedaços de goiaba ao longo da secagem nas condições: a) 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) e 3 ($H_i = 0,09$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s ⁻¹) e b) 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s ⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s ⁻¹).	77

Figura 22: Comparação entre os valores preditos pelo modelo MN-1 e os valores experimentais das cinéticas de variação dos diâmetros das partículas dos pedaços de goiaba ao longo da secagem nas condições: a) 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) e 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s ⁻¹) e b) 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s ⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s ⁻¹).....	78
Figura 23: Comparação entre os valores preditos pelo modelo MN-1 e os valores experimentais das cinéticas de variação da umidade em base seca dos pedaços de goiaba ao longo da secagem nas condições: a) 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) e 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s ⁻¹) e b) 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s ⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s ⁻¹).....	79
Figura 24: Arquitetura do modelo neural (MN-2) otimizado.....	82
Figura 25: <i>Performance</i> do modelo MN-2 durante a fase de treinamento, teste e validação do modelo.	83
Figura 26: Matriz de confusão apresentada pelo modelo neural MN-2 para os bancos de dados de treinamento, validação, teste e total para cada regime de fluxo (1- leito fixo, 2- fluidização, 3- leito de jorro e 4- <i>slugging</i>).	84
Figura 27: Comparação entre os regimes preditos pelo modelo MN-2 e os regimes observados durante a secagem com condições experimentais distintas: a) ($H_i = 0,09$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s ⁻¹), b) ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s ⁻¹) e c) ($H_i = 0,105$ m, $U_i = 1,05$ e $u_{ar} = 3,2$ m.s ⁻¹).	88
Figura 28: Simulação da temperatura do leito de partículas e do ar na saída do secador nas condições experimentais: a) ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) e b) ($H_i = 0,12$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) a partir do modelo híbrido.....	92
Figura 29: Simulação da temperatura do leito de partículas e do ar na saída do secador, considerando um sistema isotérmico (sem perdas de calor) na condição experimental: ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹).....	94
Figura 30: Simulação dos perfis de umidade absoluta do ar de secagem na saída do secador e da umidade das partículas (b.s) nas condições experimentais: a) ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) e b) ($H_i = 0,12$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s ⁻¹) a partir do modelo híbrido.	95

LISTA DE TABELAS

Tabela 1: Equações para determinação da velocidade terminal da partícula e velocidade de mínima fluidização. Fonte: Adaptado de (ALMEIDA, 2004).....	30
Tabela 2: Trabalhos encontrados na literatura com a aplicação de modelos de RNA aplicados em processos de secagem.	36
Tabela 3: Trabalhos encontrados na literatura com a aplicação de modelos híbridos neurais à processos de secagem.	38
Tabela 4: Delineamento experimental proposto.....	45
Tabela 5: Variáveis do delineamento experimental na forma descodificada.	46
Tabela 6: Funções de ativação utilizadas no processo de treinamento e suas respectivas equações.....	53
Tabela 7: Valores finais e iniciais para as propriedades físicas da goiaba estudadas ($U(b.s)$, ρ e d_p) e para o número de Arquimedes e parâmetro de Littman para as diferentes condições experimentais estudadas.	64
Tabela 8: Níveis de máximo e mínimo das variáveis de entrada e saída do MN-1.....	68
Tabela 9: Parâmetros da rede neural (MN-1) otimizados utilizando o algoritmo PSO.....	69
Tabela 10: Desempenho da melhor configuração de rede selecionada pelo algoritmo de otimização para o modelo MN-1.	70
Tabela 11: Matriz dos pesos e das bias para o modelo neural (MN-1).	74
Tabela 12: Importância relativa de cada variável de entrada para cada variável de saída do modelo neural (MN-1) calculado pelo método dos pesos sinápticos.	75
Tabela 13: Comparação entre os valores de mínimos e máximos reais e os preditos pelo modelo MN-1 e respectivos erros de predição.	80
Tabela 14: Níveis de máximo e mínimo das variáveis de entrada e saída do modelo MN-2...	81
Tabela 15: Matriz dos pesos e bias para o modelo neural MN-2.	85
Tabela 16: Importância relativa de cada variável de entrada para cada variável de saída do modelo neural (MN-2) obtido pelo método dos pesos sinápticos.	86
Tabela 17: Precisão do modelo MN-2 na predição dos diferentes regimes de fluxo durante a secagem dos pedaços de goiaba em leito de jorro.	89
Tabela 18: Resultados do teste estatístico F obtido para as quatro variáveis de saída dos modelos MN-1 e MN-2 em compoaração com os valores reais.	90

LISTA DE SÍMBOLOS

A – Parâmetro de *Littman* (-)

Ar – Número de Arquimedes (-)

a_e - área do sólido em contato com o ar de secagem ($\text{m}^2 \cdot \text{m}^{-3}$)

a_p – área específica das partículas ($\text{m}^2 \cdot \text{m}^{-3}$)

a_T – área transversal (m^2)

C_p – calor específico do sólido ($\text{J} \cdot \text{Kg}^{-1} \cdot \text{K}^{-1}$)

$C_{p \text{ ar}}$ – calor específico do ar ($\text{J} \cdot \text{Kg}^{-1} \cdot \text{K}^{-1}$)

d – diâmetro (m)

g - aceleração da gravidade ($\text{m} \cdot \text{s}^{-2}$),

G - vazão mássica de ar seco ($\text{kg} \cdot \text{s}^{-1}$)

h – coeficiente de transferência de calor entre a parede do secador e o ar externo ($\text{W} \cdot \text{m}^{-2} \cdot \text{K}^{-1}$)

h_p – coeficiente de transferência de calor entre o ar de secagem e o leito de partículas ($\text{W} \cdot \text{m}^{-2} \cdot \text{K}^{-1}$)

h_w – coeficiente de transferência de calor entre o leito de partículas e a parede do secador ($\text{W} \cdot \text{m}^{-2} \cdot \text{K}^{-1}$)

H – entalpia do ar úmido ($\text{J} \cdot \text{kg}^{-1}$)

H_i – altura inicial do leito de partículas (m)

k – condutividade térmica ($\text{W} \cdot \text{m}^{-1} \cdot \text{K}^{-1}$)

L – altura do secador (m)

ln – logaritmo neperiano

m_{ss} – massa de sólido seco (Kg)

Nu – número de *Nusselt* (-)

P – Pressão (kPa)

Pr – número de *Prandtl* (-)

P_v – pressão de vapor (kPa)

Q_p – calor perdido (W)

Ra – número de *Rayleigh* (-)

Re – número de *Reynolds* (-)

t – tempo (s)

t_{po} – temperatura no ponto de orvalho (°C)

T - temperatura (K)

u – velocidade superficial do ar ($m \cdot s^{-1}$)

u_{ar} – velocidade operacional do ar ($m \cdot s^{-1}$)

u_t – velocidade terminal da partícula ($m \cdot s^{-1}$)

v_{mf} – velocidade mínima de fluidização ($m \cdot s^{-1}$)

U – umidade (b.s)

UR – umidade relativa (%)

V_{esp} – volume específico (m^3)

W - umidade absoluta do ar ($kg_{\text{vapor d'água}} \cdot kg^{-1}_{\text{ar seco}}$)

Símbolos gregos

λ – calor latente de vaporização da água ($J \cdot Kg^{-1}$)

ε – porosidade do leito (-)

ρ – densidade (kg.m^{-3})

μ - viscosidade ($\text{kg.m}^{-1}.\text{s}^{-1}$)

β – coeficiente de expansão térmica (K^{-1})

ν – viscosidade cinemática ($\text{m}^2.\text{s}^{-1}$)

α – difusividade térmica ($\text{m}^2.\text{s}^{-1}$)

Δ – diferença (-)

Subscritos

amb – ar ambiente

ar – ar de secagem

b.s – base seca

c - coluna

e – entrada

ext – externo

i - inicial

int - interno

o – orifício de entrada

p - partícula

s – saída

sat - saturação

par – parede do secador

1. INTRODUÇÃO

A secagem é uma das técnicas mais antigas de preservação de alimentos, pois através do processo de secagem pode-se aumentar a resistência do produto a ataque de bactérias e fungos que se utilizam da presença de umidade para se proliferarem. As frutas é um dos tipos de alimentos que apresentam maior perecibilidade, associado ao envelhecimento do fruto existe a perda de propriedades físicas, nutricionais e sensoriais, o que causa a esse tipo de produto uma baixa comercialização para mercados externos.

Um dos métodos de secagem que vem ganhando bastante notoriedade em estudos recentes é a secagem através do leito de jorro. Essa técnica de secagem foi desenvolvida no Canadá em meados dos anos de 1955, desde então o leito de jorro vem sendo utilizado na secagem de diversos tipos de materiais, como: suspensões, pastas, grãos, frutas e legumes (ROBBINS *et al.*, 2003; ALMEIDA *et al.*, 2006; ZIELINSKA *et al.*, 2007; KAHYAOGU *et al.*, 2010; ROCHA *et al.*, 2011; FREIRE *et al.*, 2012; BEZERRA *et al.*, 2013; NASCIMENTO *et al.*, 2013; YOUSEFI *et al.*, 2014). Como vantagens esse equipamento proporciona durante a secagem uma alta taxa de circulação de sólidos dentro do leito, e um efetivo contato entre o fluido de secagem e o sólido. Porém uma problemática na operação com leito de jorro é a secagem de materiais deformáveis, uma vez que esses tipos de materiais podem encolher durante a secagem e modificar as suas propriedades físicas, causando no leito instabilidades e mudanças no regime ao longo do processo (ALMEIDA *et al.*, 2006).

Uma estratégia para se manter a estabilidade nos diversos tipos de regime de operação pode se dar através do controle de variáveis operacionais, como a velocidade do ar de secagem. Para a implementação do controle dessa variável operacional seria necessário o conhecimento das mudanças das propriedades físicas do material a ser seco, bem como das mudanças dos regimes de fluxo ao longo do tempo de secagem em função da variação das propriedades físicas do material (ALMEIDA *et al.*, 2006). Diante desse cenário, evidencia-se a necessidade de criação de modelos matemáticos que consigam descrever a secagem de partículas deformáveis.

Através de modelos fenomenológicos pode-se ter o entendimento dos fenômenos de transferência de calor e massa entre o material a ser seco e o ar de secagem. Com o conhecimento desses fenômenos seria possível realizar o projeto e desenvolvimento de sistemas de controle para novos secadores (SOUZA *et al.*, 2015). Trabalhos encontrados na literatura

realizaram a modelagem fenomenológica de processos de secagem em diferentes tipos de secadores através da realização do balanço de massa entre as fases (BIALOBRZEWSKI *et al.*, 2008; NIAMNUY *et al.*, 2008; SOUZA *et al.*, 2015).

A parte dos modelos fenomenológicos, se destaca na literatura a utilização de modelos baseados em Redes Neurais artificiais (RNA), esse tipo de inteligência artificial tenta simular a forma de aprendizagem do cérebro humano e é atualmente uma importante ferramenta para a modelagem de sistemas não-lineares, complexos e dinâmicos (AGHBASHLO *et al.*, 2015). Devido a essas vantagens esse tipo de modelo é vastamente utilizado em diferentes campos da ciência e engenharia, em processos de secagem esses modelos foram utilizados para o reconhecimento de padrões (KIM *et al.*, 2005; WANG *et al.*, 2011), para predição das propriedades físicas dos materiais durante a secagem (MIHAJLOVIC *et al.*, 2011; SILVA *et al.*, 2015; YOUSEFI *et al.*, 2014), porém ainda são escassos os trabalhos aplicando esse tipo de modelo para predição de propriedades físicas de partículas sólidas deformáveis na secagem em leito de jorro.

Uma outra alternativa para o uso dos modelos de RNA's é utiliza-los juntamente com modelos fenomenológicos afim de ajustar parâmetros, formando assim um modelo híbrido (NASCIMENTO *et al.*, 2013). Alguns trabalhos na literatura mostram a utilização de modelos híbridos aplicados em processos de secagem (NASCIMENTO *et al.*, 2013; SILVA COSTA *et al.*, 2016), entretanto, não encontra-se trabalhos na literatura com a aplicação de modelos híbridos ao processo de secagem de partículas sólidas deformáveis em leito de jorro.

Em estudos experimentais anteriores realizados por ALMEIDA (2004) sobre a secagem de pedaços cúbicos de goiaba em secador de leito de jorro, foi investigado o comportamento do material, bem como a fluidodinâmica do leito durante a secagem, tal fruta foi selecionada devido a apresentar durante o processo de secagem em leito de jorro o fenômeno de encolhimento e deformabilidade de partículas grandes. A partir do exposto, destaca-se o interesse neste trabalho de utilizar este processo como estudo de caso, bem como utilizar os dados produzidos por ALMEIDA (2004) para desenvolver diferentes modelos preditivos a partir da utilização da técnica de redes neurais artificiais e modelagem fenomenológico, no intuito de descrever o comportamento do processo de secagem de materiais deformáveis, a citar, a goiaba.

1.1. Objetivo geral

O trabalho tem por objetivo descrever o comportamento fluidodinâmico do leito de jorro e os fenômenos de transferência de calor e massa envolvidos na secagem de pedaços de goiaba que se deformam durante a secagem, utilizando técnicas de modelagem aplicadas ao processo.

1.2. Objetivos específicos

- Descrever, a partir da aplicação de modelo(s) baseado em redes neurais artificiais a evolução das propriedades físicas (umidade, densidade e diâmetro das partículas) dos cubos de goiaba na secagem em leito de jorro;
- Descrever, a fluidodinâmica do leito com relação a distinção dos regimes de fluxo a partir da relação entre a evolução das propriedades físicas da goiaba durante a secagem e números adimensionais através da aplicação de modelo(s) neural(is);
- Representar, a partir do modelo baseado no balanço de massa e energia proposto o comportamento da variação da umidade do ar e da partícula, bem como a temperatura do ar e da partícula durante o processo de secagem;
- Comparar a *performance* e validar os diferentes tipos de modelos neurais desenvolvidos a partir de índices estatísticos de desempenho;

2. REVISÃO BIBLIOGRÁFICA

2.1. A Goiaba e sua produção no Brasil

A goiaba (*Psidium guajava* L.) é uma fruta com origem na América tropical e que foi espalhada pelas diferentes regiões do mundo e atualmente é considerada uma das principais matérias primas para a fabricação de sucos, polpas e néctares. Com grande aceitação nos diferentes mercados no mundo essa fruta se enquadra como uma das melhores fontes de Vitamina C por apresentar cerca de 55 a 1044 mg de ácido ascórbico por 100 g de polpa, a depender do local de cultivo e do tipo de manejo aplicado, bem como a sua variedade (VIEIRA, 2014).

Além de ser uma grande fonte de Vitamina C a goiaba também é rica em vitaminas A, B₁ (Tiamina), B₂ (Riboflavina), B₆ (Piridoxina), apresentando também grande quantidade de licopeno, potássio, cobre e fibras (QUEIROZ, 2004).

O cultivo desta fruta é de fundamental importância para a região do Nordeste brasileiro, mostrando-se como uma atividade econômica e social de grande expressão, garantindo renda às comunidades rurais e pequenas empresas. Pode-se ter uma ideia da importância do cultivo desta fruta quando se analisa a área de cultivo na região Nordeste, aonde se chegou a cultivar em 2013 cerca de 6.741 hectares (IBGE, 2013).

Um dos pontos negativos do cultivo da goiaba se encontra na perecibilidade elevada dos frutos pós-colheita, onde é observado um alto grau de envelhecimento dos frutos em apenas quatro dias após sua colheita. O envelhecimento dos frutos traz também consigo perda de atributos de qualidade, como suas propriedades físicas, sensoriais e nutricionais. Diante desses fatos surge então a necessidade de desenvolvimento de processos, como a secagem, afim de garantir um maior tempo de vida útil do material (VIEIRA, 2014).

2.2. Secagem

Um dos métodos mais antigos para a conservação de alimentos é a secagem, que há séculos vem permitindo ao homem retardar a deterioração de produtos biológicos após a sua maturação fisiológica (DIAS, 2015).

Um fenômeno inerente ao processo de secagem é a transferência de massa, seja pela difusão da água no estado líquido, decorrente do gradiente de concentração da umidade ou pela difusão do vapor. Já a transferência de energia se dá na forma de calor devido a diferença de temperaturas entre a superfície do material sólido e a fonte quente, proporcionando assim a troca de calor pelo processo condutivo, convectivo ou radiação ou mesmo um processo combinado entre eles. Os mecanismos de transferência de calor e massa predominante no processo de secagem pode variar durante a secagem, onde em determinados períodos o mecanismo de transferência que apresentar maior resistência é denominado de mecanismo predominante (DIAS, 2015).

A Figura 1 apresenta as curvas de secagem características, de variação de umidade em função do tempo e a taxa de secagem em função da umidade e identifica-se os períodos da secagem.

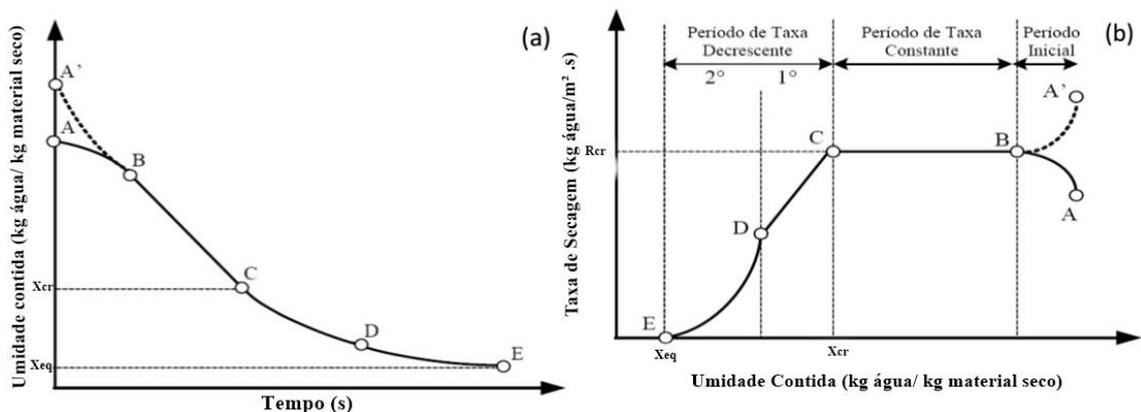


Figura 1: Curvas de secagem características de variação de umidade em base seca em função do tempo (a) e a taxa de secagem em função da umidade em base seca (b). Fonte: Adaptado de (FOUST, A. S.; CLAMP, A. S., 1982)

Na Figura 1 (a), o período de A-B representa o início da secagem onde, nessa situação o sólido a ser secado se encontra em temperaturas menores que a temperatura do gás de secagem, então o calor fornecido pelo gás irá aumentar a temperatura do sólido até que a sua temperatura

atinga a temperatura do bulbo úmido do ar. Já no período inicial de A'-B, a temperatura do sólido a ser secado é inicialmente maior que a temperatura do gás de secagem e neste caso a temperatura do sólido tende a diminuir até atingir a temperatura de bulbo úmido do ar.

Para o período B-C, o calor fornecido ao sólido é utilizado para a evaporação da água livre que está na sua superfície do sólido, nesta etapa a temperatura e a pressão de vapor são constantes e igual a temperatura de bulbo úmido do ar e pressão de vapor de água pura a temperatura do sólido respectivamente. Esse período é chamado de período de taxa constante, como pode ser observado na Figura 1 (b). Nestas condições a água que migra do interior do sólido até a sua superfície é completamente evaporada e o mecanismo predominante é a difusão de água no filme de ar que envolve o material.

Quando o material então atinge a umidade crítica (U_{cr}), ponto C na Figura 1 (a), inicia-se o período de taxa decrescente que termina no ponto E. Neste momento a taxa de reposição da água à superfície do sólido já não é a mesma que a taxa de evaporação da água da superfície, a partir daí o transporte de umidade no interior do material passa então a controlar o processo. Nessa etapa a superfície do sólido já não se encontra mais saturada e o mecanismo de transferência de massa predominante no interior do sólido é a difusão líquida devido ao gradiente de concentração, ou então pelo efeito da capilaridade resultante da diferença de pressão hidrostática provocada pela tensão superficial. Na etapa C-D (1ª etapa de taxa decrescente) a superfície do sólido já não pode ser mais mantida saturada de água pela umidade contida nos poros do material. Já na etapa D-E (2ª etapa de taxa decrescente) a superfície já se encontra completamente insaturada e há então a entrada do gás de secagem quente no interior dos poros do material formando bolsas de ar em seu interior (STRUMILLO; KUDRA, 1986 *apud* COSTA, 2013).

As variáveis que mais influenciam na transferência de massa no período de taxa constante e na primeira etapa de taxa decrescente são a temperatura e a umidade do ar de secagem, a umidade inicial do sólido, além da estrutura do material (COSTA, 2013).

Já no ponto E da Figura 1 (a) o material atingiu a umidade de equilíbrio (U_{eq}) e a taxa de secagem então tende a zero. Essa umidade de equilíbrio corresponde a umidade no qual existe o equilíbrio entre as pressões de vapor da água presente no material e no ambiente, esse valor de umidade então corresponde ao mínimo que um material pode alcançar em determinadas condições (BARROZO, 1995).

A combinação entre a análise e estudo de curvas de secagem como demonstrado na Figura 1, bem como a determinação do teor de água permitem entender melhor o processo de secagem, serve como uma ferramenta importante para definir equipamentos e temperaturas adequadas para serem realizadas a desidratação de alimentos de um modo geral com melhores qualidades sensoriais e tecnológicas (OLIVEIRA *et al.*, 2006).

2.3. Leito de Jorro

A técnica de jorro foi desenvolvida por volta de 1955 no Canadá, onde tal equipamento foi inicialmente projetado para a secagem de grãos de trigo em um processo que permitisse a aplicação de maiores quantidades de calor sem a ocorrência da perda de qualidade do material a ser secado (MATHUR; GICHLER, 1955). Desde então a técnica de secagem por leito de jorro tem sido bastante aplicada na secagem de diversos produtos, como: grãos, soluções, suspensões e pastas (MEDEIROS, 2001).

Essa técnica de secagem apresenta uma série de características importantes, tais como, promover atrito entre as partículas e a parede do equipamento devido a colisão, a alta velocidade no jorro que propicia um excelente grau de mistura e efetivo contato entre o gás injetado e o sólido a ser secado, resultando em altas taxas de transferência tanto de calor quanto de massa entre as fases (DIAS, 2015).

Concebido primeiramente por Mathur e Gishler em 1955, o leito de jorro convencional é constituído de uma câmara de secagem com formato cilíndrico e possui uma base cônica, onde possui em sua extremidade inferior um orifício de entrada, onde é injetado em seu interior o fluido de jorro (geralmente ar) produzindo um jato. Na Figura 2 é apresentado um esquema de um leito de jorro típico cônico-cilíndrico.

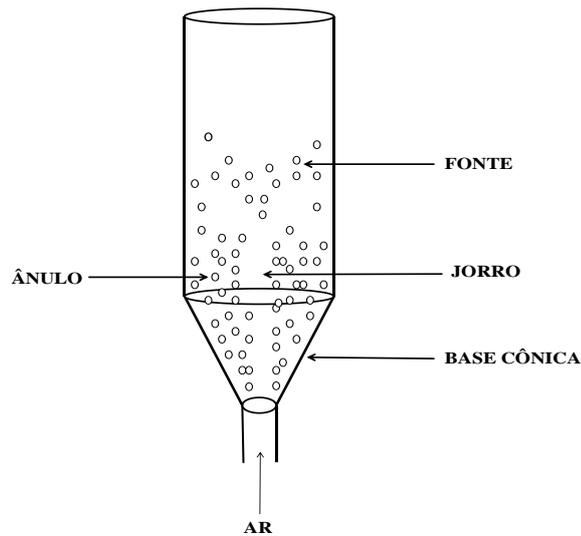


Figura 2: Diagrama esquemático de um leito de jorro cônico-cilíndrico.

Para se estabelecer um regime de jorro, primeiramente, injeta-se o fluido pelo orifício contido na base cônica que entrará em contato com o leito de sólidos particulados, com isso observará uma aceleração ascendente das partículas sólidas e se formará um canal central diluído onde as partículas apresentam altas velocidades, essa região é chamada de região de jorro. Ao redor desse canal central, ocorre a presença de um leito denso de partículas, que irão se deslocar contra o fluxo ascendente do jorro, essa região que compreende o leito deslizante de partículas é denominada de ânulo ou região anular (MATHUR & EPSTEIN, 1974).

As partículas suspensas pelo jorro desaceleram quando alcançam a superfície do leito o que resultará em uma queda na região anular. Essas mesmas partículas então descreverão uma trajetória de volta a região do jorro, seja pelo fluxo cruzado na interface jorro-ânulo ou quando atingirem a base do leito (região próxima ao orifício de entrada do ar) (MATHUR & EPSTEIN., 1974).

2.3.1. Fluidodinâmica do leito (Curvas características)

A fluidodinâmica apresentada pelo leito de jorro é um dos problemas encontrados na operação e controle desses tipos de secadores, tendo em vista que esse equipamento apresenta grande complexidade nos fenômenos fluidodinâmicos.

O mecanismo de transição de um leito estático para um leito de jorro é bem descrito pela Figura 3, onde é mostrado a queda de pressão dentro do leito pela velocidade do ar que entra

no jorro para diferentes alturas de leito inicial. Já a Figura 4 ilustra o comportamento visual do leito durante essa transição.

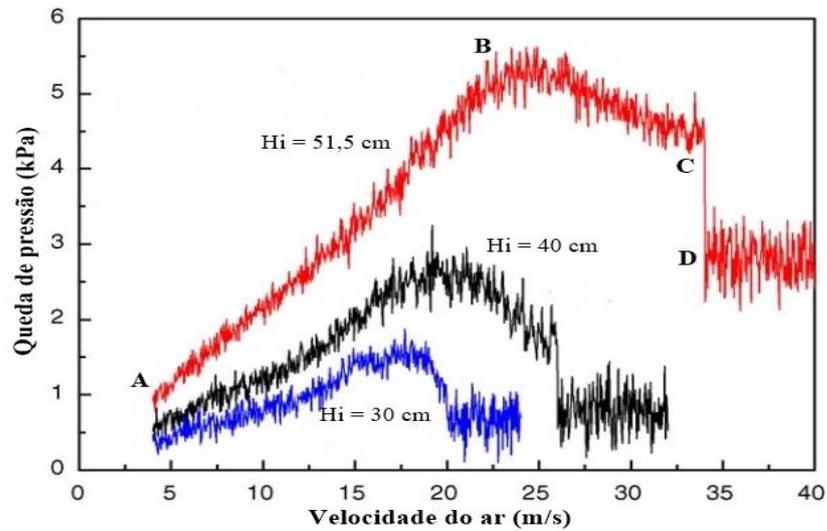


Figura 3: Típico gráfico de queda de pressão no leito versus a velocidade do ar que entra no leito. Fonte: Adaptado de (ZHONG *et al.*, 2006).

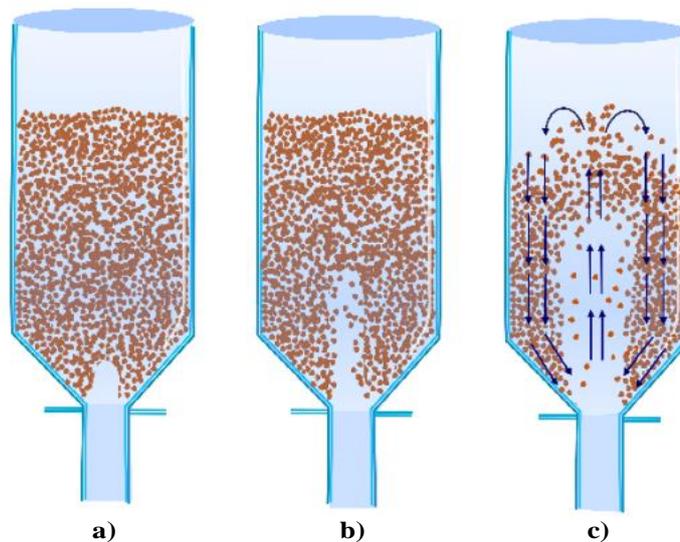


Figura 4: Etapas para a formação de um leito de jorro: (a) Formação de cavidades internas; (b) Desenvolvimento de um jorro interno; (c) Estabelecimento de um jorro estável. Fonte: Adaptado de (NASCIMENTO, 2014).

Ao observar a Figura 3, é possível identificar alguns fenômenos que acontecem dentro do leito:

1. Entre os pontos A e B, pode-se observar um aumento na queda de pressão dentro do leito com o aumento da velocidade do ar, porém, não existem perturbações muito grandes no leito de partículas, apenas a formação de uma cavidade oca acima do orifício de entrada do ar, que pode ser observado de modo visual na Figura 4 (a);
2. Ainda entre os pontos A e B com o aumento da velocidade do ar será formado então um jorro interno, fenômeno que pode ser visualizado na Figura 4 (b);

3. Quando alcançamos então o ponto B da Figura 3, temos então a perda de carga máxima registrada no leito (ΔP_{max}). Esse ponto antecipa o jorro e a queda de pressão constante de jorro (ΔP_s);
4. Conforme então se aumenta a velocidade do ar, partimos do ponto B para o ponto C, onde nesse ponto o jorro que antes era interno consegue romper a superfície de partículas, acarretando na queda de pressão até o ponto C. Neste ponto já pode ser observado um jorro incipiente dentro do equipamento, porém, ainda existem dentro do leito oscilações da queda de pressão e a formação de bolhas de ar dentro do leito, resultando em contrações e expansões do leito interno;
5. Um pequeno aumento da velocidade além do ponto C provoca então a formação de um jorro incipiente, onde o jorro interno consegue então romper a superfície do leito de partículas, fenômeno observado na Figura 4 (c). Quando esse fenômeno ocorre, a concentração de sólidos na região diretamente acima da entrada do ar diminui abruptamente causando assim, uma redução na queda de pressão até o ponto D;
6. A partir do ponto D, onde o jorro já aflora o leito de partículas, o aumento da velocidade do ar apenas causa uma elevação da altura da fonte, mantendo a queda de pressão constante. Nesse ponto a queda de pressão atual é chamada de queda de pressão constante de jorro (ΔP_s) (MATHUR & EPSTEIN, 1974).

2.3.2. Regimes fluidodinâmicos no leito de jorro

Diferentes regimes de fluxo podem ser identificados em um secador do tipo leito de jorro durante a secagem, onde podemos incluir o leito fixo, fluidização, leito de jorro, *slugging*, leito borbulhante, dentre outros mais incomuns. A Figura 5 ilustra alguns desses regimes que acontecem durante a secagem em leito de jorro e os critérios para descrever esses tipos de regimes são:

- O leito fixo acontece quando não há movimento relativo das partículas. A velocidade do gás é menor que a velocidade mínima de fluidização (V_{mf}) ou velocidade mínima de jorro (V_{mj}) (Figura 5 a));
- A fluidização acontece localmente, geralmente as partículas da seção superior do leito são fluidizadas, enquanto que as partículas próximas ao orifício de entrada do ar apresentam instabilidade, formando bolhas periodicamente próximo a superfície do leito;

- O leito de jorro é observado quando o ar de secagem consegue aflorar no topo da superfície de partículas. Isso ocorre quando a velocidade do gás de secagem é maior ou igual à velocidade mínima de jorro (V_{mj}) (Figura 5 b));
- O regime de leito borbulhante ocorre quando existe a formação de bolhas no corpo do leito, porém coexiste no leito um jorro estável (Figura 5 c));
- *Slugging* acontece quando há a formação de grandes bolhas de ar no orifício de entrada do ar no leito de jorro inicialmente e podem acontecer também no meio e na parte superior do leito, não acontecendo então a fluidização no topo do ânulo (Figura 5 d)) (EPSTEIN, N.; GRACE, 2011).

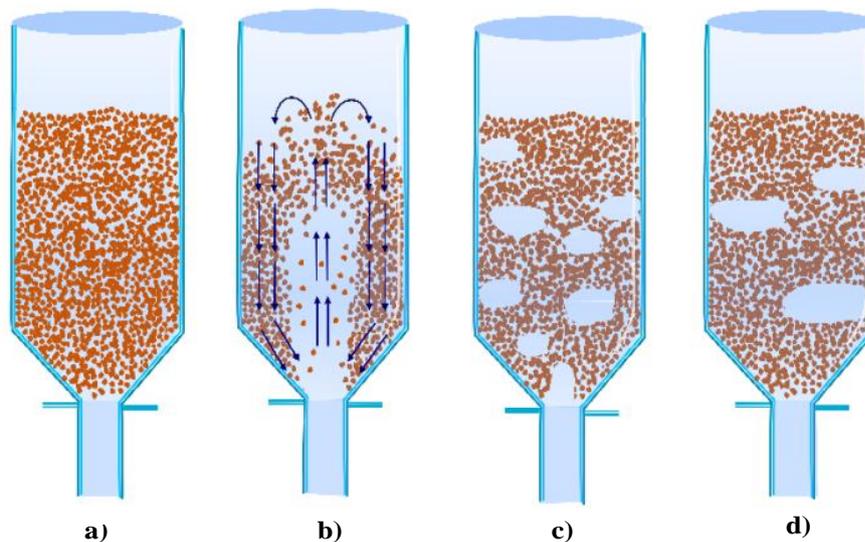


Figura 5: Regimes de fluxo no leito de jorro na secagem de cubos de goiaba: a) leito fixo; b) Leito de jorro; c) Leito borbulhante; d) *Slugging*. Fonte: Adaptado de (NASCIMENTO, 2014).

A Figura 6 mostra o diagrama de regimes em função da altura do leito e da velocidade do ar, observado na secagem de matérias com diâmetros entre 3,2 e 6,4 mm, diâmetro equivalente aos obtidos no corte dos pedaços cúbicos de goiaba observados no trabalho de ALMEIDA (2004) .

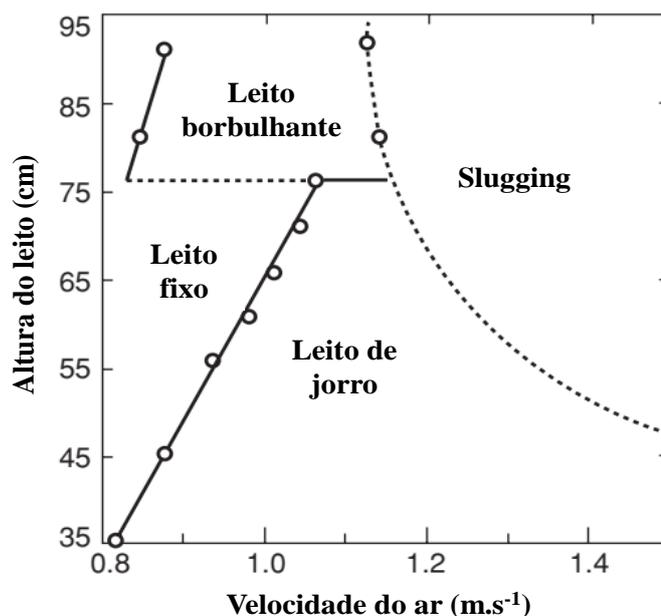


Figura 6: Diagrama de regimes para materiais sólidos ($d_p = 3,2$ à $6,4$ mm) em função da variação da altura do leito e da velocidade do ar. Fonte: Adaptado de (MATHUR & EPSTEIN., 1974).

As linhas observadas na Figura 6, representam as transições entre as fases de leito fixo para o leito agitado (leito borbulhante ou leito de jorro). É observado uma altura máxima do leito de jorro, onde a partir desse valor de altura existe dentro do secador uma baixa fluidização (regime de leito borbulhante), essa altura limite na Figura 6 é observada em 76 cm, representada pela linha horizontal. A velocidade mínima de jorro é representada na Figura 6 pela linha inclinada, onde tem-se o seu valor final no encontro com a linha horizontal (linha que representa a altura máxima do leito de jorro).

Existem alguns modos de se detectar a mudança de regimes fluidodinâmicos em um leito de jorro, entre ele se destacam na literatura a observação visual da mudança de regime quando se tem as paredes do leito transparentes e o emprego de medidas de sinais de flutuação de pressão no leito, utilizando diferentes técnicas para o tratamento dos dados.

WANG *et al.* (2011a) utilizaram sinais de flutuação de pressão do leito de jorro para prever o regime fluidodinâmico do leito. Os autores utilizaram modelos baseados em linguagem *fuzzy* usando como dados de entrada a variação de pressão no leito. O modelo então classificava os regimes em leito fixo, leito de jorro, leito borbulhante e *slugging*. Com esse modelo os autores relatam ter obtido reconhecimento de 80 a 90% dos regimes adotados.

XU *et al.* (2004) e OLIVEIRA *et al.* (2008) trataram dados de flutuação de pressão em séries de tempos advindos de transdutores de pressão distribuídos em algumas posições axiais do secador leito de jorro a fim de identificar os regimes de fluxo (leito fixo, jorro incipiente,

jorro estável, jorro pulsante, *slugging*, leito borbulhante e fluidização). Os autores utilizaram análises estatísticas como a teoria da informação mútua e análise espectral para tratar os dados e relataram que as ferramentas testadas mostraram bom desempenho no tratamento dos dados da flutuação de pressão para posteriormente identificar os regimes presentes no leito.

ALMEIDA *et al.* (2006) classificaram os regimes de fluxo através de observações visuais no leito de jorro que possuía paredes transparentes. Através das observações os regimes foram classificados em leito fixo, leito de jorro, fluidização e *slugging*.

2.3.3. *Evolução das propriedades físicas dos materiais durante a secagem e sua influência na fluidodinâmica do leito*

A importância do conhecimento das propriedades físicas dos produtos agrícolas (vegetais e frutas) a serem secos se refere a necessidade de construção e operação de equipamentos de secagem e armazenagem. Propriedades como a densidade granular, podem ser utilizadas como parâmetro de qualidade bem como pode também influenciar na comercialização do produto, e dimensionamento de silos e depósitos (ARAUJO *et al.*, 2014).

Por outro lado, a porosidade dos produtos agrícolas pode ser útil para o dimensionamento de sistemas de secagem e de aeração. O tamanho e a forma desses produtos podem apresentar dificuldades na maioria das vezes na sua determinação, porém possuem grande importância para o dimensionamento de peneiras, normalmente presentes em processos de separação e classificação. Essa mudança nas características físicas dos grãos, como o decréscimo na massa específica unitária, deformação do material, acarretando, por exemplo, a formação de espaços vazios no seu interior, redução da sua massa e da esfericidade e contração volumétrica do material que leva a uma redução das dimensões características do produto e consequente encolhimento são provocados pela perda de água no material (ARAUJO *et al.*, 2014).

RUSSO *et al.* (2013) investigaram a influência da temperatura do ar de secagem nas propriedades físicas da berinjela seca ou reidratada. Os autores estudaram as mudanças estruturais na berinjela em 4 diferentes temperaturas (40, 50, 60 e 70°C) do ar de secagem. Foi observado que a porosidade das amostras aumentou com o aumento da temperatura do ar, porém a estrutura foi mais preservada quando utilizado temperaturas intermediárias (60°C). Os autores concluíram também que longos tempos de secagem bem como altas temperaturas causam o enrugamento das estruturas da berinjela.

A modelagem, os projetos e desenvolvimento de operações de controle dependem diretamente das mudanças observadas nas propriedades físicas dos produtos biológicos durante a secagem, como o teor umidade, encolhimento, porosidade, densidade aparente e volume (KOÇ *et al.*, 2008).

Acompanhado da evolução das propriedades físicas dos materiais durante a secagem, existe também as modificações sofridas no comportamento fluidodinâmico do leito de jorro, como foi observado por MATHUR & EPSTEIN, (1974), que afirma que a estabilidade do regime de jorro depende das propriedades das partículas e dos fluidos, bem como também de parâmetros geométricos e dimensionais da coluna.

Parâmetros fluidodinâmicos como o número de Arquimedes e o parâmetro de *Littman* são afetados diretamente pelas mudanças ocorridas nas propriedades físicas do material e do gás. O número de Arquimedes foi desenvolvido com o intuito de ser utilizado para determinar o movimento de fluidos devido a diferença entre a densidade e o tamanho das partículas, com isso então os efeitos da mudança nesse número adimensional afetam diretamente na estabilidade e na fluidodinâmica do secador.

O número de Arquimedes (Equação 1) é definido como sendo a razão entre as forças gravitacionais por forças viscosas.

$$Ar = \frac{d_p^3 g \rho_{ar} (\rho_p - \rho_{ar})}{\mu^2} \quad (1)$$

Onde: g é a aceleração da gravidade, ρ_{ar} é a densidade do ar de secagem, ρ_p é a densidade da partícula a ser seca, μ é a viscosidade dinâmica do ar de secagem e d_p é o diâmetro da partícula.

O parâmetro de *Littman* (Equação 2) relaciona a energia mínima requerida do ar de secagem necessário para formar o jorro e a energia necessária para manter o jorro em sua área transversal sob as condições mínimas. O parâmetro de *Littman* é também bastante influenciado pelas modificações nas propriedades físicas dos materiais.

$$A = \frac{\rho_{ar} u_{mf} u_t}{(\rho_p - \rho_{ar}) g d_0} \quad (2)$$

Onde: u_{mf} é a velocidade de mínima fluidização, u_t é a velocidade terminal, ρ_p e ρ_g é a densidade da partícula e do gás respectivamente, d_o é o diâmetro do orifício de entrada do gás no leito e g é a aceleração da gravidade. A velocidade terminal da partícula pode ser determinada considerando a partícula em formato esférico a partir das Equações 3, 4 ou 5 da Tabela 1, já a velocidade de mínima fluidização pode ser determinada pelas Equações 6, 7 e 8 contidas na mesma tabela.

A depender da faixa do parâmetro de *Littman* (A), pode ser observado diferentes características do escoamento de ar no leito em função do mecanismo de terminação do leito, são esses:

- $A > 0,02$: tem como mecanismo de terminação do jorro a fluidização no topo do anular;
- $0,014 < A < 0,02$: tem-se a transição dos mecanismos;
- $A < 0,014$: tem-se como mecanismo a degeneração do jorro na base do leito (pistonagem).

Tabela 1: Equações para determinação da velocidade terminal da partícula e velocidade de mínima fluidização. Fonte: Adaptado de (ALMEIDA, 2004).

	Condição	Equação
Velocidade terminal da partícula	Reynolds < 0,4	$u_t = \frac{g \cdot d_p^2 \cdot (\rho_p - \rho_{ar})}{18\mu}$ (3)
	0,4 < Reynolds < 500	$u_t = \left[\frac{4}{225} \frac{(\rho_p - \rho_{ar})^2 \cdot g^2}{\rho_{ar} \cdot \mu} \right]^{1/3} \cdot d_p$ (4)
	500 < Reynolds < 200.000	$u_t = \left[\frac{3,1 \cdot g \cdot (\rho_p - \rho_{ar}) \cdot d_p}{\rho_{ar}} \right]^{1/2} \cdot d_p$ (5)
Velocidade de mínima fluidização	--	$\frac{d_p \cdot u_{mf} \cdot \rho_{ar}}{\mu} = [28,7^2 + 0,0494 \cdot Ar]^{0,5} - 28,7$ (6)
	--	$\frac{d_p \cdot u_{mf} \cdot \rho_{ar}}{\mu} = [25,46^2 + 0,0382 \cdot Ar]^{0,5} - 25,46$ (7)
	--	$\frac{d_p \cdot u_{mf} \cdot \rho_{ar}}{\mu} = 2,79 \cdot 10^{-2} Ar^{0,63}$ (8)

A secagem da goiaba em secador do tipo leito de jorro possui grande relevância para a literatura, tendo em vista que através da secagem desse produto em leito de jorro, pode-se estudar como se comporta o leito durante a secagem de um material deformável, e dessa forma relacionar as mudanças nas propriedades físicas desse material à eficiência do processo de secagem. Relacionando as mudanças nas propriedades físicas às modificações sofridas nos regimes fluidodinâmicos bem como a estabilidade apresentada por esses.

2.4. Redes Neurais Artificiais

Segundo LINKO *et al.* (1992) e ZORZETTO *et al.* (2000), os modelos baseados em redes neurais são chamados de modelos empíricos, ou modelo de caixa preta, pois não necessitam conhecimento do fenômeno físico envolvido no processo em que se quer modelar, apenas basta ter um banco de dados que deve ser representativos para o processo

Essencialmente os modelos de Redes Neurais Artificiais (RNA's) são modelos computacionais que simulam a função dos neurônios biológicos e aprendem a partir da experiência ou treinamento (processo de aprendizagem). A partir disso as RNA's são capazes de correlacionar dados entre si, possibilitando evidenciar informações presentes no banco de dados anteriormente não perceptíveis, sem que se conheça previamente a relação entre as variáveis (KARIMI *et al.*, 2012).

A estrutura das redes neurais, comumente chamada também de arquitetura da rede é constituída de três camadas de neurônios. A primeira é a camada de entrada, onde são apresentados à rede os padrões (dados de entrada), a segunda é a camada intermediária ou também chamada de camada escondida, onde é feito a maior parte do processamento das informações por meios de conexões ponderadas. É nessa camada que são extraídas as características do sistema a ser modelado. E por fim a camada de saída, onde através dessa são concluídos e apresentados os resultados finais.

A Figura 7 ilustra o esquema de aprendizagem de um neurônio artificial, representando o processo de apresentação dos dados de entrada para o neurônio, processamento de dados feita pelo combinador linear até a apresentação do resultado final.

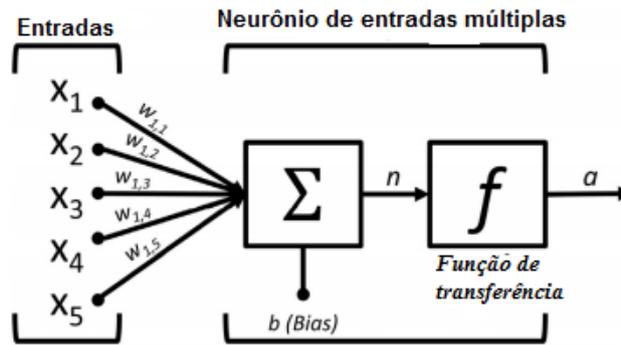


Figura 7: Esquema do processo de aprendizagem de um neurônio. Fonte: Adaptado de (SITTON *et al.*, 2017).

Onde:

- a) x_1, x_2, \dots, x_5 são os sinais de entrada da rede neural advindas do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica;
- b) w_1, w_2, \dots, w_5 são os pesos sinápticos que servem para ponderar cada uma das variáveis de entrada da rede, permitindo quantificar a sua relevância;
- c) Σ é o combinador linear que tem como função agregar todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos a fim de produzir um valor de potência de ativação;
- d) b é chamado de limiar de ativação ou bias e tem a função de especificar para o resultado produzido pelo combinador linear para que possa gerar um valor de disparo em direção à saída do neurônio;
- e) n é o potencial de ativação resultante da diferença do valor produzido entre o combinador linear e o limiar de ativação;
- f) f é a função de ativação ou de transferência que tem como objetivo limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional;
- g) a é o sinal de saída e consiste do valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada (SILVA *et al.*, 2010).

A Equação 9 representa bem o esquema ilustrado na Figura 6 onde a resposta a pode ser calculada pela equação (SITTON *et al.*, 2017).

$$a = f \left(\sum_{j=1}^5 w_{i,j} x_j + b \right) \quad (9)$$

O processo de aprendizagem de uma rede neural pode ser então resumido da seguinte forma: sinais são apresentados às entradas da rede, onde cada sinal é multiplicado por um peso que indica o seu grau de importância na resposta obtida na saída da rede; É feito então a soma ponderada dos sinais, que por sua vez produz um nível de atividade, e se tal nível de atividade exceder certo limite, chamado de *threshold* a unidade então produzirá uma determinada resposta de saída (MARTINS *et al.*, 2008).

Os pesos são então os responsáveis pela memorização dos padrões e tem a função de ponderar o sinal de cada neurônio de entrada permitindo então quantificar a sua relevância com relação ao sinal de saída (resposta do modelo), pois são ajustados durante o processo de treinamento da rede que irá capturar as informações contidas nos dados.

Durante o processo de treinamento das redes, a cada iteração feita os pesos sinápticos e as bias são ajustados a fim de se minimizar os erros produzidos pelo modelo e representar apropriadamente a relação entre as variáveis de entrada e saída (ZEINALI *et al.*, 2016). A maioria dos modelos neurais possui alguma regra de treinamento, onde os pesos das conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, aprendem por meio de exemplos (MARTINS *et al.*, 2008).

O ajuste dos pesos das conexões é feito então pela Equação 10, onde esses ajustes são proporcionais ao negativo da derivada parcial do erro em relação ao próprio peso sináptico (ZHONG *et al.*, 2013).

$$\Delta W_{ij} = -\eta \frac{\partial E(w_{ij})}{\partial w_{ij}} \quad (10)$$

Onde E é a função erro definida para o peso do neurônio ij, ΔW_{ij} é o ajuste para o peso do neurônio ij e η é a taxa de aprendizagem. Essa última tem grande influência no processo de treinamento da rede neural e seu valor varia entre 0 e 1, a definição do seu valor é importante

pois uma taxa muito baixa pode provocar na rede um aprendizado muito lento, enquanto que um valor muito alto provoca oscilações durante o treinamento impedindo que a rede tenha uma convergência no processo de aprendizagem.

Para que as redes ajustem os pesos das suas conexões e as bias a fim de adequar as respostas da rede às respostas reais contidos nos bancos de dados, são utilizados algoritmos de treinamento. Entre os mais conhecidos são os baseados em retropropagação do erro, ou *backpropagation* como são mais conhecidos. A Figura 8 está ilustrando os passos de um treinamento do tipo *backpropagation*.

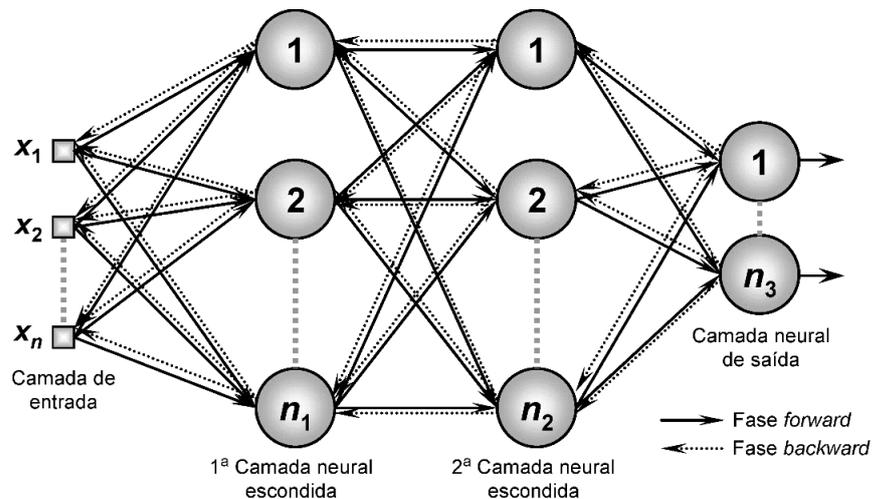


Figura 8: Representação de uma RNA utilizando como algoritmo de treinamento um do tipo *backpropagation*.
Fonte: SILVA *et al.*, (2010).

Nesta técnica de treinamento, o sinal de entrada se propaga pelos neurônios, de camada para camada, até atingir a camada de saída com os resultados produzidos pela rede (fase *forward*). Posteriormente é realizado o passo para trás (fase *backward*), onde o sinal é então propagado na direção inversa das conexões e os pesos são então ajustados para que a resposta da rede seja o mais próximo das respostas desejadas. Nesse momento os pesos sinápticos são ajustados de acordo com a regra de correção de erros que é expresso pela Equação 11 que corresponde à resposta encontrada pela rede subtraída da resposta desejada. (HAYKIN, 2001).

$$E_j(n) = d_j(n) - y_j(n) \quad (11)$$

Onde: $d_j(n)$ corresponde à resposta desejada e $y_j(n)$ é a resposta produzida pela rede.

Observa-se na literatura que as redes *feedforward* junto com o algoritmo de treinamento *backpropagation* tem como pontos principais a vantagem de ser supervisionado e iterativo. Entre os principais algoritmos de treinamento *Backpropagation* podemos destacar o *Levenberg-Marquardt*, o gradiente decrescente, o gradiente conjugado e o gradiente decrescente com momento e taxa adaptativa.

O algoritmo de treinamento *backpropagation Levenberg-Marquardt* é um método bastante eficiente quando utilizado em redes que não possuam um número muito grande de conexões (da ordem de centena) a serem ajustadas (HAGAN, 1994). Essa limitação está ligada ao fato de que tais algoritmos precisam armazenar uma matriz quadrada cuja sua dimensão é da ordem do número de conexões. A principal característica desse algoritmo é a utilização dos ajustes dos pesos por um método de otimização quase-Newton (MENEZES, 2010).

As funções de ativação ou de transferência como são conhecidas podem ser do tipo linear, degrau, rampa, logarítmica sigmoidal representado pela Figura 9 (a), (b), (c) e (d) respectivamente ou a tangente hiperbólica, dentre outras mais. As funções de ativação são consideradas funções restritivas, que restringem os intervalos dos sinais de saída dos neurônios a valores finitos em intervalos fechados $[0,1]$ ou alternados $[-1,1]$ (HAYKIN, 2001).

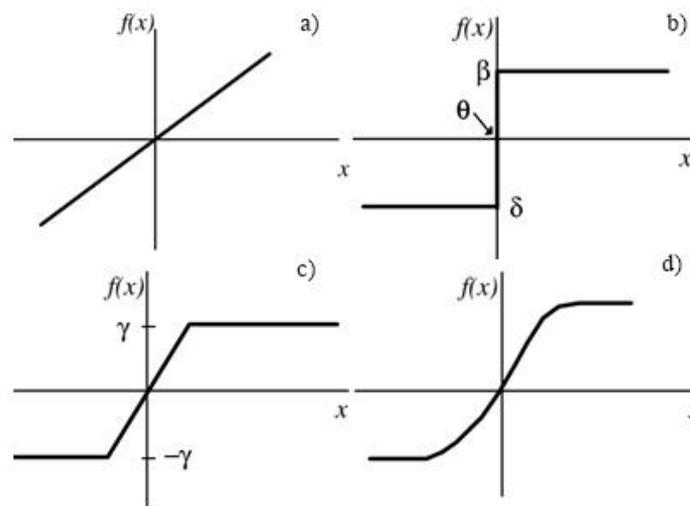


Figura 9: Representação das funções de ativação mais comumente utilizadas.

Algumas vantagens podem ser atribuídas a esses modelos, dentre as quais se pode citar a facilidade de programação em *Softwares* e resultados satisfatórios apresentados em trabalhos encontrados na literatura. (NASCIMENTO, 2013).

Como pontos negativos à utilização das RNA's podem ser citados a necessidade de conhecimento sobre programação de *software* que contenham o pacote de redes neurais artificiais e a necessidade de se ter um banco de dados com valores de variáveis reais em uma quantidade suficiente para se treinar e validar a rede criada.

Alguns autores já utilizaram da técnica de redes neurais artificiais para descrever sistemas que envolvam secagem de matérias como frutas, leite e outros diferentes tipos de alimentos em diferentes tipos de secadores, predizendo parâmetros fluidodinâmicos do secador, bem como na predição de propriedades físicas do material durante a secagem.

A Tabela 2 apresenta alguns trabalhos encontrados na literatura com a aplicação de modelo de RNA em processos de secagem de diversos materiais. Ainda nessa tabela estão descritos também as variáveis preditas pelos modelos, bem como os índices de desempenhos utilizados para avalia-los.

Tabela 2: Trabalhos encontrados na literatura com a aplicação de modelos de RNA aplicados em processos de secagem.

Autores	Material utilizado na secagem	Variáveis preditas pelo modelo de RNA	Índices de desempenho dos modelos
HUSSAIN <i>et al.</i>, (2002)	Frutas e legumes em geral	Porosidade do material	MSE = $2,68 \times 10^{-4}$
KERDPIBOON <i>et al.</i>, (2006)	Cenoura	Encolhimento e taxa de reidratação	$R^2 = 0,969$
AGHBASHLO <i>et al.</i>, (2011)	Cenoura	Taxa de umidade	$R^2 = 0,9928$, MSE = 0,00064 e MAE = 0,02129
FATH <i>et al.</i>, (2011)	Kiwi	Encolhimento	$R^2 = 0,95$, MSE = 1,6762, MAE = 1,0146
MIHAJLOVIC <i>et al.</i>, (2011)	Maltodextrina e Lactose	Temperatura do ar na saída do secador	$R^2 = 0,93$ e RMSE = 0,15
NASCIMENTO <i>et al.</i>, (2013)	Diferentes tipos de leite	Queda de pressão no leite	Erro (%) = 1,26 à 2,1
YOUSEFI <i>et al.</i>, (2014)	Framboesa	Porosidade, densidade, tempo de secagem e atividade de água	$R^2 \leq 0,96$
SILVA <i>et al.</i>, (2015)	Sementes de aroeira	Umidade do material	$R^2 0,99$ e RMSE = 0,007

Neste trabalho, uma das propostas de modelo é utilizar as redes neurais artificiais para a predição das mudanças dos regimes de fluxo no leite de jorro, relacionando a essas mudanças a evolução das propriedades físicas dos cubos de goiaba durante a secagem. Como diferencial

apresentado nessa proposta de modelagem, tem-se a associação das mudanças nas propriedades físicas da goiaba ao longo da secagem às mudanças nos regimes de fluxo dentro do leito de jorro. Dessa forma então se sugeriu a acoplamento de dois modelos de redes neurais, um para a predição das propriedades físicas e outro para a predição dos regimes de fluxo.

2.4.1. Modelos híbridos

Os modelos que combinam modelos mecanicistas e empíricos são conhecidos como modelos de caixa cinza ou híbridos (PSICHOGIOS *et al.*, 1992). Nesse caso as equações advindas dos balanços de massa, energia e momento que descrevem determinado processo representam os modelos mecanicistas, enquanto que os modelos empíricos são representados, por exemplo, por modelos de Redes Neurais Artificiais, que são conhecidos também como modelos de caixa preta. A junção dessas duas estratégias de modelagem gera então um modelo de caixa cinza ou híbrido neural, como também são chamados.

As RNA's, nesse contexto, são acopladas aos modelos a fim de se prever parâmetros como os coeficientes de transferência de calor e massa, taxas de cinéticas, dentre outros parâmetros (NASCIMENTO, 2013).

CUBILLOS *et al.* (1996) citam que para a formulação de um modelo híbrido/neural devem-se seguir quatro etapas, são elas:

- a) Desenvolvimento dos balanços de massa, energia e momento, juntamente com as relações termodinâmicas e de transporte, permitindo a ligação entre as variáveis de entrada e de saídas do modelo;
- b) Seleções dos parâmetros do modelo que serão estimados pela Rede Neural e determinação de como esses parâmetros dependem das variáveis de entrada;
- c) Determinação da arquitetura da rede e treinamento da rede utilizando dados experimentais;
- d) Avaliação da capacidade de predição do modelo final, usando se possível, dados que não estão incluídos no banco utilizado para treinamento.

A modelagem baseada em modelos de caixa-cinza, os quais estão baseados na combinação de modelos fenomenológicos ou mecanicistas e modelos empíricos como são as RNA's surge como uma boa alternativa para a modelagem de fenômenos complexos como são

os encontrados em processos de secagem, tendo em vista das vantagens que são atribuídos a parte empírica dos modelos. Estes apresentam simplicidade teórica, facilidade em sua programação em *Softwares* e, além disso, bons resultados relatados na literatura (NASCIMENTO, 2013).

Na literatura encontram-se alguns trabalhos que envolvem a aplicação de modelos baseados em redes neurais artificiais acoplados a modelos fenomenológicos para descrever diversos processos de secagem em diferentes equipamentos.

A Tabela 3 mostra alguns trabalhos encontrados na literatura com a aplicação de modelos híbridos neurais em processos de secagem de diversos tipos de materiais, descrevendo as variáveis preditas pelos modelos de RNA, desenvolvidos para a previsão de parâmetros do modelo fenomenológico, e as variáveis obtidas pela resolução dos modelos físicos.

Tabela 3: Trabalhos encontrados na literatura com a aplicação de modelos híbridos neurais à processos de secagem.

Autores	Material utilizado na secagem	Variáveis preditas pelo modelo de RNA	Variáveis obtidas pelo modelo fenomenológico
CUBILLOS <i>et al.</i>, (2011)	Farinha de peixe	Taxa de secagem e coeficiente de transferência de calor	Umidade do sólido e Temperatura do gás ambos na saída do secador
FREIRE <i>et al.</i>, (2012)	Pastas com partículas inertes	Taxa de secagem	Umidade do produto na saída do secador e a temperatura do gás na saída
NASCIMENTO; FREIRE; FREIRE, (2013)	Diferentes tipos de leite	Taxa de secagem	Umidade do produto na saída do secador e a temperatura do gás na saída
SILVA COSTA <i>et al.</i>, (2016)	Leites e suspensões	Taxa de secagem	Umidade do gás e do produto na saída do secador e a temperatura do gás

Como se pode observar os modelos híbridos neurais foram aplicados a processos de secagem, incluindo secadores rotativos, secadores vibratórios com leito fluidizado e secadores de leito de jorro, utilizados para a secagem de diversos tipos de matérias. Cada um dos modelos apresentou características diferentes, porém as redes neurais estiveram presentes em todas as propostas de modelagem predizendo parâmetros importantes do processo.

Dos trabalhos citados, verifica-se que nenhum apresentou um modelo fenomenológico para a previsão da variação de propriedades físicas em secagem em leito de jorro para partículas sólidas deformáveis, dessa forma encontra-se ainda em aberto o desenvolvimento de um modelo fenomenológico que descreva tal processo.

A proposta nesse trabalho é criar um modelo híbrido utilizando as redes neurais como estimador de parâmetros para um conjunto de equações diferenciais advindas de balanços de massa e energia feitos em um secador de leito de jorro em secagem de partículas deformáveis e que serão resolvidas numericamente por um método de integração numérica posteriormente.

2.5. Otimização por enxame de partículas

A técnica de otimização por enxame de partículas ou *Particle Swarm Optimization* (PSO) foi descoberta em meados dos anos 90 por Kennedy e Eberhart. Tais cientistas ao observarem o comportamento de enxame de pássaros e formigas, constataram que membros do enxame geralmente aprenderam com as experiências vividas tanto por eles próprios como por outros membros na busca de recursos (KENNEDY *et al.*, 1995)

O comportamento apresentado por esses enxames (populações) levou os pesquisadores a modelar a inteligência desses, para tratar por exemplo de problemas de otimização de engenharia (DAS *et al.*, 2013).

Nesta técnica, cada indivíduo presente no enxame é tratado então como uma partícula dentro do enxame que representa um ponto no espaço vetorial das soluções possíveis a esse problema a ser otimizado. As soluções possíveis então se movimentam em busca de outras melhores soluções simulando a coreografia feita por pássaros ao saírem em busca de alimentos, do qual essa busca é feita baseada na melhor experiência vivida por cada indivíduo do enxame, conhecido por Melhor pessoal ou *Personal Best* e pela melhor experiência conhecida pelo enxame até aquele momento, conhecido como Melhor Global ou *Global Best* (DAS *et al.*, 2013).

Cada partícula dentro do espaço vetorial de soluções possíveis é gerada aleatoriamente e o tamanho de cada partícula é do tamanho do número de componentes que se deseja otimizar. A Figura 10 mostra o esquema de um enxame contendo 10 partículas, onde cada partícula possui dimensão n que se refere ao número de componentes a serem otimizados.

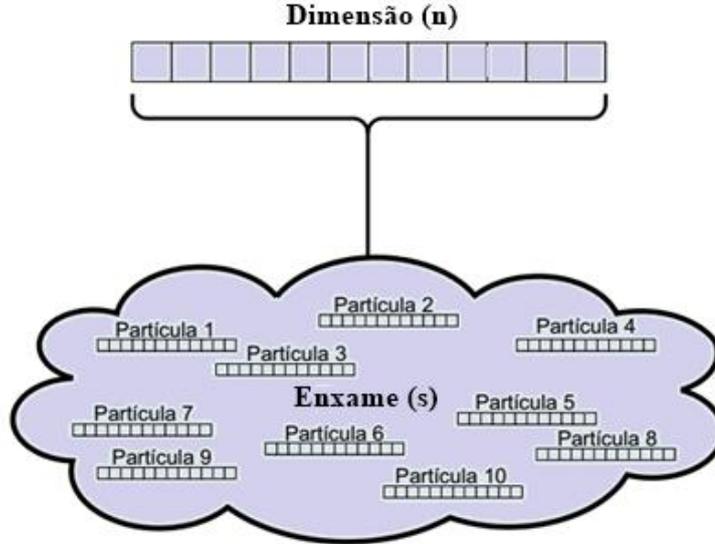


Figura 10: Esquema de um enxame de partículas com dimensão n e cada partícula com sua determinada dimensão. Fonte: Adaptado de (Carvalho, 2007).

Sendo s o tamanho do enxame de partículas, t o instante atual e n a dimensão do problema ou número de parâmetros a serem otimizados. Dentro do espaço vetorial de soluções possíveis cada partícula possui então uma posição $x_i(t)$ e uma velocidade $v_i(t)$ que juntas governam a direção e a magnitude com que essas partículas se deslocam no espaço vetorial de soluções possíveis. Vale ressaltar que cada partícula possui um termo chamado de lembrança da melhor posição visitada pela partícula $y_i(t)$, assim como existe também a lembrança da melhor posição visitada pelo conjunto de partículas $\hat{y}(t)$. Tanto a velocidade como também as posições de cada partícula são atualizadas pelas Equações 12 e 13. Em cada uma das equações o sub-índice j representa o índice do componente atual do vetor de dimensão n e i refere-se a partícula, onde $1 \leq i \leq s$ e $1 \leq j \leq n$.

$$v_{ij}(t + 1) = w \cdot v_{ij}(t) + c_1 \cdot r_1 (y_{ij}(t) - x_{ij}(t)) + c_2 \cdot r_2 (\hat{y}_j(t) - x_{ij}(t)) \quad (12)$$

$$x_{ij}(t + 1) = x_{ij}(t) + v_{ij}(t + 1) \quad (13)$$

A Equação 12 atualiza a velocidade de cada partícula, levando em consideração a melhor posição visitada individualmente pela partícula $y_i(t)$ e a melhor posição visitada pelo enxame

$\hat{y}(t)$. Com o cálculo da nova velocidade da partícula é então feito a atualização da posição desta pela Equação 13.

Caso as variáveis a serem otimizadas estejam no domínio dos números inteiros, a velocidade então permanece real, porém a posição é arredondada pela função arredamento descrita pela Equação 14.

$$x_{ij}(t + 1) = x_{ij}(t) + arredonda(v_{ij}(t + 1)) \quad (14)$$

O termo w presente na Equação 12 é chamado de peso inercial, e tem a função de modificar a natureza da busca do algoritmo. Através dessa função esse parâmetro consegue acelerar a velocidade de convergência ou evitar uma convergência prematura. Se o valor do peso inercial atual for maior que o peso inercial anterior, isso significa dizer que a natureza da busca foi explorativa, procurando soluções em espaços maiores. Então se o peso inercial atual for menor que o valor assumido anteriormente a natureza de busca será agora explorativa, procurando soluções em intervalos menores do domínio do problema. Geralmente a esse parâmetro é atribuído um regime linear de decaimento do valor de 0,9 à 0,4. (LI *et al.*, 2013)

O c_1 e o c_2 representam os coeficientes pessoal e global de aceleração, respectivamente, e possuem valores fixos e iguais e a esses coeficientes são atribuídos a função de controlar a movimentação de uma partícula a cada interação. Os termos r_1 e r_2 são variáveis que assumem valores aleatórios a cada interação e com isso tem a função de tornar aleatórias as influências dos termos individual e global na equação de velocidade.

A cada interação feita pelo algoritmo são selecionados um melhor pessoal que se refere ao melhor resultado de cada partícula e o melhor global, esse diz respeito à melhor solução dentro do universo de todas as partículas e todas as iterações feitas até o momento.

Alguns trabalhos encontrados na literatura utilizaram do algoritmo *PSO* para a otimização da arquitetura das redes neurais. DAS *et al.* (2013) aplicaram o algoritmo para aperfeiçoar o número de camadas escondidas, o número de neurônios em cada camada e o tipo de função de transferência das camadas escondidas de uma RNA para a equalização de canais digitais, os autores utilizaram 25 partículas em seu exame, peso inercial igual a 0,8 e coeficientes pessoal e global iguais a 2. Os autores ressaltam também que para a otimização desse tipo de problema cerca de 20 à 50 partículas dentro do exame é o suficiente.

BOUDI *et al.* (2012), aperfeiçoaram parâmetros de uma RNA utilizada para a predição do comportamento de reservatórios de gás condensado retrogrado. Os parâmetros otimizados foram o número de neurônios na camada escondida e o número de iterações da rede através da aplicação do algoritmo de enxame de partículas. Os autores estudaram a variação do número de partículas e dos coeficientes globais e pessoais encontrando os melhores resultados da otimização quando utilizado 21 partículas dentro do enxame e valores de coeficientes global e pessoal iguais a 2.

KALANI *et al.* (2017), otimizaram parâmetros da arquitetura de modelos baseados em redes neurais artificiais e modelos baseados em lógica *fuzzy*, aplicados à um processo de aquecimento de um nanofluido através da utilização de placas fotovoltaicas utilizando a otimização por enxame de partículas.

Nesse trabalho um algoritmo baseado em enxame de partículas foi desenvolvido para a otimização de parâmetros da arquitetura das RNA's. Foram selecionados para serem otimizados o número de neurônios na camada escondida, a função de transferência da camada escondida e a taxa de aprendizagem da rede e as performances de cada partícula do enxame foram avaliadas pela soma dos quadrados dos erros (MSE) obtido pela simulação da rede neural.

3. MATERIAIS E MÉTODOS

Nessa etapa está descrito de forma breve a metodologia experimental adotada por ALMEIDA (2004) para o processo adotado como estudo de caso: secagem dos cubos de goiaba em leito de jorro. Os experimentos foram realizados no Laboratório de Processos Químicos da Universidade Federal de Campina Grande (UFCG). Os dados obtidos no trabalho foram utilizados para a composição do banco de dados no trabalho atual de forma a favorecer a criação dos modelos.

Neste tópico também será descrito a metodologia adotada para a obtenção dos diferentes modelos com o intuito de obter uma boa descrição do processo de secagem dos cubos de goiaba em leito de jorro.

3.1. Matéria prima utilizada

Para a realização dos experimentos foram utilizadas goiabas vermelhas (*Psidium guajava* L.) da variedade Paluma. Tais frutos foram obtidos no centro de abastecimento central de Campina Grande-PB (EMPASA) em condições ótimas para o consumo *in natura* (em média de 3 a 5 dias pós-colheita). A metodologia para a secagem em leito fixo e de jorro, bem como a caracterização dos cubos de goiaba estão descritos em ALMEIDA (2004).

3.2. Preparo das amostras e pré-secagem em leito fixo

Para a realização dos ensaios de secagem, os frutos foram primeiramente separados das sementes utilizando água corrente e em seguida foram descascados e cortados em um cortador de batatas industrial apresentando espessuras entre 0,2 e 1,5 cm. Os pedaços de goiaba obtidos são classificados segundo GELDAR (1973), como pertencentes a categorial D, na qual durante a secagem essas apresentam uma fluidização instável, na maioria dos casos, entretanto a umidade inicial dos pedaços de goiaba (cerca de 4,75 kg de água/ kg de sólido seco) não favorece o escoamento no leito, sendo assim necessário a realização de uma pré-secagem.

A pré-secagem dessas amostras foi realizada em um leito fixo onde em tempos determinados eram verificados a umidade das partículas. Atingidos os níveis de umidade desejados e pré-definidas pelo planejamento experimental, os cubos de goiabas seguiam então para a secagem em leito de jorro.

Com a utilização de uma curva da cinética de secagem dos cubos de goiaba em leito fixo, foram definidos os limites inferiores e superiores da umidade inicial em base seca dos experimentos que seriam realizados posteriormente no leito de jorro sendo 0,6 e 1,5 respectivamente.

3.3. Ensaio de secagem no leito de jorro

Todos os cálculos e análises durante a secagem em leito de jorro foram realizados considerando a partícula como uma esfera tendo em vista que conforme as modificações sofridas pelos cubos de goiaba esses apresentaram a tendência de achatarem os seus vértices aproximando a geometria do cubo à de uma esfera.

Após a pré-secagem em leito fixo os pedaços de goiaba seguiam então para o secador do tipo leito jorro, tal secador possui 1,0 m de altura, 0,108 m de diâmetro interno, extremidades cônicas com cerca de 0,09 m de altura e ângulo de 60° e diâmetro de orifício de entrada de ar igual a 0,028 m. O objetivo dos experimentos no leito de jorro foi observar a modificação das propriedades físicas das partículas de goiaba ao longo da cinética de secagem, bem como também verificar e classificar de modo visual os regimes fluidodinâmicos durante a secagem até o tempo final do experimento.

Os ensaios de secagem em leito de jorro tinham duração máxima de cerca de 60 minutos, e em intervalos pré-definidos de tempo eram feitas amostragens de pedaços de goiaba no leito de jorro (cerca de 2 gramas) para caracterização física dessas amostras (medidas de umidade, densidade e diâmetro médio das partículas), tomando a precaução de a retirada do material não causar interferências no comportamento fluidodinâmico do mesmo. Vale ressaltar que todos os experimentos realizados no leito de jorro tiveram a temperatura do ar na entrada do secador fixada em 60°C.

A fim de limitar o número de experimentos foi realizado um planejamento experimental 2^K para avaliar a evolução das propriedades físicas, bem como classificar o regime fluidodinâmico dentro da coluna. Foram selecionadas 3 variáveis ($K=3$): altura inicial do leito de jorro (H_i) (m), umidade inicial em base seca ($U_{i(b.s)}$) e a velocidade do ar de entrada (u_{ar}) ($m.s^{-1}$). As faixas das variáveis foram definidas através da realização preliminar de experimentos a fim de observar o comportamento fluidodinâmico do leito durante a secagem dos pedaços de goiaba. A Tabela 4 apresenta a matriz experimental confeccionada com os valores codificados

Tabela 4: Delineamento experimental proposto.

Nº do experimento	Variáveis		
	H_i	$U_{i(b.s)}$	u_{ar}
1	-1	-1	-1
2	+1	-1	-1
3	-1	+1	-1
4	+1	+1	-1
5	-1	-1	+1
6	+1	-1	+1
7	-1	+1	+1
8	+1	+1	+1
9(C)	0	0	0
10(C)	0	0	0

A Tabela 5 mostra as variáveis estudadas por ALMEIDA, (2004) na secagem em leito de jorro na forma descodificada.

Tabela 5: Variáveis do delineamento experimental na forma decodificada.

Variáveis	Valores decodificados		
	-1	0	1
H_i (m)	0,09	0,105	0,12
$U_{i(b.s)}$	0,6	1,05	1,5
u_{ar} (m.s ⁻¹)	2,8	3,2	3,5

3.4. Caracterização física das partículas

Para os ensaios realizados no leito de jorro foram verificadas as seguintes variáveis do sistema: a densidade (ρ_{ap}) (kg.m⁻³), o diâmetro da partícula (d_p) (m) e a umidade em base seca ($U_{[b.s]}$), através da amostragem de pedaços de goiaba no leito de jorro, onde ao longo de 60 min do tempo total de secagem eram feitas cerca de 6 a 8 amostragens. Com a obtenção dessas variáveis foi possível analisar o comportamento dos parâmetros fluidodinâmicos, como o parâmetro de *Littman* e o número de Arquimedes que nos dão uma ideia do tipo de terminação do jorro e da estabilidade do regime, respectivamente. Também durante a realização dos experimentos foi possível classificar o regime fluidodinâmico no leito de modo visual.

3.4.1. Umidade em base seca

Para a determinação da umidade em base seca, conforme ALMEIDA (2004), eram retiradas do leito cerca de 2 g de pedaços de goiaba e logo após iam para a estufa à 70°C onde permaneciam por cerca de 24 horas, tempo necessário para as amostras atingirem peso constante. Logo após esse tempo, as amostras eram retiradas da estufa e colocadas em um dessecador até atingirem temperatura ambiente e então eram pesadas novamente. A partir da Equação 15, era determinada a umidade em base seca do produto.

$$U_{(b.s)} = \frac{m_{a.p}}{m_f} \quad (15)$$

Onde, $U_{(b.s)}$ é a umidade em base seca, $m_{a.p}$ é a massa de água perdida e m_f massa final da amostra.

3.4.2. Densidade aparente

Em uma proveta de 100 mL foi colocado um determinado volume conhecido de álcool etílico e então foi adicionado cerca de 30 pedaços de goiaba com massa conhecida pesada anteriormente em uma balança analítica e observava-se o volume correspondente ocupado pela massa de goiaba (volume aparente) que é igual ao volume deslocado de álcool etílico. A partir da relação entre a massa de goiaba e o volume aparente ocupado pelos pedaços de goiaba obtinha-se a densidade aparente da goiaba pela Equação 16.

$$\rho_{ap} = \frac{m}{V} \quad (16)$$

Onde, ρ_{ap} é a densidade, m é a massa de goiaba colocado na proveta em kg e V é o volume aparente em m^3 . Os testes foram feitos em triplicata.

As medidas foram feitas no tempo inicial do experimento e no tempo final, com isso ajustou-se um polinômio de primeira ordem (Equação 17) para a determinação da densidade dos pedaços de goiaba em função da umidade em base seca.

$$\rho_{ap} = 876,619 + 155,543 \cdot U_{(b.s)} \quad (17)$$

3.4.3. Diâmetro dos pedaços de goiaba

Para a determinação do diâmetro dos pedaços de goiaba foi utilizado a metodologia do encolhimento volumétrico da partícula. Para isso considerou-se uma esfera com volume semelhante ao das partículas de goiaba e determinou-se o diâmetro inicial e final. A partir desses resultados foi ajustado um polinômio de segunda ordem (Equação 18) para determinação do diâmetro teórico da partícula em função da umidade em base seca.

$$d_p = 0,5889 + 0,454 \cdot U_{(b.s)} - 0,18312 \cdot U_{(b.s)}^2 \quad (18)$$

3.4.4. Classificação dos regimes fluidodinâmicos

Para a classificação dos regimes de fluxo que acontecem no leito de jorro, foram feitas observações visuais analisando as características da circulação das partículas dentro do leito para classificar os regimes como sendo: leito fixo, fluidização, em regime de jorro ou regime de *slugging*. Tais observações foram feitas em função do tempo de secagem, afim de obter mapas de regimes de fluxo no leito nas diferentes condições experimentais testadas.

3.5. Construção dos modelos baseados em Redes Neurais

Para a construção dos modelos baseado em redes neurais artificiais, primeiramente foi realizado uma análise completa do processo utilizado como estudo de caso. Posteriormente, foram definidas as variáveis que seriam utilizadas para criação dos modelos e que comporiam o banco de dados.

A etapa seguinte foi a seleção de uma arquitetura de rede que se adequasse melhor aos dados a que se pretendia modelar, de forma que os resultados produzidos pela rede fossem os mais próximos dos dados experimentais ou reais. É nessa etapa que foram definidos o número de camadas escondidas mais adequado, bem como o número de neurônios ideias em cada camada, e a definição das funções de ativação e algoritmos de treinamento.

Em seguida, foram realizadas as etapas de treinamento da rede e posteriormente foram realizados os testes de desempenho, a fim de avaliar a eficiência de predição do modelo desenvolvido. Para essa etapa, utilizou-se parâmetros estatísticos para medir o desempenho do modelo desenvolvido: o erro médio quadrado (MSE- *Mean Squared Error*), a raiz do erro médio quadrado (RMSE- *Root Mean Squared Error*) e o coeficiente de determinação (R^2). As etapas que envolvem a construção do modelo baseado em RNA estão descritas no fluxograma da Figura 11.

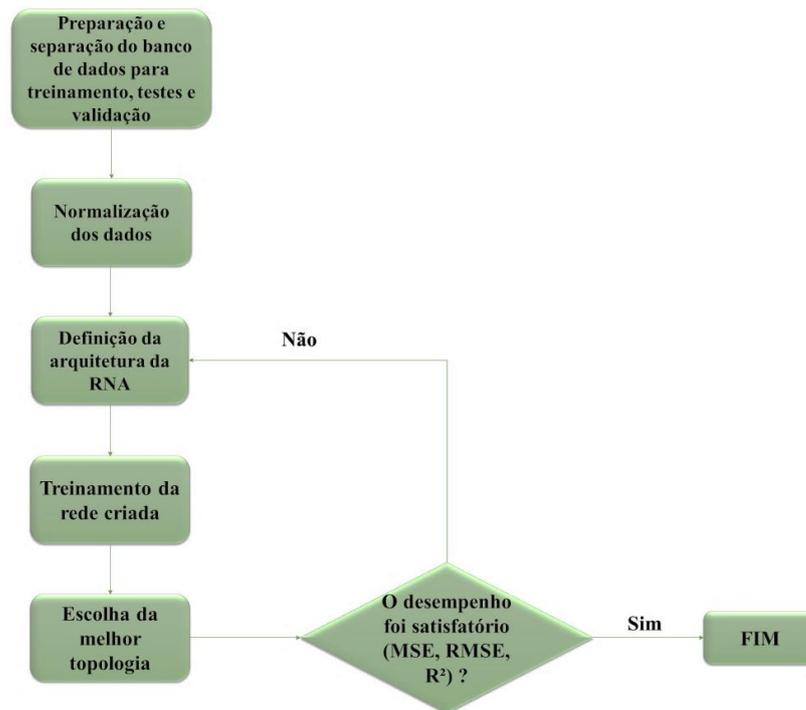


Figura 11: Fluxograma da construção do modelo baseado em RNA.

A criação dos modelos foi executada no *software* MATLAB®, versão 4.0.

3.5.1. Processamento e separação dos bancos de dados

Para que fosse possível prever o regime fluidodinâmico no leito, primeiramente foi necessário o desenvolvimento de um modelo para predição da variação das propriedades físicas dos pedaços de goiaba durante a secagem em leito de jorro. Esse modelo teve como variáveis de entrada os parâmetros estudados no planejamento experimental: altura inicial do leito (H_i), a umidade inicial em base seca ($U_{i(b,s)}$), a velocidade do ar de secagem (u_{ar}) e o tempo de secagem (min). Foram definidas como variáveis de saída para esse modelo a densidade dos pedaços de goiaba (ρ), o diâmetro das partículas (d_p) e a umidade ao longo da secagem ($U_{(b,s)}$).

Em seguida foi desenvolvido um segundo modelo que utilizou o parâmetro de *Littman* (A) (Equação 2), o número de Arquimedes (Ar) (Equação 1) e a velocidade do ar como variáveis de entrada. Como saída para esse modelo, foi definido o regime fluidodinâmico. A Figura 12 mostra o diagrama esquemático do fluxo de dados para os dois modelos neurais, modelo MN-1 desenvolvido para a predição das propriedades físicas dos pedaços de goiaba e o modelo MN-2 confeccionado para predição do regime fluidodinâmico do leito.

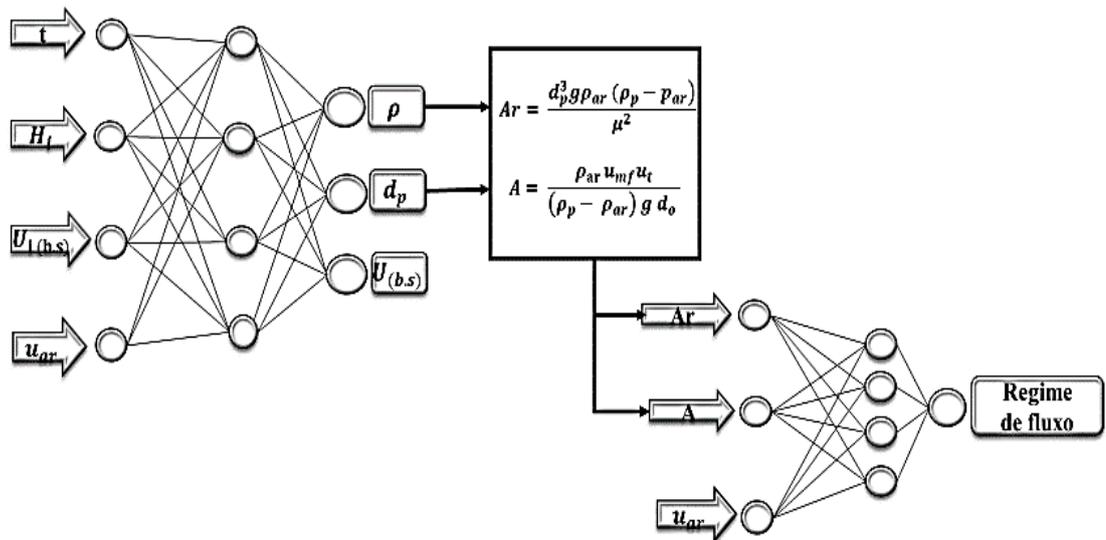


Figura 12: Diagrama esquemático do fluxo de dados dos modelos de redes neurais artificiais (MN-1 e MN-2)

Como os dados de saída do segundo modelo foram dados qualitativos foram codificados utilizando codificação *Dummy*, também conhecida como 1-de-C, dessa forma a variável regime fluidodinâmico são transformadas em variáveis artificiais assumindo conjunto de valores de 0 e 1.

Durante a elaboração do banco de dados atual foram adicionados dados experimentais em tempos distintos dentro das faixas estudadas. Para isso foi utilizado o MATLAB® com um rotina pré-programada para a realização da interpolação numérica, ao final desse processo o banco de dados possuía um total de 180 amostras. Esse aumento do número de amostras no banco é necessário para se garantir que a rede não perca sua capacidade de representação e análise do processo. Alguns autores retratam na literatura a utilização de interpolação, como pode ser observado no trabalho de TURAN *et al.* (2011) e a técnica que usa do desvio padrão experimental que sugere que os novos dados estejam da faixa desse erro como pode ser observado no trabalho de OLIVEIRA *et al.* (2015).

Após a finalização da confecção do banco de dados, esse foi randomizado para que evitasse que a rede ficasse concentrada em determinada faixa experimental do processo estudado e acabasse apenas memorizando padrões do banco de dados. Posteriormente, os dados foram separados como sendo 70% para o treinamento, 15% para validação do modelo durante o treinamento, prevenindo a rede de sofrer o *overtraining*. Os demais 15% dos dados que compõe o banco de testes, são dados apresentados à rede após a etapa de treinamento, sendo

esses dados nunca “vistos” pela rede. Essa subdivisão se torna necessária para a avaliação do modelo neural com relação a sua aprendizagem, pois um dos grandes problemas encontrado nas RNA’s é a realização de treinamentos excessivos causando a perda da capacidade de generalização da rede, conhecida como *overtraining* (KHASHEI *et al.*, 2010).

Após a divisão dos bancos de dados e randomização, foi feita a normalização dos dados para evitar que a rede tenha uma tendência a ter uma maior consideração pelos valores com maiores magnitudes o que caracterizaria uma extrapolação numérica conhecida como *overflow* (NASR *et al.*, 2013)

A etapa de normalização dos valores contidos no banco de dados foi realizada a partir da Equação 19. Tal equação normalizou os dados de entrada e saída do primeiro e do segundo modelo neural para uma gama de valores entre [-1, +1] em função dos valores máximos e mínimos contidos no banco de dados.

$$y = \frac{(y_{max} - y_{min}) * (x - x_{min})}{(x_{max} - x_{min})} + y_{min} \quad (19)$$

Na Equação 19 $y_{max} = 1$; $y_{min} = -1$, x_{max} é o valor máximo que a variável assume, x_{min} é o valor mínimo que a variável assume e x é o valor da variável que se pretende normalizar.

3.5.2. Definição da arquitetura da RNA

Após a etapa de processamento dos dados e separação dos bancos de dados em treinamento, teste e validação, a etapa posterior foi a definição da arquitetura ou configuração da rede. Nessa etapa foi definido então o número de camadas escondidas, o número de neurônios ideais em cada camada escondida, as funções de ativação para cada camada e o algoritmo de treinamento ideal para a rede.

Para a definição do número de neurônios e camadas escondidas, assim como as funções de ativações ainda não existe uma técnica específica para determinação dos melhores parâmetros, deve-se ser testada um de cada vez nas várias combinações possíveis.

Para solucionar o problema de testes excessivos para as dezenas de combinações possíveis dos parâmetros supracitados, foi proposta uma metodologia de otimização dos parâmetros baseados em otimização por enxame de partículas (*Particle Swarm Optimization* - PSO). Desta forma, o algoritmo de otimização utilizado aprimorou nas redes propostas o número de neurônios da camada escondida, a função de transferência da camada intermediária e a taxa de aprendizagem, que é um parâmetro de treinamento da rede.

A taxa de aprendizagem foi variada entre 0 e 1, valores mínimos e máximos que podem ser assumidos, e a função de transferência da camada intermediária variando entre a função linear, tangente hiperbólica e a sigmoide.

A Figura 13 mostra o fluxograma da aplicação do algoritmo PSO aplicado a otimização da arquitetura da rede neural artificial desenvolvida nesse trabalho.

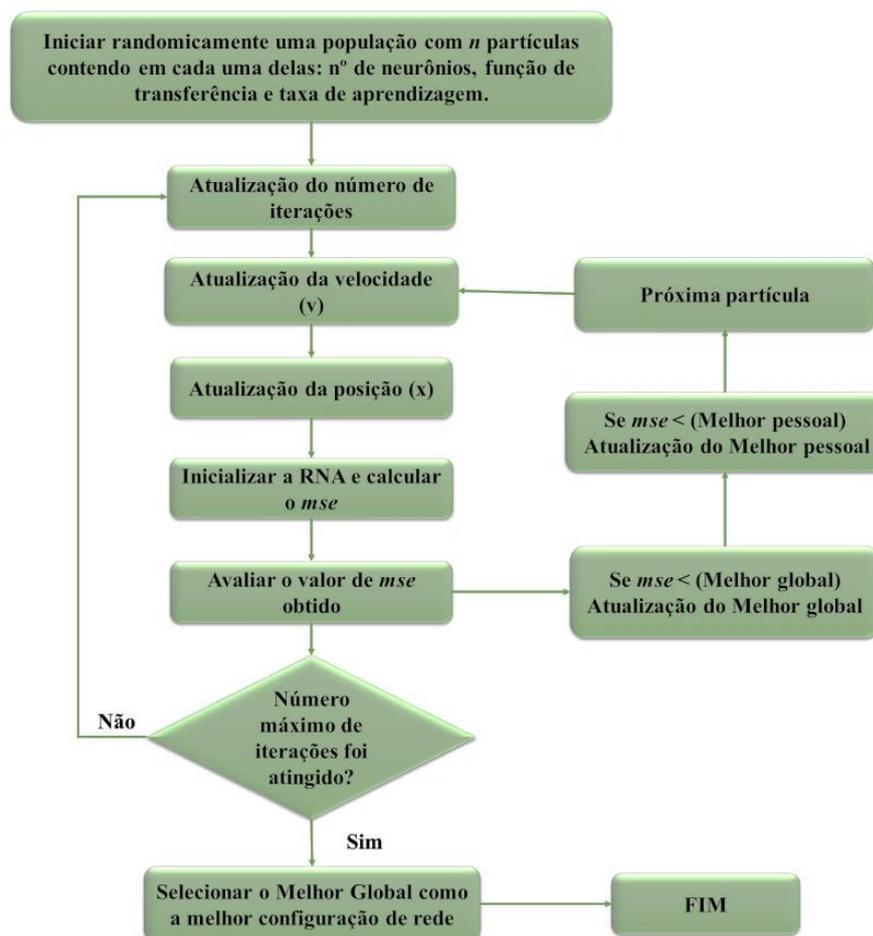


Figura 13: Fluxograma do algoritmo PSO aplicado à otimização da arquitetura da RNA.

3.5.3. Treinamento e análise de desempenho da RNA

Na etapa de treinamento, foram testados diferentes números de neurônios na camada escondida e diferentes funções de ativação na primeira camada escondida (linear, tangente hiperbólica, logarítmica sigmoideal e *softmax*), cujas equações e respectivos códigos do Matlab estão descritos na Tabela 6.

Tabela 6: Funções de ativação utilizadas no processo de treinamento e suas respectivas equações.

Função de ativação	Equação	Gama de valores dos resultados
Linear	$y(n) = n$	[-1, +1]
Tangente hiperbólica	$y(n) = \frac{2}{(1 + e^{-2n})} - 1$	[-1, +1]
Logarítmica Sigmoide	$y(n) = \frac{1}{1 + e^{-an}}$	[-1, +1]
<i>Softmax</i>	$y(n) = \frac{e^n}{\sum e^n}$	[0, +1]

Onde: n é o valor de entrada, a é o parâmetro de inclinação da função logarítmica sigmoideal e $y_{(n)}$ é a saída do neurônio.

Para medir o desempenho dos modelos durante o processo de treinamento evitando que os mesmos sofram um *overtraining*, é comum acompanhar o comportamento do erro durante essa etapa. É importante salientar que o treinamento excessivo da rede acontece quando o erro de treinamento diminui enquanto que o erro de validação aumenta para um determinado número de épocas (KUMAR *et al.*, 2007). No trabalho atual foi utilizado o critério do erro quadrático médio (MSE) dado pela Equação 20.

$$MSE = \frac{\sum_{i=1}^n (y_{i \text{ calc}} - y_{i \text{ exp}})^2}{n} \quad (20)$$

Onde: $y_{i \text{ exp}}$ é o valor real, obtido através dos experimentos, $y_{i \text{ calc}}$ é o valor obtido pelo modelo neural, ou seja, é o valor previsto e n é o número de amostras experimentais.

Nessa etapa foi apresentada a rede os dados experimentais que compõem o banco de teste. Com geração dos valores preditos pela rede, são então calculados alguns parâmetros estatísticos assim como foi feito com a rede na etapa de treinamento com o cálculo do MSE.

Para definir a rede que apresentou melhor resultado nessa etapa foram definidos os seguintes critérios: menor valor de MSE, menor raiz do erro quadrático médio (RMSE), dado pela Equação 21 e maior coeficiente de determinação (R^2) para essa etapa dado pela Equação 22.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{i \text{ calc}} - y_{i \text{ exp}})^2}{n}} \quad (21)$$

$$R^2 = \frac{\sum_{i=1}^n (y_{i \text{ calc}} - \bar{y})^2}{\sum_{i=1}^n (y_{i \text{ exp}} - \bar{y})^2} \quad (22)$$

Onde: \bar{y} é o valor médio das amostras.

3.6. Desenvolvimento do modelo híbrido

Através do balanço de massa e energia aplicado ao leito de jorro em secagem de pedaços de goiaba, foram obtidas equações que descrevem os fenômenos de transferência de calor e massa envolvidos no processo. Para isso foram utilizadas as seguintes hipóteses para desenvolvimento do modelo:

- A secagem dos pedaços de goiaba é considerada como um sistema binário contendo uma fase sólida e uma fase gasosa;

- A altura do anel permanece igual a altura do leito estático, desprezando efeitos de expansão ou encolhimento;
- Os pedaços de goiaba sofrem encolhimento durante a secagem e se comportam como esferas;
- Os pedaços de goiaba são perfeitamente misturados, sendo assim a temperatura das partículas e a umidade não varia com a posição;
- Ao serem feitos os cálculos de coeficiente de transferência de calor entre a partícula e o ar foi assumido que a região anular tem aproximação com leito fixo (h_p) e desconsideradas as contribuições da região do jorro e da fonte ($Re_p < 100$) (Littman, H.; Sliva, 1970);
- O ar de secagem é alimentado com velocidade e temperaturas constantes;

Com base nessas hipóteses, pode-se obter a variação da umidade dos pedaços de goiaba (U_p) em função do tempo através do balanço pelas Equações 23 e 24.

$$G(H_e - H_s) = h_p a_e \Delta T V_{leito} + Q_p \quad (23)$$

$$- m_{ss} \frac{dU_p}{dt} = G(W_e - W_s) \quad (24)$$

Onde: G é a vazão mássica de ar seco ($\text{kg}\cdot\text{s}^{-1}$), H_e e H_s são respectivamente a entalpia do ar úmido na entrada e na saída do secador ($\text{J}\cdot\text{kg}^{-1}$), h_p é o coeficiente global convectivo de transferência de calor entre o leito de partículas e o ar de secagem ($\text{W}\cdot\text{m}^{-2}\text{K}^{-1}$), a_e é a área do sólido em contato com o ar de secagem (m^2), ΔT é dado pela diferença de temperatura do ar de secagem (T_{ar}) e a temperatura da partícula (T_p) respectivamente (K), V_{leito} é o volume do leito de partículas estático (m^3), m_{ss} é a massa de sólido seco (kg), W_s e W_e são respectivamente a umidade absoluta do ar na saída e na entrada do secador ($\text{Kg}_{\text{vapor d'água}}/\text{Kg}_{\text{ar seco}}$), U_p é a umidade dos pedaços de goiaba, t é o tempo e Q_p é o calor perdido entre a parede do secador e o ar ambiente (W).

Pelo balanço de energia podemos determinar as variações de temperaturas dos pedaços de goiaba e do ar na saída do secador a partir das Equações 25 e 26.

$$m_{ss} \lambda \frac{dU_p}{dt} + C_p m_{ss} \frac{dT_p}{dt} = h_p a_e \Delta T V_{leito} \quad (25)$$

$$\Delta T = \frac{(T_{ar,e} - T_p) + (T_{ar,s} - T_p)}{2} \quad (26)$$

Onde: C_p é o calor específico do sólido desprezando o aquecimento da água contida no mesmo ($J \cdot Kg^{-1} \cdot K^{-1}$), $T_{ar,s}$ é a temperatura do ar na saída do secador (K) e $T_{ar,e}$ é a temperatura do ar na entrada do secador (K).

Para determinar a área de contato entre o leito de partícula e o ar de secagem foram utilizados as Equações 27, 28 e 29, considerando a partícula como uma esfera, tendo em vista que conforme as modificações sofridas pelos pedaços de goiaba esses apresentaram a tendência de achatarem os seus vértices aproximando a geometria do cubo à de uma esfera.

$$a_p = \frac{6}{d_p} \quad (27)$$

$$\varepsilon = 1 - \frac{\rho_b}{\rho_{ap}} \quad (28)$$

$$a_e = a_p (1 - \varepsilon) \quad (29)$$

Onde: a_p é a área específica das partículas ($m^2 \cdot m^{-3}$), a_e é a área específica global do leito de partículas ($m^2 \cdot m^{-3}$), d_p é o diâmetro da partícula (m), ρ_b é a densidade do leito de partículas ou densidade *bulk*, obtida entre a razão da massa de partículas e do volume do leito ($kg \cdot m^{-3}$), ρ_{real} é a densidade aparente das partículas, medida experimentalmente pelo método de

deslocamento de volume (kg.m^{-3}) e ε é a porosidade do leito fixo (adimensional), desconsiderando as expansões sofridas pelo leito com a mudança nos regimes.

Para a estimação do coeficiente de troca térmica convectiva entre o leito de partículas e o ar de secagem foi utilizada a correlação proposta por (Littman, H.; Sliva, 1970) (Equação 30) para o cálculo do número de *Nusselt*, que reflete a medida da transferência de calor de um fluido por convecção na superfície do sólido. Tal correlação é utilizada para estimar o coeficiente de troca térmica global entre o as partículas e o ar de secagem ($\overline{h_p}$) e apenas pode ser utilizada para valores de Re_p menores que 100, onde foi confirmado essa condição para o número de *Reynolds* para as diferentes condições experimentais (Littman, H.; Sliva, 1970) (Equação 33).

$$Nu = 0,42 + 0,35 Re_p^{0,8} \quad (30)$$

$$u = u_{ar} \frac{a_{T o}}{a_{T c}} \quad (31)$$

$$h_p = \frac{Nu k_{ar}}{d_p} \quad (32)$$

$$Re_p = \frac{d_p \rho_{ar} u}{\mu_{ar}} \quad (33)$$

Onde: u é a velocidade superficial do ar (m.s^{-1}), u_{ar} é a velocidade operacional do ar (m.s^{-1}), $a_{T o}$ é a área transversal do orifício de entrada do ar (m^2), $a_{T c}$ é a área transversal da coluna (m^2), ρ_{ar} é a densidade do ar (kg.m^{-3}) e k_{ar} é a condutividade térmica do ar ($\text{W.m}^{-1} \cdot \text{K}^{-1}$).

O calor perdido através das paredes do secador e o ar ambiente foi estimado utilizando a Equação 34.

$$Q = \frac{T_{ar,s} - T_{amb}}{\frac{1}{h_w 2\pi r_{int} H_i} + \frac{\ln(r_{ext}/r_{int})}{2\pi k_{par} L} + \frac{1}{h 2\pi r_{ext} L}} \quad (34)$$

Onde: Q é o calor perdido (W), T_{∞} é a temperatura do ar externo (K), r_{int} é o raio interno do secador, r_{ext} é o raio externo do secador, k_{par} é a condutividade térmica da parede do secador ($W.m^{-1}.K^{-1}$), h é o coeficiente convectivo de transferência de calor entre a parede do secador e o ar externo ($W.m^{-2}.K^{-1}$) e L é a altura da parede do secador (m). Vale ressaltar que na Equação 34, o primeiro termo do denominador refere-se a troca de calor entre o leito de partículas e a parede do secador onde considera-se apenas a troca de calor na altura dada pelo leito estático, não levando em conta a expansão do leito e a troca de calor entre as partículas da fonte e a parede.

Para estimação do coeficiente de convecção entre o leito de partículas e a parede do secador, foi utilizada a correção proposta por (CHATTERJEE *et al.*, 1983) dada pela Equação 35.

$$h_w = 0,6 \left(\frac{u d_p \rho_{ar}}{\mu_{ar}} \right)^{0,39} \left(\frac{C_p g \mu_{ar}}{k_{ar}} \right)^{0,72} \left(\frac{C_p \rho_p}{C_{p ar} \rho_{ar}} \right)^{0,12} \left(\frac{k_{ar}}{d_p} \right) \quad (35)$$

Onde: g é a aceleração da gravidade ($m.s^{-2}$), ρ_p é a densidade das partículas ($Kg.m^{-3}$), $C_{p ar}$ é o calor específico do ar ($J. Kg^{-1}. K^{-1}$).

Para determinação do coeficiente de convecção de troca térmica entre a parede do secador e o ar ambiente, foi utilizada a correlação para troca térmica em cilindros verticais proposta por (Churchill, S. W.; Chu, 1975) (Equação 36) para o cálculo do número de *Nusselt* e as Equações complementares 37 e 38.

$$Nu = \left\{ 0,825 + \frac{0,387 Ra^{1/6}}{[1+(0,492/Pr)^{9/16}]^{8/27}} \right\}_2 \quad (36)$$

$$Ra = \frac{g \beta (T_{parede} - T_{amb})L^3}{\nu \alpha} \quad (37)$$

$$h = \frac{Nu k_{ar}}{L} \quad (38)$$

Onde Pr é o número de *Prandtl* (adimensional) que é a razão entre a difusividade de momento e a difusividade térmica do fluido, Ra_L é o número de *Rayleigh* (adimensional) que representa a razão de forças de fluabilidade e viscosidade multiplicadas pela razão das difusividades térmica e dinâmica. L é a altura do secador (m), Nu é o número de *Nusselt* (adimensional), g é a aceleração da gravidade ($m.s^{-2}$), β é o coeficiente de expansão térmica (K^{-1}), T_{parede} é a temperatura da parede do secador (K), ν é a viscosidade cinemática ($m^2.s^{-1}$) e α é a difusividade térmica ($m^2.s^{-1}$).

Para o cálculo das propriedades psicrométricas do ar de secagem é necessário ter pelo menos duas variáveis independentes, para que assim seja possível calcular as demais. Com isso foi assumido que a temperatura do ar na entrada e na saída do secador em $t = 0$ s foram iguais a $60^\circ C$ e $30^\circ C$ respectivamente e umidade relativa do ar na entrada do secador igual a 11,7% e na saída 54,9%. Através então das equações 39, 43, 44, 45, 46, 47, 48 e 49 respectivamente para o cálculo da pressão de vapor do ar na saturação (Pv_{sat}) (kPa), pressão de vapor (Pv) (kPa), umidade absoluta na saturação (W_{sat}) ($kg.kg^{-1}$), umidade absoluta (W) ($kg.kg^{-1}$), temperatura no ponto de orvalho (t_{po}) ($^\circ C$), volume específico (V_{esp}) (m^3), calor específico do ar ($C_{p ar}$) ($J.Kg^{-1}.K^{-1}$) e entalpia do ar (h) ($kJ.kg^{-1}$).

$$Pv_{sat} = e^{(A + B + C)} \quad (39)$$

$$A = -\frac{7511,52}{T} + 89,63121 + 0,02399897 T \quad (40)$$

$$B = 1,1652551 \cdot 10^{-5} T^2 - 1,2810336 \cdot 10^{-8} T^3 \quad (41)$$

$$C = 2,0998405 \cdot 10^{-11} T^4 - 12,50799 \ln(T) \quad (42)$$

$$Pv = \frac{UR}{100} Pv_{sat} \quad (43)$$

$$W_{sat} = 0,62198 \frac{Pv_{sat}}{P - Pv_{sat}} \quad (44)$$

$$W = 0,62198 \frac{Pv}{P - Pv} \quad (45)$$

$$t_{po} = 13,8 + 9,478 \cdot \ln(Pv) + 1,991(\ln(Pv))^2 \quad (46)$$

$$V_{esp} = \left(\frac{R T}{P} \right) (1 + 1,6078 \cdot W) \quad (47)$$

$$C_{p ar} = 1,05 - 0,365 \frac{T}{1000} + 0,85 \left(\frac{T}{1000} \right)^2 - 0,39 \left(\frac{T}{1000} \right)^3 \quad (48)$$

$$H = 1,006 T + (W (2501 + 1,775 T)) \quad (49)$$

3.6.1. Proposta de resolução do modelo híbrido

Primeiramente, para resolução das equações diferenciais, foi desenvolvido um modelo de redes neurais artificiais para a estimação da variação das propriedades físicas dos cubos de goiaba ao longo da secagem ($U_{(b.s)}$, d_p e ρ) (Modelo MN-1), propriedades essas importante para o cálculo de diversos parâmetros do modelo fenomenológico. Tal modelo de RNA proposto seguiu o passo a passo de desenvolvimento descritos na seção 3.5 desse trabalho.

As variações das propriedades físicas dos pedaços de goiaba preditos pela rede eram então utilizadas para auxiliar no cálculo das temperaturas do leito de partículas e do ar na saída do secador, bem como para o cálculo da umidade absoluta do ar na saída do secador. A Figura 14 mostra o diagrama de fluxo de dados do processo de soluções das equações diferenciais.

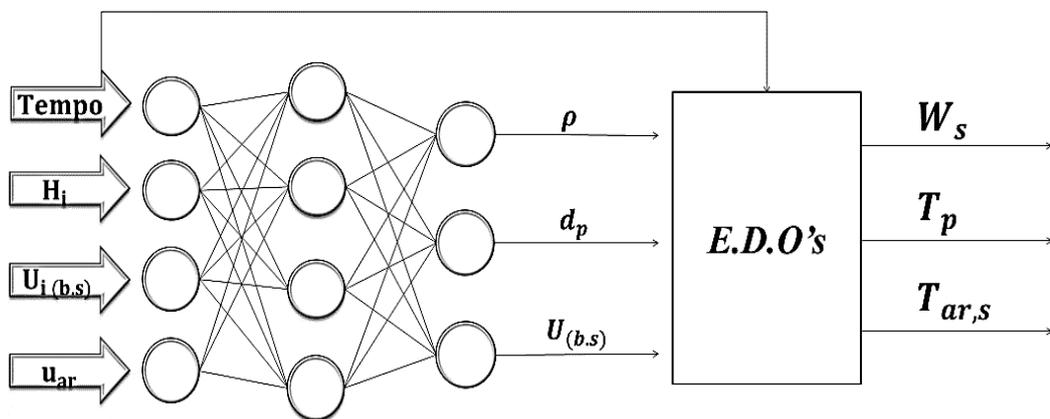


Figura 14: Diagrama de fluxo de dados do processo de resolução do modelo híbrido.

As Equações Diferenciais Ordinárias (E.D.O's) descritas na Figura 14 foram resolvidas numericamente pelo método das diferenças finitas desenvolvido em código do Matlab (Versão 4.0). Para solução das equações as condições iniciais aplicadas foram em $t = 0$, $U_{p(0)} = U_{p(0), exp}$ e $T_{p(0)} = T_{p(0), exp}$.

4. RESULTADOS E DISCUSSÕES

Nesse capítulo inicialmente serão descritos os resultados obtidos nos experimentos de secagem dos pedaços de goiaba em leito de jorro de forma sucinta, a fim de fornecer com clareza informações e dados dos experimentos que serão necessários para se entender e interpretar os resultados dos modelos obtidos, aplicando-os ao processo.

Posteriormente estão descritos os resultados obtidos a partir dos modelos de RNA e do modelo híbrido neural aplicados ao processo de secagem utilizado como estudo de caso, bem como a comparação dos dados obtidos através da modelagem e os dados experimentais.

4.1. Resultados experimentais da secagem dos pedaços de goiaba no secador leito de jorro

Os resultados experimentais descritos na Figura 15 representa a variação da umidade em base seca ($U_{(b.s)}$), o diâmetro da partícula (d_p), a massa específica (ρ) e também a variação dos parâmetros fluidodinâmicos: número de Arquimedes (Ar) e o parâmetro de *Littman* (A) durante a secagem dos pedaços de goiaba para o ensaio sob as condições de $H_i = 0,12$ m, $U_{i(b.s)} = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹. Comportamento semelhante foi observado para os demais ensaios experimentais.

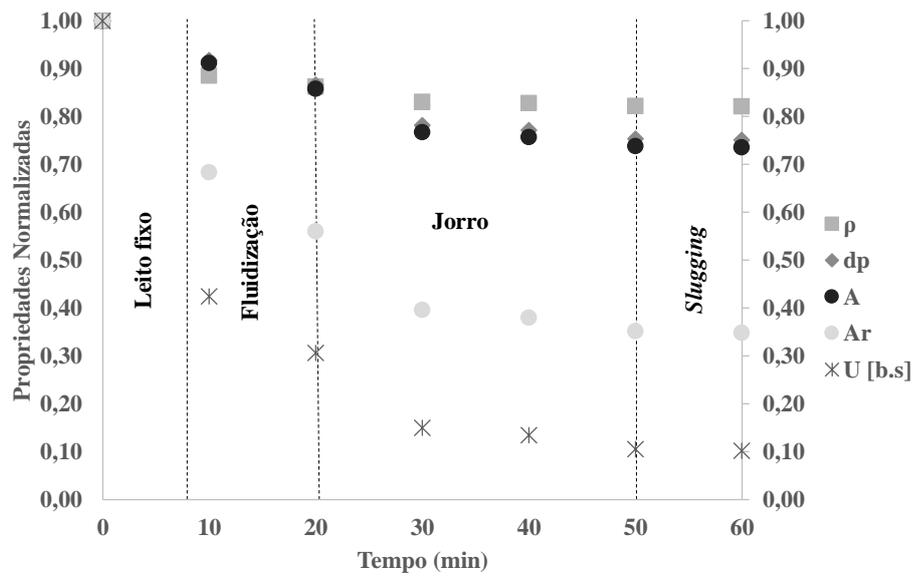


Figura 15: Evolução das propriedades físicas dos pedaços de goiaba durante a secagem no leito de jorro e classificação dos regimes de fluxo para o ensaio sob as condições experimentais: ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹). Fonte: (ALMEIDA, 2004).

A Tabela 7 mostra os resultados obtidos para os valores iniciais e finais da umidade em base ($U_{(b.s)}$), densidade (ρ) e diâmetros médio das partículas (d_p), bem como dos parâmetros fluidodinâmicos: número de Arquimedes (Ar) e parâmetro de *Littman* (A), sob diferentes condições experimentais (H_i , U_i e u_{ar}).

Tabela 7: Valores finais e iniciais para as propriedades físicas da goiaba estudadas ($U(b.s)$, ρ e d_p) e para o número de Arquimedes e parâmetro de *Littman* para as diferentes condições experimentais estudadas.

ENSAIO	Variáveis independentes			Variáveis dependentes				
	H_i (m)	$U_{i(b.s)}$	u_{ar} ($m.s^{-1}$)	$U(b.s)$	ρ ($kg.m^{-3}$)	d_p (m) ($\times 10^{-3}$)	Ar ($\times 10^7$)	A
1	0,09	0,6	2,8	0,649	977,6	8,0	1,32	0,122
				0,108	893,4	6,3	0,59	0,095
2	0,12	0,6	2,8	0,645	976,9	8,0	1,3	0,122
				0,125	896,1	6,4	0,61	0,096
3	0,09	1,5	2,8	1,478	1106,6	8,6	1,81	0,131
				0,151	900,1	6,5	0,65	0,097
4	0,12	1,5	2,8	1,523	1113,4	8,5	1,80	0,130
				0,159	901,3	6,5	0,66	0,098
5	0,09	0,6	3,5	--	--	--	--	--
6	0,12	0,6	3,5	0,622	973,3	8,0	1,29	0,121
				0,122	895,5	6,4	0,61	0,095
7	0,09	1,5	3,5	1,5	1109,9	8,6	1,81	0,130
				0,13	896,8	6,4	0,62	0,096
8	0,12	1,5	3,5	1,4	1094,4	8,6	1,83	0,132
				0,143	898,9	6,5	0,64	0,097
9	0,105	1,05	3,2	1,04	1039,2	8,6	1,72	0,131
				0,19	907,6	6,7	0,71	0,100
10	0,105	1,05	3,2	1,05	1039,9	8,6	1,73	0,131
				0,19	906,2	6,7	0,70	0,100

Ao observar a Figura 15, pode-se perceber o decréscimo das propriedades físicas normalizadas ao longo do processo de secagem, em destaque para a diminuição do teor de umidade dos pedaços de goiaba. É possível observar também a redução dos valores do parâmetro de *Littman* e do número de Arquimedes, uma vez que estes são influenciados diretamente pelos diâmetros das partículas e densidade.

Essa diminuição do diâmetro da partícula decorrente do processo de secagem explica a grande instabilidade fluidodinâmica apresentada pelo leito durante o processo. Analisando-se o comportamento da secagem para a condição experimental apresentada, nota-se que o parâmetro de *Littman* possui variação, sempre com valores maiores que 0,02, classificando

assim o mecanismo de terminação do jorro como sendo a fluidização no topo da região anular. Comportamento similar para o parâmetro de *Littman* foi encontrado para as demais condições experimentais estudadas por ALMEIDA *et al.*, (2006).

Com relação ao mapeamento dos regimes fluidodinâmicos no leito, na Figura 15 percebe-se que na condição experimental representada, foram observados 4 regimes de fluxo distintos, sendo eles o leito fixo, que durou cerca de 10 minutos iniciais da secagem, seguido pela observação do regime de fluidização, por cerca de mais de 10 minutos e posteriormente foi observado o leito de jorro, durando cerca de 30 minutos. Por último o regime de *Slugging* perdurando pelos 10 minutos finais da secagem. Os demais ensaios experimentais apresentaram comportamentos parecidos com os observados nas condições experimentais da Figura 15, porém em alguns ensaios foi verificado a ausência de alguns dos regimes (ALMEIDA *et al.*, 2006).

Alguns autores descritos na literatura estudaram o mapeamento dos regimes de fluxo no leito de jorro através de observações visuais, como é o caso do trabalho de MARMO (2007) que estudou o mapeamento dos regimes de fluxo em um leito de jorro na secagem de bagaços, modificando parâmetros de fluxo do gás de secagem para avaliar o efeito nos regimes de fluxo. DOGAN *et al.* (2000) também estudaram os efeitos de diferentes tamanhos do bico de entrada do ar, bem como a velocidade do ar no mapeamento dos regimes de fluxo em um secador de leito de jorro retangular, os autores utilizaram de observações visuais para classificar os regimes de fluxo no leito contendo bolas de vidro. Os autores observaram a presença de diversos regimes dentro do leito, dentre eles, o regime de jorro e de *slugging*, regimes esses apresentados também na secagem dos pedaços de goiaba em leito de jorro.

4.2. Construção dos modelos neurais

4.2.1. Divisão do banco de dados

Para a construção dos bancos de dados necessários para treinar, validar e testar os modelos de redes neurais artificiais foi utilizado um conjunto de dados contendo 180 amostras. Esse conjunto de dados foi então embaralhado aleatoriamente e então, 70% dos dados foram utilizadas para o processo de treinamento das redes, 15% para a validação no momento do

treinamento e outros 15% para realizar os testes da rede neural, essas proporções para cada banco de dados foi baseada em trabalhos já publicados na literatura na utilização de redes para predição, onde os autores ressaltam que uma adequada distribuição nos bancos de dados deve ser garantida para que esses possam abranger o problema em questão (AMEER *et al.*, 2017; GHAHDARIJANI *et al.*, 2017; SUNPHORKA *et al.*, 2017).

Após a separação dos bancos, as amostras quantitativas foram normalizadas entre +1 e -1, enquanto que as qualitativas foram classificadas utilizando a codificação *Dummy*. A Figura 16 mostra a distribuição dos bancos de dados de treinamento, validação e teste para as 4 variáveis dos modelos MN-1 (densidade, diâmetro da partícula e umidade) e MN-2 (regime de fluxo).

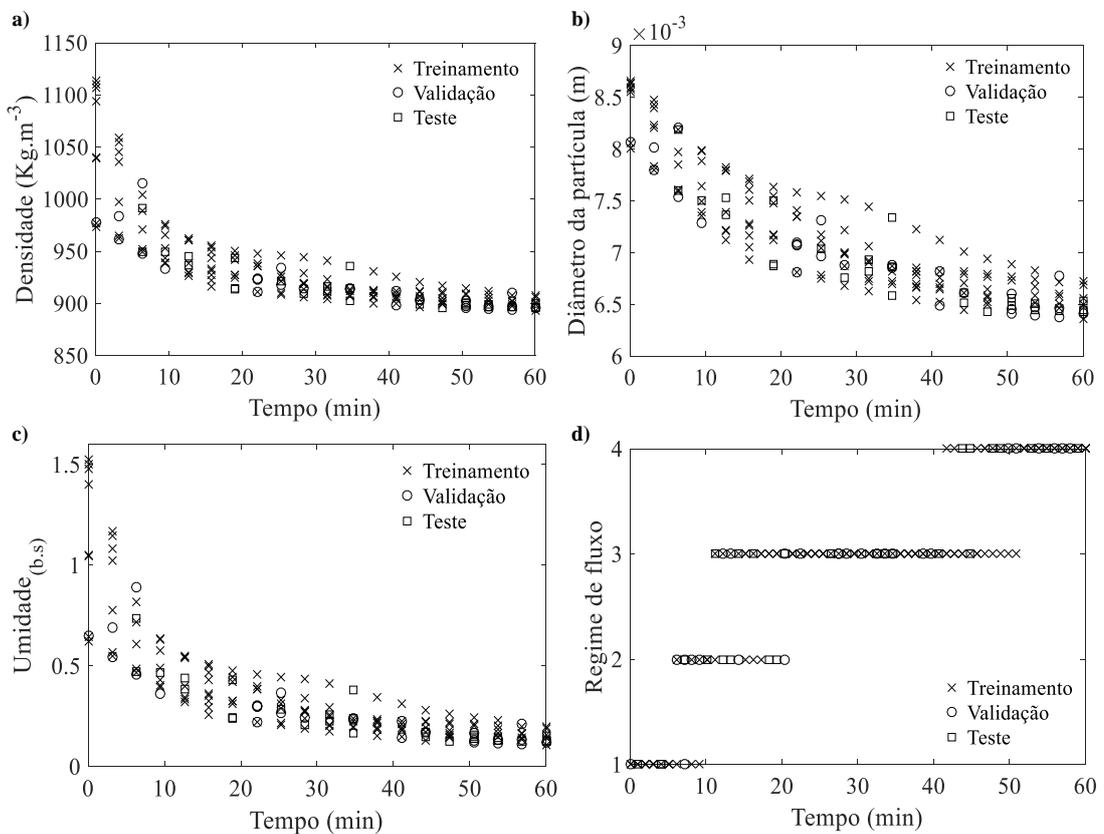


Figura 16: Distribuição dos dados experimentais para os 3 subconjuntos de treinamento, validação e teste para: a) massa específica, b) diâmetro da partícula, c) Umidade em base seca e d) Regimes de fluxo.

Pode-se observar na Figura 16 que os bancos de dados de treinamento, validação e testes dos modelos MN-1 e MN-2 contemplam as faixas de estudo. É importante garantir que os

bancos de dados abrangam todo o problema em questão, pois só dessa forma o modelo será mais representativo ao processo.

4.2.2. Definição dos parâmetros do PSO

Para determinação da arquitetura dos modelos neurais a serem desenvolvidos, foi aplicado um algoritmo de otimização por enxame de partículas (PSO). Para aplicação deste algoritmo foram testados diferentes valores de coeficiente pessoal (c_1) e global (c_2) de aceleração e número de partículas presente no enxame, afim de determinar o melhor valor de cada parâmetro a ser utilizado através da análise do desempenho do modelo, a partir do valor de MSE.

A Figura 17 apresenta o menor valor de MSE encontrado pelo algoritmo de otimização PSO para diferentes valores dos parâmetros c_1 e c_2 em um range de 1,4 a 2,6, e diferentes números de partículas no enxame, variando entre 15 e 25 partículas. O range dos coeficientes foram definidos baseados em trabalhos encontrados na literatura o qual foram obtidos bons resultados quando utilizaram valores dentro desse range aplicados no processo de modelagem de reservatórios de gás condensado e canais de equalização (ZENDEHBOUDI *et al.*, 2012; DAS *et al.*, 2013).

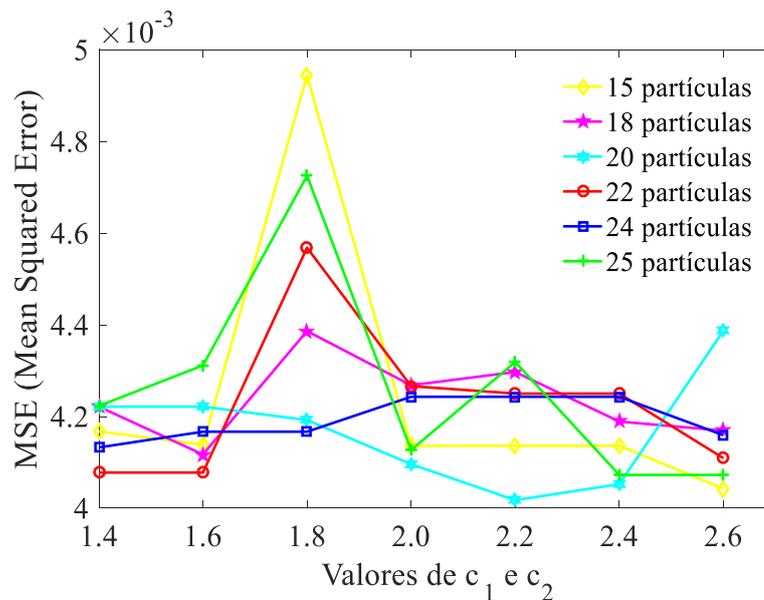


Figura 17: Performance do algoritmo de otimização baseado no número de partículas do enxame e nos valores do coeficiente pessoal (c_1) e global (c_2) de aceleração.

Observa-se na Figura 17 que o menor valor de MSE foi encontrado quando utilizados no algoritmo PSO um número de partículas igual a 20 e valores de c_1 e c_2 igual a 2,2 onde o valor de MSE encontrado foi de 0,00401. Resultados semelhantes foram reportados por ZENDEHBOUDI *et al.* (2012), onde foi encontrado um valor ótimo de c_1 e c_2 iguais a 2,0 e número de partículas igual a 21, para a otimização de uma rede neural para predição do comportamento de um reservatório de gás condensado.

4.2.3. Desenvolvimento do modelo para predição da evolução das propriedades físicas (MN-1)

Para o desenvolvimento do modelo neural denominado MN-1, foram utilizados como variáveis de entrada do modelo: o tempo de secagem, a umidade inicial das amostras ($U_{i(b.s)}$), a velocidade do ar de secagem (u_{ar}) e a altura inicial do leito (H_i) e como variáveis de saída do modelo: a densidade (ρ), o diâmetro da partícula (d_p) e a umidade em base seca dos pedaços de goiaba ($U_{(b.s)}$). As faixas das variáveis utilizadas como entrada e saída do modelo MN-1 estão descritas na Tabela 8.

Tabela 8: Níveis de máximo e mínimo das variáveis de entrada e saída do MN-1.

Variáveis	Faixa
Entrada	
Tempo (min)	0 - 60
u_{ar} (m.s ⁻¹)	2,8 - 3,5
H_i (m)	0,09 - 0,12
$U_{i(b.s)}$	0,60 - 1,52
Saída	
ρ (Kg/m ³)	893,4 - 1113,4
d_p (m)	0,0063 - 0,0086
$U_{(b.s)}$	0,1082 - 1,52

Nesse trabalho foi fixado o algoritmo de treinamento *Backpropagation Levenberg-Marquardt*. Uma das características desse algoritmo é que o mesmo tem o objetivo de buscar o processo de convergência mais eficaz, evitando os problemas de convergência muito lenta que faz com que aumente os esforços computacionais, além de apresentar em diversos trabalhos na bibliografia bons resultados aplicados em vários processos (OLIVEIRA *et al.*, 2015; SILVA *et al.*, 2015; AMEER *et al.*, 2017; GHAHDARIJANI *et al.*, 2017).

Foi fixado também apenas uma camada escondida, tendo em vista, que essa configuração é o suficiente para a aplicação de redes a problemas mais simples, ficando restrito o uso de mais camadas a processos mais complexos, além de que uma segunda camada poderia aumentar demasiadamente o número de conexões tornando a rede sobre parametrizada (excesso de conexões). A função linear foi fixada entre a camada intermediária e a camada de saída, pois segundo KHAYET *et al.* (2011) essa função se comporta como um aproximador universal de funções.

4.2.3.1. Definição da arquitetura da rede MN-1

A definição do número de neurônios na camada escondida, a função de transferência na camada intermediária e a taxa de aprendizagem mais adequada para o desenvolvimento do modelo neural MN-1 foram definidas através da utilização do algoritmo de otimização por enxame de partículas (PSO). O algoritmo foi utilizado para selecionar a melhor configuração com base na resposta do modelo neural baseado no erro de predição (MSE).

Para que a rede neural MN-1 não ficasse sobre parametrizada, foi utilizada a metodologia proposta no trabalho de CYBENKO (1989), o qual afirma que o número de neurônios na camada escondida deve ser igual ou menor que $(2i + 1)$, onde i é o número de variáveis de entrada do modelo. Dessa forma, o número máximo de neurônios a serem utilizados na camada escondida foi igual a 9. A Tabela 9 mostra os parâmetros do modelo neural, bem como a suas variações otimizadas pelo algoritmo PSO.

Tabela 9: Parâmetros da rede neural (MN-1) otimizados utilizando o algoritmo PSO.

Parâmetros otimizados	Variação
Número de neurônios	De 1 à 9 neurônios
Função de transferência	Linear, tangente hiperbólica e sigmoide
Taxa de aprendizagem	De 0 à 1

A função tangente hiperbólica na camada intermediária, a taxa de aprendizagem igual a 0,56 e o número de neurônios na camada escondida igual a 7, foram os parâmetros neurais encontrados para proporcionar o menor MSE após a otimização pelo algoritmo PSO. Resultados semelhantes foram encontrados no trabalho de ZHONG *et al.* (2013) que utilizaram algoritmos genéticos para a otimização de uma rede neural para predição de velocidade mínima

de jorro. Neste trabalho os autores utilizaram de um banco de dados com 164 amostras e obtiveram um número ótimos de neurônios igual a 9 e taxa de aprendizagem de 0,79.

A Tabela 10 apresenta os resultados da configuração do modelo MN-1 obtida pelo algoritmo de otimização. Com essa configuração do modelo neural foi obtido no treinamento os seguintes parâmetros de desempenho: MSE igual a 0,004, RMSE igual a 0,066 e R^2 0,99.

Tabela 10: Desempenho da melhor configuração de rede selecionada pelo algoritmo de otimização para o modelo MN-1.

Número de neurônios em cada camada	Função de transferência		Algoritmo de treinamento	Desempenho	
	Camada escondida	Camada de saída		MSE	RMSE
4-7-3	Tangente hiperbólica	Linear	<i>Backpropagation</i> <i>Levenberg</i> <i>Marquardt</i>	0,004	0,066

No trabalho de MIHAJLOVIC *et al.* (2011), o qual utilizaram um modelo de rede neural aplicado no processo de secagem de lactose e maltodextrina em um secador do tipo *spray-dryer*, foram observados um valor de RMSE igual a 0,15 e R^2 de 0,93 na predição da temperatura do ar na saída do secador. YOUSEFI *et al.* (2014), relata a utilização de um modelo de RNA aplicado ao processo de secagem de framboesa em leito fluidizado, no qual o modelo era utilizado para predição da densidade e da porosidade do material, obtendo coeficiente de correlação (R^2) de 0,96. Já no trabalho de SILVA *et al.* (2015), o qual aplicaram um modelo de RNA a dados obtidos no processo de secagem de sementes de aroeira em leito fixo, foram observados um valor de RMSE igual a 0,007 e R^2 de 0,99 na predição da cinética de secagem. Sendo assim, o modelo MN-1 desenvolvido no trabalho atual obteve índices de desempenho satisfatórios, se comparados aos índices dos modelos já publicados na literatura.

A Figura 18 ilustra a arquitetura da modelo final de redes neurais para a predição das propriedades físicas da goiaba.

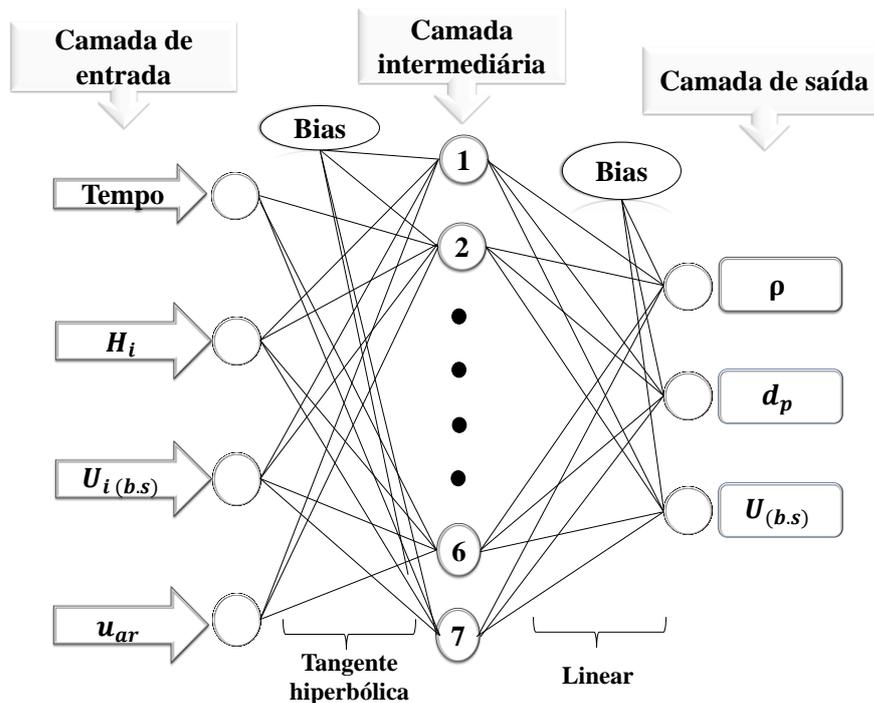


Figura 18: Arquitetura do modelo neural (MN-1) otimizado.

4.2.3.2. Desempenho de treinamento do modelo MN-1

O desempenho do modelo MN-1 foi medido através do acompanhamento do erro de predição (MSE) para os 3 bancos de dados distintos, durante as etapas de criação do modelo. A Figura 19 apresenta a variação do MSE em função do número de iterações (Épocas) para o modelo desenvolvido. Pode-se perceber que a cada nova iteração feita pelo modelo para os bancos de dados de treinamento, validação e teste o valor de MSE respectivo para cada etapa minimizou-se. Esse acompanhamento do erro de predição é importante, pois evita-se que a rede seja treinada excessivamente (*overtraining*), causando assim problemas de generalização do modelo neural (KUNDU *et al.*, 2015).

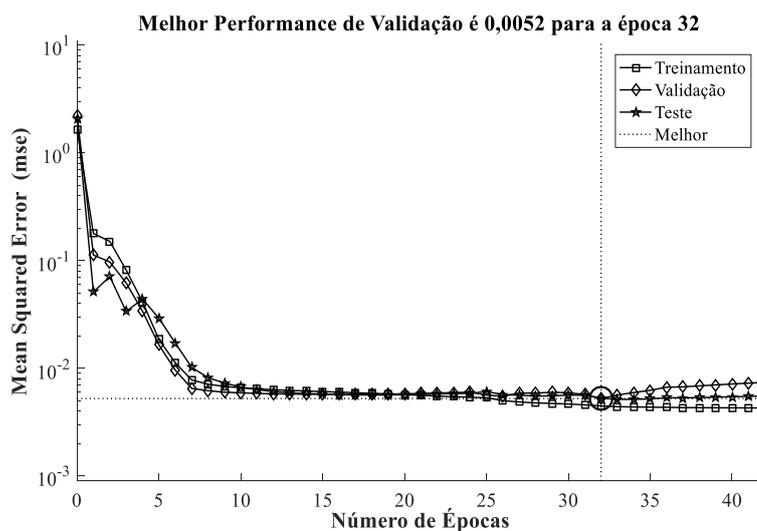


Figura 19: Performance do modelo MN-1 durante a fase de treinamento, teste e validação do modelo.

Percebe-se ainda na Figura 19 que a partir do número de épocas igual a 32 existe o crescimento do erro de validação, enquanto que o erro de treinamento diminui, o que sugere, para número de épocas maiores que 32 que acontece no modelo o *overtraining*. Sendo assim foram definidas 32 iterações como o número ideal de iterações, alcançando-se valor de MSE igual a 0,0052.

A Figura 20 exibe a regressão linear para o modelo utilizando o banco de dados de treinamento, validação, teste e todos os conjuntos de dados contidos em um só banco. Essa regressão linear mostra a relação entre as respostas produzidas pelo modelo neural e as respostas reais (valores experimentais ou observados). Essa forma serve para validar o modelo a partir do valor do coeficiente de correlação da reta (R^2) que melhor representa essa relação, quanto mais próximo de 1 é esse valor melhor o modelo desenvolvido consegue representar os dados reais.

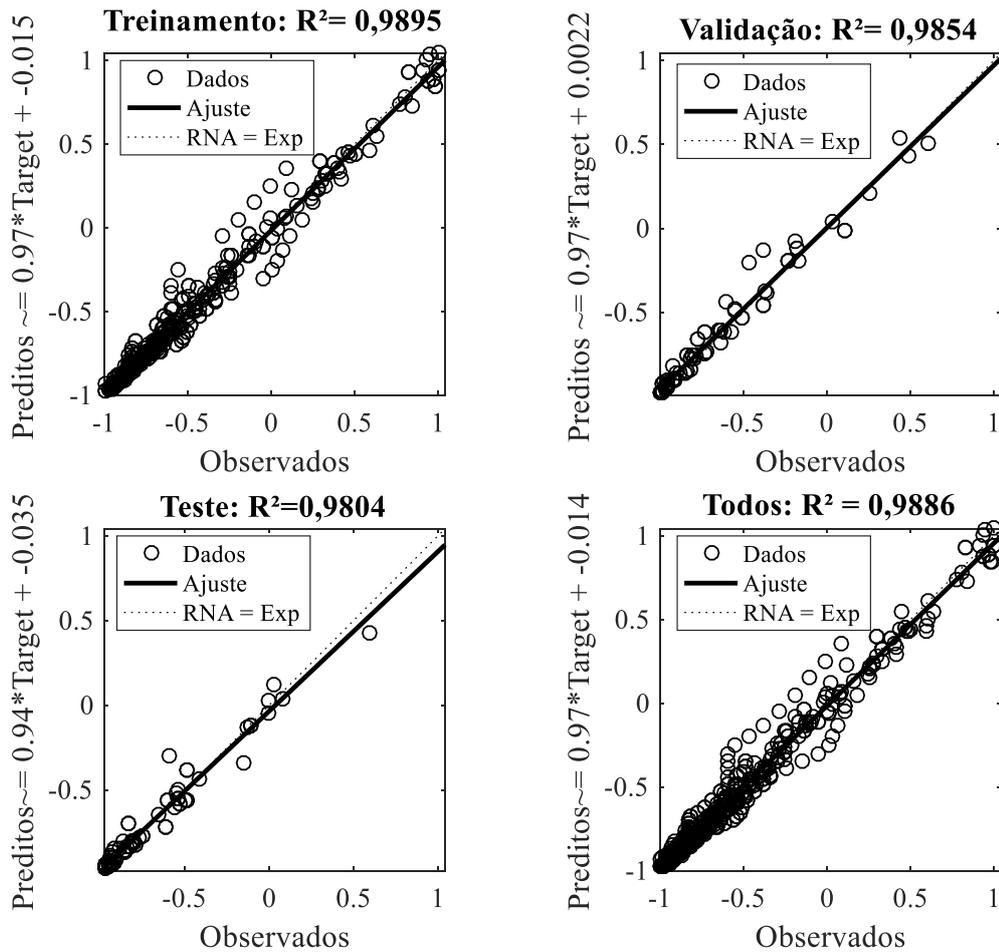


Figura 20: Regressão linear feita para os dados de treinamento, validação, teste e o conjunto global para o modelo neural para predição das propriedades físicas dos pedaços de goiaba.

Observa-se na Figura 20 que foram obtidos para o banco de dados de treinamento um R^2 de 0,9895, enquanto que o R^2 de validação e de teste apresentam valores iguais a 0,9854 e 0,9804 respectivamente. Por consequência pode-se afirmar que o modelo desenvolvido obteve um ajuste satisfatório aos dados reais.

4.2.3.3. Equações do modelo MN-1 e análise da importância relativa das variáveis pela RNA

Após a etapa de treinamento e validação da rede neural foi então obtida a matriz de pesos e bias do modelo, apresentados na Tabela 11.

Tabela 11: Matriz dos pesos e das bias para o modelo neural (MN-1).

Neurônios	W_e				Bias (B_1)	W_s			Bias (B_2)
	Variáveis de entrada					Variáveis de saída			
	Tempo	H_i	$U_{i(b.s)}$	u_{ar}		ρ	d_p	$U_{(b.s)}$	
1	-1,33	3,36	2,36	-1,78	2,75	0,27	0,64	0,27	1,33
2	1,73	-1,66	2,97	1,42	-2,51	-0,18	-0,42	-0,18	0,64
3	0,44	3,04	0,44	-1,10	0,67	-0,19	-0,48	-0,19	1,33
4	3,59	-0,01	-0,50	0,02	4,43	-1,85	-0,44	-1,85	
5	0,46	-4,34	-0,09	-0,01	1,42	0,04	0,08	0,04	
6	-1,29	0,22	-0,05	-0,05	-1,61	0,45	1,12	0,45	
7	0,95	-1,11	-3,45	-2,95	2,40	-0,15	-0,35	-0,15	

Para a Tabela 11 os pesos e as bias de cada conexão estão divididos da seguinte forma, W_e refere-se aos pesos e B_1 as bias para cada conexão entre os neurônios de entrada e os neurônios da camada intermediária, já W_s e B_2 refere-se aos valores de pesos e bias entre as conexões feitas pelos neurônios da camada intermediária e a camada de saída.

Através da utilização da matriz de pesos e bias para o modelo desenvolvido utilizando-se as Equações 50, 51 e 52 é possível simular a resposta do modelo proposto para se calcular os valores de densidade, diâmetro da partícula e umidade em base seca dos pedaços de goiaba respectivamente.

$$\rho = \left(\frac{2}{(1 + e^{-2(-8,1.tempo+0,728.H_i+1,41.U_i-0,123.u_{ar}-8,142)})} - 1 \right) + 1,33 \quad (50)$$

$$d_p = \left(\frac{2}{(1 + e^{-2(-5,12.tempo+1,67.H_i+1,4.U_i-0,264.u_{ar}-1,961)})} - 1 \right) + 0,64 \quad (51)$$

$$U_{(b.s)} = \left(\frac{2}{(1 + e^{-2(-8,1.tempo+0,728.H_i+1,41.U_i-0,123.u_{ar}-8,142)})} - 1 \right) + 1,33 \quad (52)$$

Onde o *tempo*, refere-se ao tempo de secagem em minutos, H_i é a altura inicial do leito em metros, U_i é a umidade inicial em base seca dos cubos de goiaba e u_{ar} é a velocidade do ar de secagem em metros por segundos.

Uma forma de extrair as contribuições de cada variável de entrada nas respostas do modelo baseado em redes neurais é utilizando uma equação matemática que nos revela a importância relativa (I.R) de cada variável, independente do processo em função dos pesos sinápticos de cada conexão de neurônios, tendo em vista que os pesos tem a função de ponderar a relevância de cada neurônio para a saída do modelo (OLDEN *et al.*, 2002).

A importância relativa de cada variável independente é então calculada utilizando a Equação 53.

$$I.R_x = \sum_{y=1}^m w_{xy}w_{yz} \quad (53)$$

Onde, $I.R_x$ é a importância relativa do neurônio de entrada x, y são os neurônios da camada escondida e z são os neurônios da camada de saída, enquanto que w refere-se aos pesos sinápticos de cada neurônio.

A Tabela 12 refere-se à importância relativa de cada variável independente (neurônios de entrada do modelo) para cada variável dependente (neurônios de saída do modelo), vale ressaltar que foi retirado do cálculo da importância relativa das variáveis o tempo de secagem, pois por se tratar de uma cinética essa variável poderia mascarar a importância das demais variáveis de entrada do modelo.

Tabela 12: Importância relativa de cada variável de entrada para cada variável de saída do modelo neural (MN-1) calculado pelo método dos pesos sinápticos.

Variáveis dependentes (resposta)	Importância relativa das variáveis independentes (entrada) (%)		
	H_i	$U_{i(b.s)}$	u_{ar}
ρ	32,05%	62,38%	5,57%
d_p	50,15%	41,93%	7,92%
$U_{(b.s)}$	32,05%	62,38%	5,57%

Ao analisar a Tabela 12, é verificado que para a densidade e para a umidade do produto a variável de entrada com maior importância relativa foi a umidade inicial. Segundo ARAUJO *et al.* (2014), o decréscimo das propriedades físicas durante a secagem de produtos agrícolas é decorrente da perda de água do material, isso explica uma maior importância relativa para a umidade inicial para as duas variáveis.

Para o diâmetro da partícula, a variável com maior importância relativa foi a altura inicial do leito de jorro, esse comportamento é explicado devido ao fato de menores alturas de leito aumentarem a área de contato entre a partícula e o ar de secagem. Dessa forma esse efetivo contato tende a causar uma maior deformação nas partículas, conseqüentemente reduzindo seu diâmetro. Percebe-se também, uma grande importância relativa para a umidade inicial, o que foi confirmado pelo comportamento das curvas experimentais em diferentes condições.

4.2.3.4. Aplicação do modelo MN-1 para a predição da cinética das propriedades físicas

Após o desenvolvimento do modelo neural para predição da evolução das propriedades físicas do material, foram realizados testes para verificar a sua capacidade de predição quanto aos perfis da cinética da densidade, da umidade e do diâmetro da partícula em diferentes condições experimentais.

As Figuras 21 (a) e (b) apresentam a cinética de variação da densidade para diferentes condições específicas de H_i , U_i e u_{ar} durante o processo de secagem, ao longo de 60 minutos, bem como a comparação com os valores preditos pelo modelo MN-1.

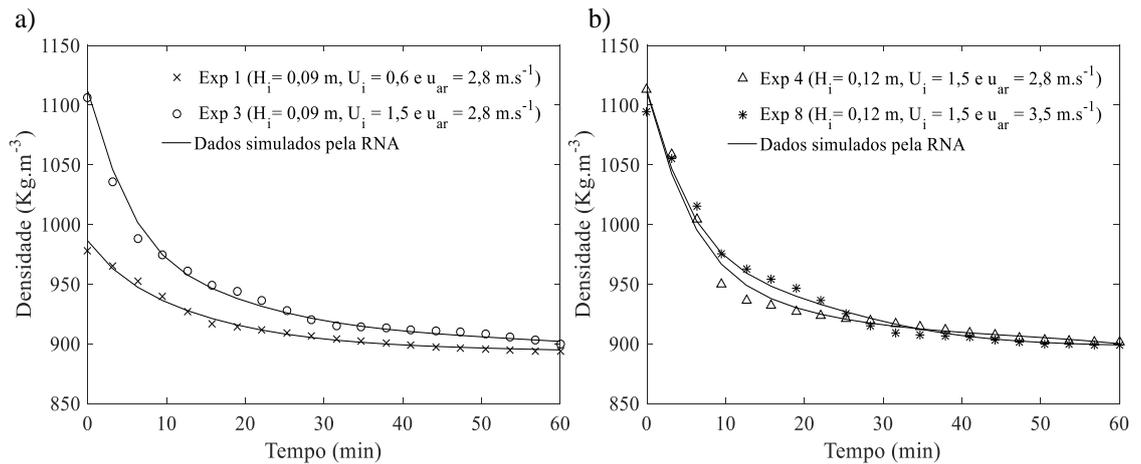


Figura 21: Comparação entre os valores preditos pelo modelo MN-1 e os valores experimentais das cinéticas de variação da densidade dos pedaços de goiaba ao longo da secagem nas condições: a) 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹) e 3 ($H_i = 0,09$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e b) 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹).

A fim de se demonstrar o efeito da umidade inicial, pode-se comparar os Ensaios 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹) e 3 ($H_i = 0,09$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) (Figura 20 (a)), onde permanecem constantes a altura inicial do leito e a velocidade do ar, afim de demonstrar o efeito da umidade inicial. Verifica-se que para o experimento 3 que tem condições iniciais de umidade maiores se comparado ao experimento 1, que maiores valores de umidade refletem em maiores valores de densidade ao longo de toda a secagem, o que confirma o que foi encontrado na Tabela 12 da importância relativa, onde foi verificado que para a densidade, a umidade inicial possui maior efeito.

É verificado também na Figura 21 (a) que, ao final da secagem, os valores de densidade para ambas as condições experimentais são próximos, o que pode ser explicado pelo fato da umidade em ambas as condições experimentais ter atingido o seu valor de equilíbrio no material. Além disso a densidade é diretamente influenciada pela perda de umidade, consequentemente, os seus valores finais tendem a se aproximar (KAHYAOGLU *et al.*, 2010).

Na Figura 21 (b), comparando-se os Ensaios 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹), sob mesmas condições de altura do leito e umidade inicial, a fim de verificar então o efeito da velocidade do ar, percebe-se que os valores de densidade ao longo da cinética de secagem para ambos os ensaios permaneceram muito próximos, mostrando assim que a velocidade do ar não apresenta influência significativa para a variável densidade.

A Figura 22 (a) e (b) exibem a cinética de variação do diâmetro da partícula dos pedaços de goiaba ao longo da secagem para três condições experimentais diferentes: 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹), 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e o 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹).

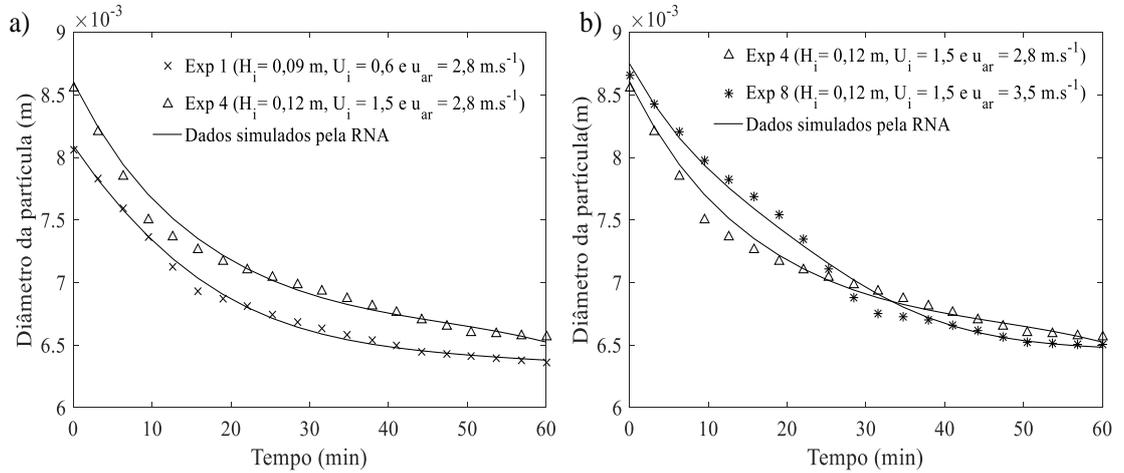


Figura 22: Comparação entre os valores preditos pelo modelo MN-1 e os valores experimentais das cinéticas de variação dos diâmetros das partículas dos pedaços de goiaba ao longo da secagem nas condições: a) 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹) e 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e b) 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹).

Pela a análise da Figura 22 (a), pode-se perceber que para menores valores de altura e umidade inicial (Experimento 1), favoreceu a obtenção de diâmetros de partículas menores ao longo da secagem. Tal fato demonstra a grande influência dessas variáveis no diâmetro da partícula, e de acordo com a importância relativa que foi encontrada na Tabela 12. Segundo KERDPIBOON *et al.* (2006), o encolhimento das partículas de produtos deformáveis e consequentemente a diminuição das suas dimensões durante a secagem é diretamente influenciada pelas modificações nas estruturas celulares do material, pois devido a umidade presente neste ser parte integrante da estrutura sólida ou estar retido nas fibras, conforme se é retirado a umidade existe então a formação de vazios dentro de sua estrutura, que por sua vez pode causar o processo de encolhimento das partículas.

Observa-se ao longo da cinética dos pedaços de goiaba, que o diâmetro da partícula teve redução em seu valor, o que explica também a instabilidade no leito durante os experimentos de secagem como observados por ALMEIDA *et al.* (2006).

A fim de verificar o efeito da velocidade do ar, comparando-se os Ensaios 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹), verifica-se na Figura

22 (b), que a cinética de ambos os experimentos coincide entre si, demonstrando que a velocidade do ar não possui influência significativa para o diâmetro da partícula, e confirma a baixa importância relativa desta variável para o diâmetro da partícula (Tabela 12).

Nas Figuras 23 (a) e (b), estão plotados os resultados da comparação entre os valores experimentais da cinética de secagem e dos valores preditos pela rede neural, para três condições diferentes: Ensaios 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹), 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹). Verifica-se a efetividade na predição da umidade em base seca em diferentes condições experimentais pelo modelo.

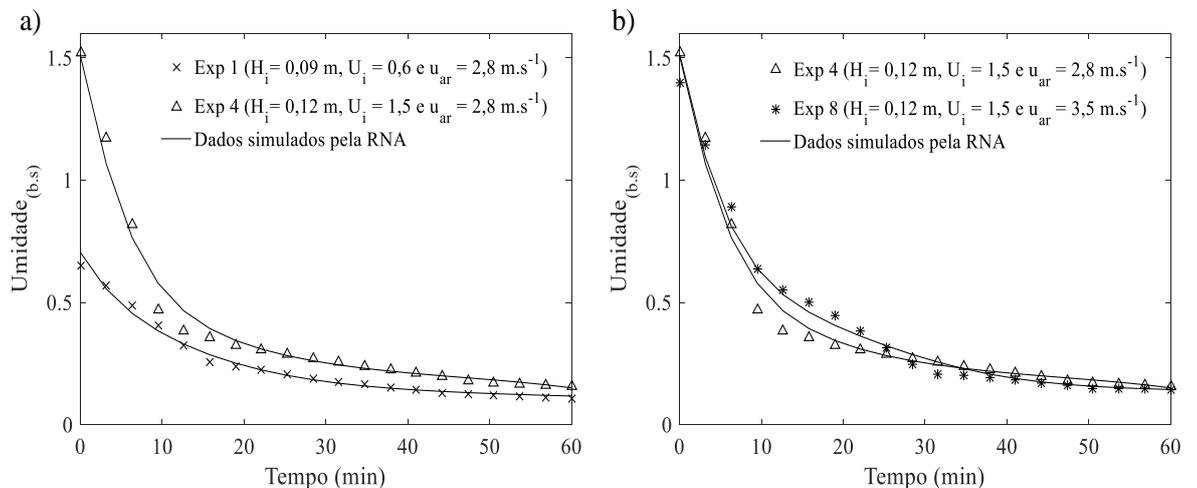


Figura 23: Comparação entre os valores preditos pelo modelo MN-1 e os valores experimentais das cinéticas de variação da umidade em base seca dos pedaços de goiaba ao longo da secagem nas condições: a) 1 ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹) e 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e b) 4 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 2,8$ m.s⁻¹) e 8 ($H_i = 0,12$ m, $U_i = 1,5$ e $u_{ar} = 3,5$ m.s⁻¹).

Analisando a Figura 23 (a) pode-se afirmar que para alturas do leito e umidade inicial mais baixas (Experimento 1), os valores de umidade finais dos pedaços de goiaba são menores. Menores volumes do leito de partículas, favorecem a um maior contato entre o fluido de secagem e os pedaços de goiaba resultando em uma maior taxa de transferência de calor e massa.

Em contrapartida a velocidade do ar de secagem não teve grande influência na cinética de secagem dos pedaços de goiaba, como pode ser observado na Figura 23 (b). Comportamento semelhante foi encontrado na secagem de sementes de aroeira em leito fixo no trabalho de SILVA *et al.* (2015). A maior influência da umidade inicial e a da altura inicial do leito, e a

baixa influência da velocidade do ar corroboram com os resultados encontrados na Tabela 12, referente a análise por RNA da importância relativa das variáveis.

Na Tabela 13 são apresentados os valores reais e preditos pelo modelo para todas as três variáveis de saída estudadas.

Tabela 13: Comparação entre os valores de mínimos e máximos reais e os preditos pelo modelo MN-1 e respectivos erros de predição.

Variáveis		Valor Experimental	Valor predito pela RNA	Erro relativo (%)
ρ (Kg/m ³)	Valor mínimo	893,4	890,6	0,32
	Valor máximo	1113,4	1110,9	0,23
d_p (m)	Valor mínimo	0,0063	0,0064	0,74
	Valor máximo	0,0086	0,0087	0,24
$U_{(b.s)}$	Valor mínimo	0,108	0,101	5,9
	Valor máximo	1,52	1,506	0,56

Comprova-se através da análise feita na Tabela 13, que o valores preditos pela RNA em comparação com os valores experimentais de máximo e mínimo para cada variável estudada, possuem grande proximidade. NASCIMENTO *et al.* (2013) obtiveram erro relativo entre 1,26 e 2,1 % na predição da queda de pressão no leito de jorro na secagem de diversos tipos de leite. Sendo assim o modelo MN-1 obteve erros relativos menores, atestando um satisfatório poder de predição das propriedades físicas dos pedaços de goiaba em secagem em leito de jorro.

Através das análises das Figuras 21 a 23 e da Tabela 13, é possível concluir que o modelo MN-1 apresentou um desempenho eficiente quando comparado os valores preditos e os valores experimentais para as três propriedades físicas dos pedaços de goiaba estudados na secagem em leito de jorro. É verificado que esse desempenho efetivo é independente das condições experimentais utilizadas, o que comprova o bom poder de generalização da rede neural.

O modelo neural desenvolvido pode auxiliar no desenvolvimento de sistemas de controle para secadores do tipo leito de jorro, tendo em vista que, através do controle de algumas variáveis operacionais do equipamento, como é o caso da velocidade do ar, pode-se estabelecer um jorro estável independente das mudanças nas propriedades físicas do material. Com isso,

pode-se concluir que a técnica de modelagem via redes neurais se mostrou promissora para a sua aplicação no processo de secagem em leito de jorro, com secagem de partículas sólidas, em relação à variação das propriedades físicas das partículas durante o processo de secagem.

4.2.4. Desenvolvimento do modelo para predição dos regimes de fluxo (MN-2)

Para o desenvolvimento do modelo para predição do regime de fluxo, denominado MN-2, foram utilizadas como variáveis de entrada, os parâmetros fluidodinâmicos de *Littman* (A) e o número de Arquimedes (Ar), juntamente com a velocidade do ar de secagem (u_{ar}). Como variável de saída foi utilizado o regime fluidodinâmico, sendo essa variável codificada utilizando a codificação conhecida como *Dummy*. Com essa estratégia os neurônios de saída do modelo produziam valores de 0 e 1. As faixas das variáveis utilizadas para a predição dos regimes de fluxo pelo modelo MN-2 estão apresentadas na Tabela 14.

Tabela 14: Níveis de máximo e mínimo das variáveis de entrada e saída do modelo MN-2.

Variáveis	Faixas
Entrada	
Ar	$6,2 \times 10^6 - 1,83 \times 10^7$
A	0,096- 0,132
u_{ar} (m.s⁻¹)	2,8 - 3,5
Saída	
Regime fluidodinâmico	Leito fixo - <i>Slugging</i>

Foi fixado para o modelo MN-2 o algoritmo de treinamento *Backpropagation Levenberg-Marquardt*. Foi estabelecida a função *Softmax* como sendo a função de ativação entre a camada intermediária e a camada de saída. Essa função é utilizada em redes neurais classificatórias, pois ela força a saída da RNA a representar a probabilidade dos dados a serem de uma classe definida. Foi utilizado também para esse modelo, apenas uma camada intermediária, evitando assim o excesso de conexões na rede.

4.2.4.1. Definição da arquitetura da rede MN-2

Utilizando o algoritmo de otimização por enxame de partículas, foram otimizados a taxa de aprendizagem, a função de transferência entre a camada de entrada e a camada intermediária

e o número de neurônios na camada de saída, para esse último parâmetro, foi utilizado a metodologia proposta por CYBENKO (1989) para definição do número máximo de neurônios. Os parâmetros do modelo MN-2 otimizados pelo algoritmo PSO foram: o número de neurônios na camada intermediária (de 1 à 7 neurônios), função de transferência entre a camada de entrada e a camada intermediária (linear, tangente hiperbólica e sigmoide) e taxa de aprendizagem (de 0 a 1).

Através do algoritmo PSO foram encontrados os parâmetros otimizados da rede como sendo o número de neurônios na camada escondida igual à 4, formando assim uma arquitetura do tipo 3-4-4 (3 neurônios na camada de entrada, 4 neurônios na camada intermediária e 4 neurônios na camada de saída), a taxa de aprendizagem igual à 0,24 e a função de transferência entre a camada de entrada e a camada intermediária como sendo a função tangente hiperbólica. A Figura 24 ilustra a arquitetura da rede do modelo final para reconhecimento dos regimes de fluxo no leito durante a secagem da goiaba.

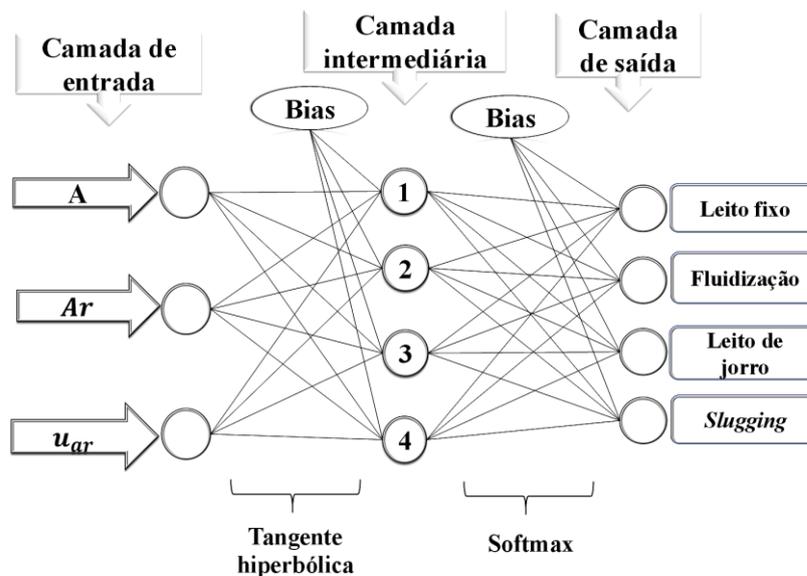


Figura 24: Arquitetura do modelo neural (MN-2) otimizado.

4.2.4.2. Desempenho de treinamento do modelo MN-2

Para evitar que o modelo neural MN-2 sofresse um *overtraining*, acompanhou-se a evolução da *performance* (erro), durante todas as etapas de construção da rede (treinamento, validação e teste). A Figura 25 mostra a evolução do MSE em função do número de épocas para o modelo MN-2.

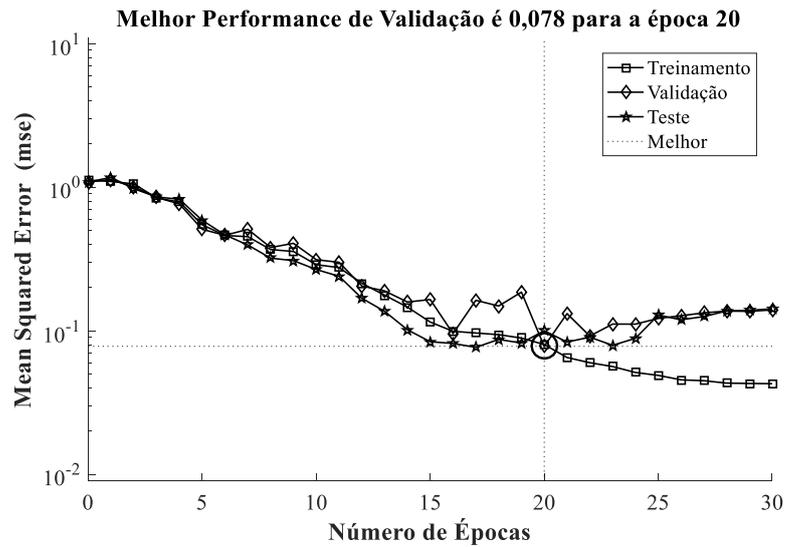


Figura 25: Performance do modelo MN-2 durante a fase de treinamento, teste e validação do modelo.

Percebe-se na Figura 25 que após o número de épocas 20, existe uma diminuição no erro de treinamento, enquanto que o erro de validação aumenta, caracterizando o *overtraining* nas épocas posteriores. Sendo assim foram definidas 20 iterações, como o número ideal de iterações.

As precisões dos reconhecimentos de cada um dos 4 regimes de fluxo no leito de jorro pelo modelo MN-2, para os bancos de dados utilizados nas diferentes etapas de construção do modelo de rede neural estão descritas na Figura 26, dados pela matriz de confusão entre as classes.

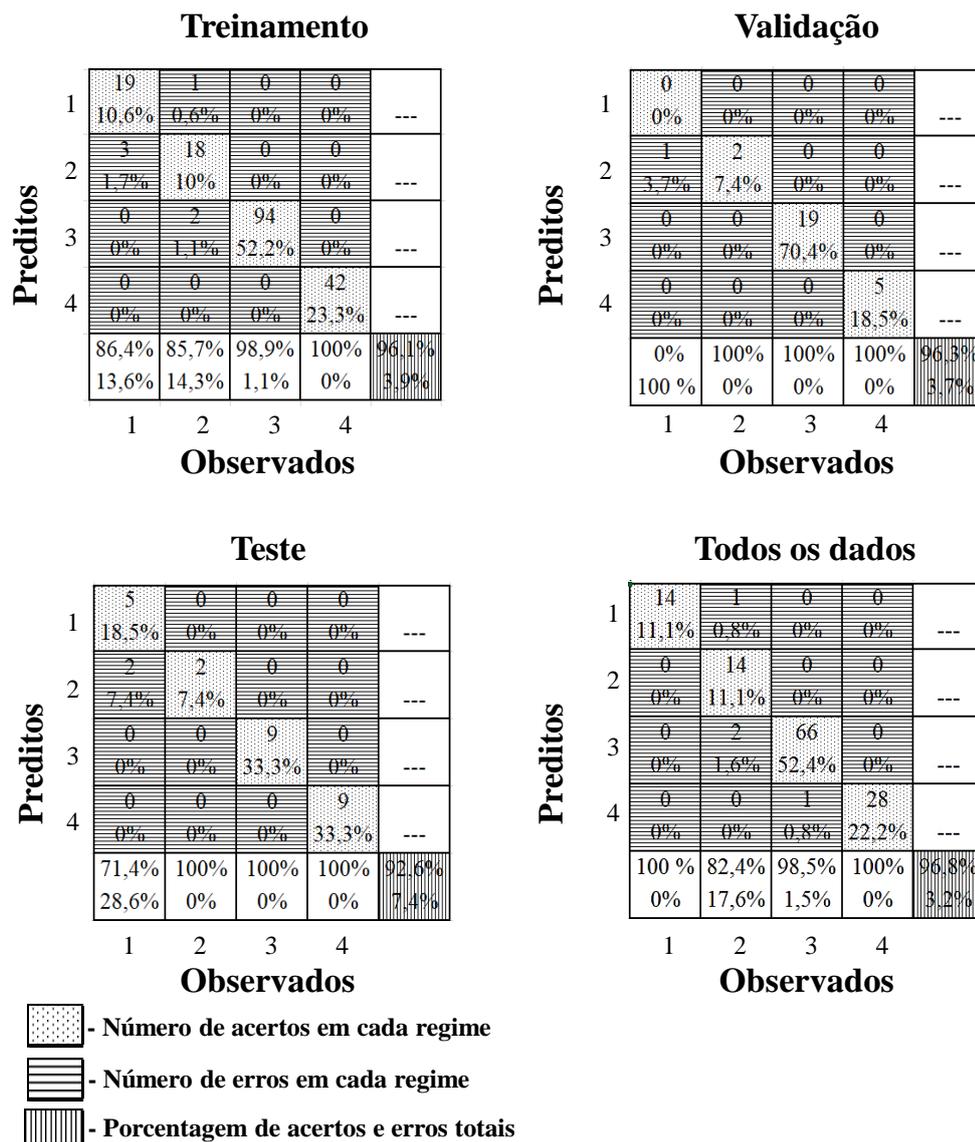


Figura 26: Matriz de confusão apresentada pelo modelo neural MN-2 para os bancos de dados de treinamento, validação, teste e total para cada regime de fluxo (1- leito fixo, 2- fluidização, 3- leito de jorro e 4- *slugging*).

Na Figura 26 está apresentada a matriz de confusão gerada utilizando os 4 bancos distintos (treinamento, validação, teste e todos os dados juntos), a diagonal principal de cada matriz, apresenta o número de acertos feitos em cada regime (1- leito fixo, 2- fluidização, 3- leito de jorro, 4- *slugging*), e a soma de todas as porcentagens de acertos para os 4 regimes é apresentada na última linha e última coluna (quadrado com listas verticais). Nesse quadrado, a porcentagem acima, é a de acertos, enquanto que o número abaixo, apresenta a porcentagem de classificações esquecidas ou erradas. Os quadrados acima e abaixo da diagonal principal (quadrado com listas horizontais) mostra o número de classificações feitas de modo incorreta

pelo modelo MN-2. Percebe-se que para os bancos de dados de treinamento, validação, teste e todos os dados, a rede neural obteve uma eficiência de reconhecimento para os diversos regimes de fluxo de cerca de 96,8%, 96,3%, 92,6% e 96,1% respectivamente.

4.2.4.3. Equações do modelo MN-2 e análise da importância relativa das variáveis pela RNA

A partir da definição da arquitetura da RNA para predição dos regimes de fluxo no leito de jorro, foi então determinada a matriz de pesos e bias (Tabela 15) para cada camada da rede e que possibilitam o desenvolvimento do modelo MN-2.

Tabela 15: Matriz dos pesos e bias para o modelo neural MN-2.

W_e	Variáveis de entrada			Bias (B_1)	W_s				Bias (B_2)
					Variáveis de saída				
	A	A_r	u_{ar}		Leito fixo	Fluidização	Leito de jorro	Slugging	
1	-0,49	-5,71	-0,17	0,70	-4,10	4,03	0,60	-0,29	1,07
2	-5,54	-3,75	4,78	3,16	-3,35	-2,07	3,57	1,36	0,87
3	-11,45	-3,87	-1,78	-12,5	-3,24	-5,78	-5,55	16,55	-3,27
4	4,32	5,92	2,94	-1,51	1,20	3,57	-3,79	-1,37	0,47

Onde: W_e são os pesos das conexões entre os neurônios da camada de entrada e os da camada intermediária e W_s são os pesos das conexões entre os neurônios da camada intermediária e os da camada de saída. Através das equações 54, 55, 56 e 57 é possível simular a resposta da rede e prever o regime fluidodinâmico.

$$Leito\ fixo = \frac{e^{\left(\frac{2}{1+e^{-2(62,85 \cdot A+55,64 \cdot A_r-6,07 \cdot u_{ar}+25,266)}}-1\right)+1,07}}{e^{\left(\frac{2}{1+e^{-2(-21,72 \cdot A-9,53 \cdot A_r-38,49 \cdot u_{ar}+376,55)}}-1\right)-0,86}} \quad (54)$$

$$Fluidização = \frac{e^{\left(\frac{2}{1+e^{-2(91,16 \cdot A+28,23 \cdot Ar+10,23 \cdot u_{ar}+63,3)}}-1\right)+0,87}}{e^{\left(\frac{2}{1+e^{-2(-21,72 \cdot A-9,53 \cdot Ar-38,49 \cdot u_{ar}+376,55)}}-1\right)-0,86}} \quad (55)$$

$$Leito de jorro = \frac{e^{\left(\frac{2}{1+e^{-2(27,07 \cdot A-17,8 \cdot Ar-15,71 \cdot u_{ar}+86,89)}}-1\right)-3,27}}{e^{\left(\frac{2}{1+e^{-2(-21,72 \cdot A-9,53 \cdot Ar-38,49 \cdot u_{ar}+376,55)}}-1\right)-0,86}} \quad (56)$$

$$Slugging = \frac{e^{\left(\frac{2}{1+e^{-2(-202,8 \cdot A-75,6 \cdot Ar-26,94 \cdot u_{ar}+201,1)}}-1\right)+0,47}}{e^{\left(\frac{2}{1+e^{-2(-21,72 \cdot A-9,53 \cdot Ar-38,49 \cdot u_{ar}+376,55)}}-1\right)-0,86}} \quad (57)$$

Onde A , refere-se ao parâmetro de *Littman*, Ar ao número de Arquimedes e u_{ar} a velocidade do ar em metros por segundo.

A Tabela 16 apresenta a importância relativa de cada variável de entrada, para cada variável de saída do modelo neural MN-2 utilizando o método dos pesos sinápticos.

Tabela 16: Importância relativa de cada variável de entrada para cada variável de saída do modelo neural (MN-2) obtido pelo método dos pesos sinápticos.

Variáveis dependentes (resposta)	Importância relativa das variáveis independentes (entrada) (%)		
	A	Ar	u_{ar}
Leito fixo	50,46%	44,67%	4,87%
Fluidização	70,33%	21,78%	7,89%
Leito de jorro	44,69%	29,38%	25,93%
Slugging	66,43%	24,75%	8,82%

Verifica-se na Tabela 16 que a variável com maior importância relativa para a detecção dos regimes de fluxo foi o parâmetro de *Littman* (A). Essa maior importância relativa ao parâmetro de *Littman* pode ser explicado pelo fato de que pequenas variações nesse parâmetro

pode ser um indicio de grandes oscilações e instabilidade nos regimes de fluxo durante a secagem em secadores do tipo leito de jorro.

4.2.4.4. Aplicação do modelo MN-2 para predição dos regimes de fluxo durante a secagem

Após a definição da arquitetura ideal da rede para o modelo MN-2, foram realizados testes na rede para verificar a eficiência de predição do modelo quanto a variação dos regimes de fluxo em diferentes condições experimentais da secagem.

As Figuras 27 (a), (b) e (c) ilustram as comparações feitas entre os regimes de fluxo observados experimentalmente e os preditos pelo modelo MN-2 para diferentes condições experimentais ao longo do tempo de secagem. Os marcadores representam os regimes preditos pela rede neural, enquanto que a linha vertical tracejada representa os limites para cada regime observados experimentalmente.

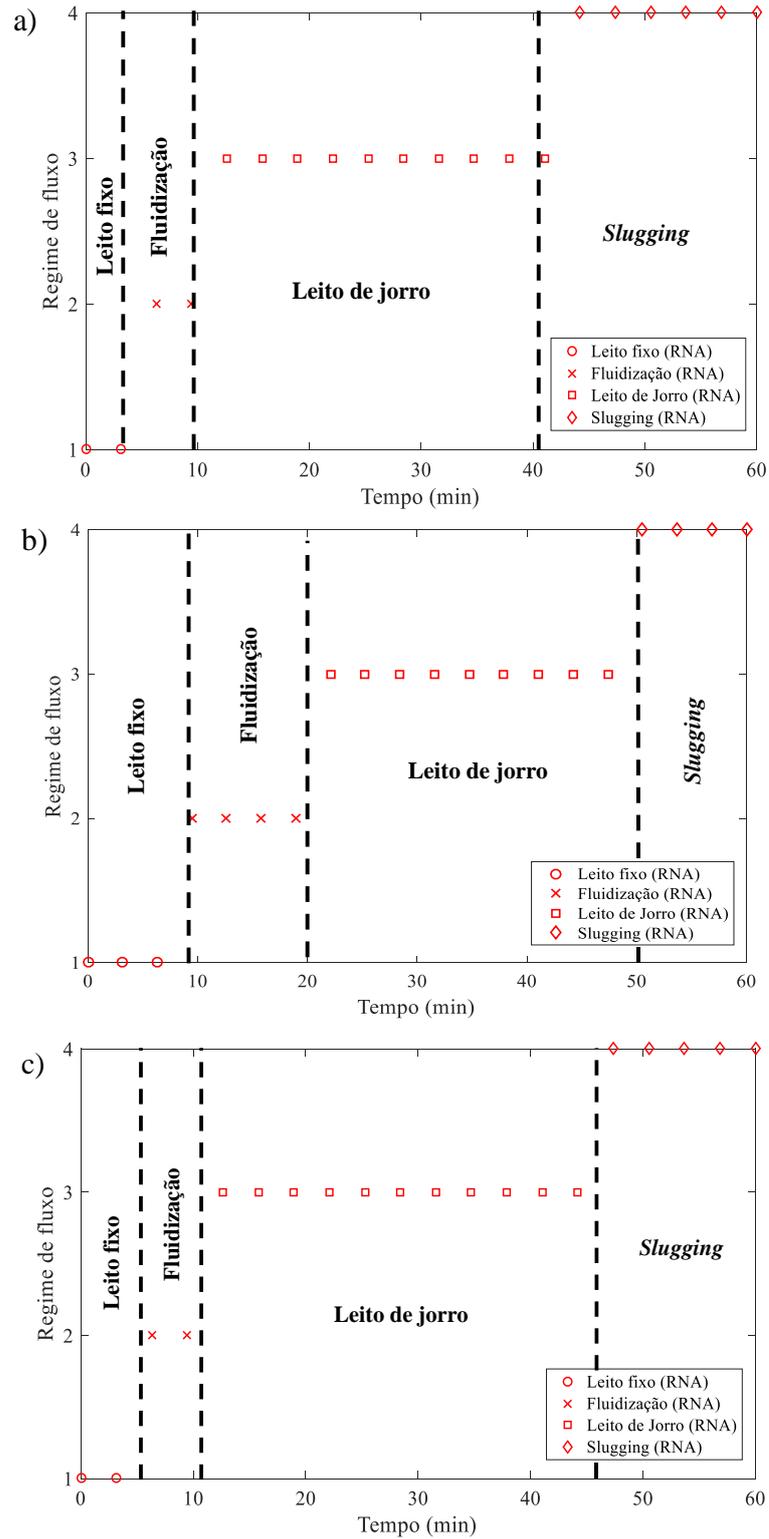


Figura 27: Comparação entre os regimes preditos pelo modelo MN-2 e os regimes observados durante a secagem com condições experimentais distintas: a) ($H_i = 0,09 \text{ m}$, $U_i = 1,5$ e $u_{ar} = 3,5 \text{ m.s}^{-1}$), b) ($H_i = 0,12 \text{ m}$, $U_i = 1,5$ e $u_{ar} = 3,5 \text{ m.s}^{-1}$) e c) ($H_i = 0,105 \text{ m}$, $U_i = 1,05$ e $u_{ar} = 3,2 \text{ m.s}^{-1}$).

É possível observar na Figura 27 que o erro de classificação dos regimes pela rede para tais ensaios foi eficiente, uma vez que a predição para todos os regimes de fluxo foi acima de 80%, conforme apresentado na Tabela 17.

Tabela 17: Precisão do modelo MN-2 na predição dos diferentes regimes de fluxo durante a secagem dos pedaços de goiaba em leito de jorro.

Regimes de fluxo	Precisão de reconhecimento (%)
Leito fixo	86,36
Fluidização	85,71
Leito de jorro	98,94
<i>Slugging</i>	100,00

Na Tabela 17, nota-se que os erros de reconhecimento dos regimes foram baixos. Os regimes que mostraram os maiores erros de classificação foram o leito fixo e a fluidização. O que pode explicar maiores erros de classificação nesses regimes, é que esses estão em condições próximas as regiões de transição. O mesmo comportamento de classificação foi encontrado no trabalho de XIE *et al.* (2004), onde os autores relatam maiores erros de classificação para os regimes *plug flow* e agitação forte, considerados pelos autores como regimes de transição.

Nos trabalhos de WANG *et al.* (2011) e WANG *et al.* (2012), no qual os autores utilizaram sinais de flutuação de pressão obtidos no leito de jorro para o reconhecimento de regimes de fluxo, onde foram desenvolvidos modelos baseados nas redes neurais recorrentes de Elman e máquina de vetores de suporte, relatando que obtiveram uma precisão entre 80 % e 90% para os regimes adotados. Sendo assim, o modelo desenvolvido neste trabalho obteve eficiência de predição dos regimes de fluxo maior do que os modelos desenvolvidos pelos autores supracitados. Vale destacar também que o modelo foi eficiente na predição dos regimes mesmo quando testado em condições experimentais diferentes.

Dessa forma, fica comprovado que os modelos baseados em redes neurais artificiais consistem em um método eficiente de reconhecimento de regimes de fluxo em secadores do tipo leito de jorro, utilizando como variáveis de entrada parâmetros operacionais do leito (u_{ar}) e parâmetros fluidodinâmicos do secador (A, Ar), podendo então ser aplicado em equipamentos de escala industrial. Além de que, esse método de reconhecimento pode servir para aplicação não somente em sistema gás-sólido, mas também em sistemas gás-líquido ou mesmo sistemas multifásicos (gás-sólido-líquido) (XIE *et al.*, 2004; WANG *et al.*, 2012).

A aplicação desses modelos a secadores industriais pode aumentar a eficiência do processo de secagem, levando-se em conta que diversos eventos, como por exemplo a formação de zonas mortas no leito, podem causar mudanças bruscas no comportamento fluidodinâmico do leito, causando assim oscilações nos regimes e mudanças na estabilidade desses durante o processo de secagem, levando então a diminuição da eficiência do processo.

4.2.5. Teste estatístico dos modelos desenvolvidos (MN-1 e MN-2)

A partir dos resultados obtidos na simulação dos modelos MN-1 e MN-2 foram realizados testes estatísticos utilizando o teste-F, afim de aferir se existem diferenças significativas entre a variância dos dados preditos pelas redes neurais e dos dados obtidos experimentalmente.

A Tabela 18 mostra os resultados obtidos no teste F para as respostas do modelo MN-1 (densidade, diâmetro das partículas e umidade) e para a resposta do modelo MN-2 (regimes fluidodinâmicos) ao nível de significância (α) de 5%.

Tabela 18: Resultados do teste estatístico F obtido para as quatro variáveis de saída dos modelos MN-1 e MN-2 em comparação com os valores reais.

Modelos	Variáveis resposta	Média		F _{calculado}	F _{tabelado}
		Real			
MN-1	Massa Específica (Kg.m ⁻³)	Real	931,48	1,0233	1,2795
		Predito	932,09		
	Diâmetro da partícula	Real	7,11x10 ⁻³	1,0331	1,2795
		Predito	7,12x10 ⁻³		
	Umidade (b.s)	Real	0,352	1,0233	1,2795
		Predito	0,356		
MN-2	Regime de fluxo	Real	2,87	1,0412	1,2795
		Predito	2,9		

Diante dos resultados do teste F apresentados na Tabela 18, a um nível de significância de 5%, pode-se constatar que não existe diferença significativa entre as médias dos dados preditos pelo modelo e as médias dos dados reais, devido aos valores de F_{calculado} serem menores que o valor de F_{tabelado} para as quatro variáveis de saída dos modelos (densidade, diâmetro da partícula, umidade e regime de fluxo). Sendo assim, pode-se concluir que os modelos neurais

MN-1 e MN-2 apresentaram uma performance satisfatória na predição dos dados reais, sendo o processo de secagem dos pedaços de goiaba bem representados pelos modelos em questão.

4.3. Análise da simulação numérica da transferência de calor e massa na secagem dos cubos de goiaba em leito de jorro

Foi adotado nesse trabalho uma estratégia de modelo híbrido (fenomenológico/Rede Neural) para descrever o comportamento térmico e mássico da secagem dos pedaços de goiaba em leito de jorro a partir da simulação, conforme descrito no tópico 3.6. Nessa estratégia de modelagem, foi utilizado o modelo MN-1 para predição da variação das propriedades físicas dos pedaços de goiaba ao longo da secagem, permitindo assim ao modelo fenomenológico levar em consideração os efeitos da variação dessas propriedades e o encolhimento dos pedaços de goiaba durante a secagem.

Nas Figuras 28 (a) e (b) estão apresentados os perfis de temperatura do leito de partículas de goiaba e do ar de secagem na saída do secador (°C) em diferentes condições experimentais ao longo de todo tempo de secagem (3600 segundos), obtidas através da realização do balanço de energia no secador, conforme as Equações 25 e 26 apresentadas no tópico 3.6

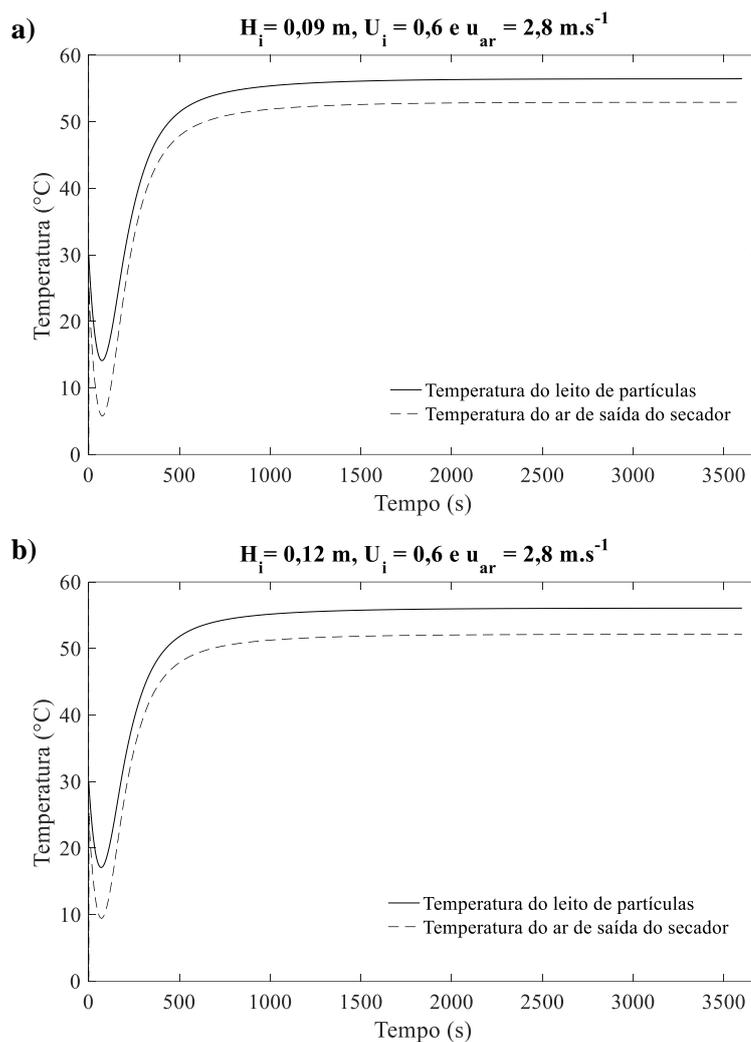


Figura 28: Simulação da temperatura do leito de partículas e do ar na saída do secador nas condições experimentais: a) ($H_i = 0,09 \text{ m}, U_i = 0,6 \text{ e } u_{\text{ar}} = 2,8 \text{ m.s}^{-1}$) e b) ($H_i = 0,12 \text{ m}, U_i = 0,6 \text{ e } u_{\text{ar}} = 2,8 \text{ m.s}^{-1}$) a partir do modelo híbrido

Pode-se observar nas Figura 28 (a) e (b), uma queda brusca nos instantes iniciais no valor da temperatura das partículas, assim como observado nos perfis de temperatura do ar. Essa queda na temperatura é justificada por uma instabilidade inicial na resolução do modelo, bem como a grande quantidade de energia utilizada para a intensiva evaporação nos primeiros instantes de secagem. A influência do termo relativo a energia gasta na evaporação da água pode ser comprovado visualmente na Figura 29, na qual apresenta-se a simulação dos perfis de temperatura desprezando a energia necessária para evaporação da umidade presente nas partículas na Equação do modelo referente ao balanço de energia. Nessa figura destaca-se a ausência da queda das temperaturas observada na Figura 28 (a) e (b) nos instantes iniciais da

secagem que é causada pela grande quantidade de energia requerida para a intensa evaporação da umidade presente nas partículas.

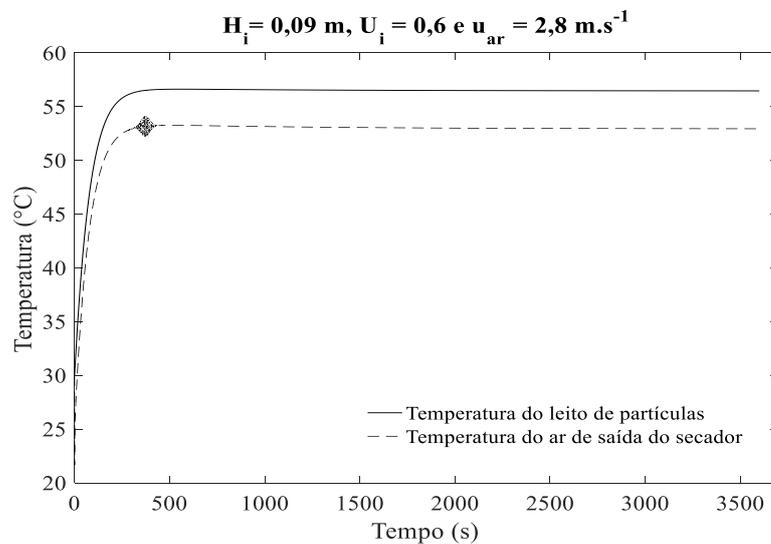


Figura 29: Simulação da temperatura do leito de partículas e do ar na saída do secador, desprezando o termo de energia necessária para evaporação: ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹).

Percebe-se também nas Figuras 28 (a) e (b) que para os perfis de variação da temperatura das partículas em cerca de 1000 s de simulação, ou cerca de 17 min do tempo de secagem as partículas existem uma estabilização da temperatura, que é intermediária entre a temperatura do ar na entrada e na saída devido as perdas de calor ao ambiente (55°C). Esse rápido aumento da temperatura das partículas está associado ao fato do alto grau de mistura no leito observado, o que proporciona o aumento dos coeficientes de transferência de calor entre as partículas e o ar de secagem (h_p).

Ainda nas Figuras 28 (a) e (b), identifica-se que a temperatura do ar na saída é menor que a temperatura das partículas ao longo de toda a secagem. Esse fenômeno pode ser explicado pelo fato do leito de partículas trocar calor com o ar de secagem logo na entrada do leito, onde nessa condição o ar ainda se encontra na temperatura mais elevada (60°C). Conforme o ar atravessa o leito de partículas entrega a esta energia para evaporar a umidade e aquece-las, simultaneamente o ar perde energia para o ambiente externo (Q_p).

A Figura 30, mostra a simulação dos perfis de temperatura se considerássemos um sistema isolado termicamente, ou seja, sem perdas de calor para o ambiente externo, afim de observar o efeito dessa variável no processo de secagem. O que pode-se analisar é que quando desprezamos as perdas de calor os perfis de temperatura do ar e das partículas se equilibram em

cerca de 1000 s do tempo de simulação em cerca de 60°C (temperatura do ar na entrada do secador), o que não foi observado nas simulações das Figura 28 (a) e (b) nas quais são considerados as perdas de calor no processo. Sendo assim, o calor perdido tem grande influência na temperatura do ar na saída do secador e na evolução das temperaturas das partículas.

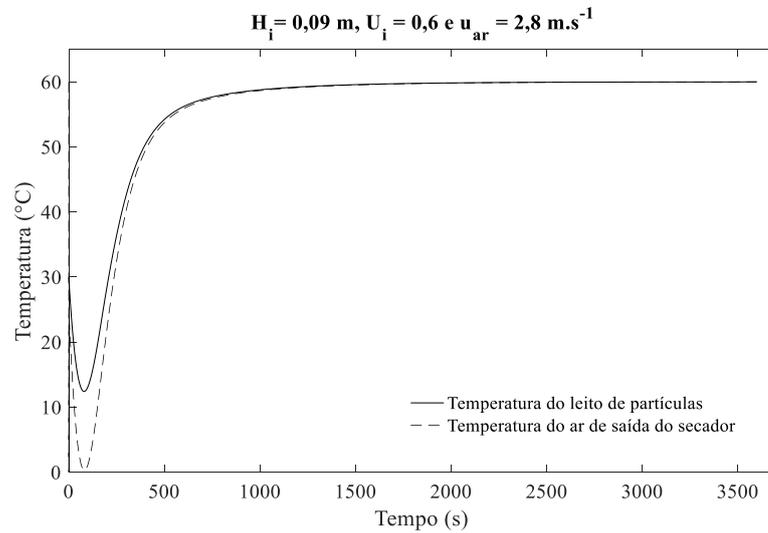


Figura 30: Simulação da temperatura do leito de partículas e do ar na saída do secador, desprezando as perdas de calor ao ambiente na condição experimental: ($H_i = 0,09$ m, $U_i = 0,6$ e $u_{ar} = 2,8$ m.s⁻¹).

Nas Figuras 31 (a) e (b) são apresentados os perfis de umidade absoluta do ar na saída do secador (W_s) e a umidade em base seca dos pedaços de goiaba ($U_{(b.s.)}$) ao longo da secagem para diferentes condições experimentais obtidos através do balanço de massa no secador.

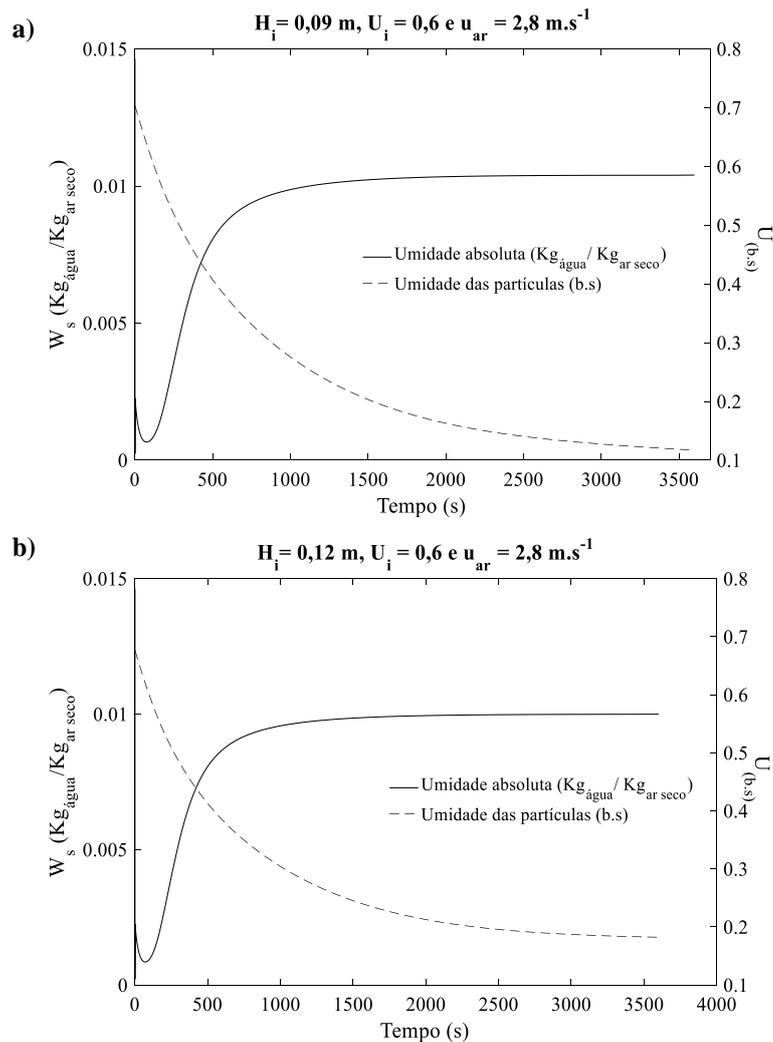


Figura 31: Simulação dos perfis de umidade absoluta do ar de secagem na saída do secador e da umidade das partículas (b.s) nas condições experimentais: a) ($H_i = 0,09 \text{ m}$, $U_i = 0,6$ e $u_{ar} = 2,8 \text{ m.s}^{-1}$) e b) ($H_i = 0,12 \text{ m}$, $U_i = 0,6$ e $u_{ar} = 2,8 \text{ m.s}^{-1}$) a partir do modelo híbrido.

Observa-se na simulação dos perfis da umidade das partículas, que o tempo necessário para evaporar grande parte da umidade presente nos pedaços de goiaba, coincide com o tempo gasto para a temperatura das partículas atingirem o seu valor de equilíbrio (cerca de 17 min), como pode ser observado nas Figuras 28 a) e b). Tal comportamento também foi observado por ROBBINS & FRYER (2003), na simulação da secagem de cevada. Esse fenômeno está ligado ao fato de que a medida que a temperatura das partículas aumenta, intensifica-se também a difusão interna da água presente, que por sua vez fornecem umidade à superfície dessas partículas. Desta forma, a difusão é o mecanismo predominante no processo de perda de umidade, e o teor de umidade superficial dos pedaços de goiaba encontram-se em equilíbrio com a umidade do ar presente no leito de jorro.

CONCLUSÕES

No presente trabalho foi realizado a modelagem matemática do processo de secagem de pedaços de goiaba em um secador do tipo leito de jorro, através do desenvolvimento de modelos neurais e híbrido (fenomenológico/Rede Neural). Os dados necessários para o desenvolvimento dos modelos foram obtidos através da realização de experimentos laboratoriais.

Os modelos neurais desenvolvidos foram utilizados para a predição da variação das propriedades físicas dos pedaços de goiaba (ρ , d_p e $U_{(b.s)}$), modelo MN-1, e para a predição da variação dos regimes de fluxo durante a secagem em leito de jorro, modelo MN-2. Ambos os modelos foram otimizados através do algoritmo de otimização de enxame de partículas (*Particle Swarm Optimization*) e utilizaram como algoritmo de treinamento o *Backpropagation Levenberg- Marquardt*

Através de equações advinda do balanço de massa e energia do secador e posterior acoplamento do modelo neural MN-1 para ajustar parâmetros das equações, foi desenvolvido um modelo híbrido neural, o qual teve o objetivo de descrever os fenômenos de transferência de calor e massa envolvidos no processo de secagem em questão.

Para o modelo MN-1, a arquitetura do modelo otimizada para a predição das propriedades físicas da goiaba foi composta por 7 neurônios na camada escondida (4-7-3), função de transferência tangente hiperbólica entre a camada de entrada e a camada intermediária e função linear entre a camada intermediária e a camada de saída, e taxa de aprendizagem igual a 0,56. Com essa configuração o modelo MN-1 apresentou uma precisa e efetiva predição das propriedades físicas dos pedaços de goiaba, com satisfatórios valores de MSE (0,004), RMSE (0,066) e R^2 (0,99).

No modelo de predição dos regimes de fluxo, denominado MN-2, a arquitetura da rede neural otimizada foi composta por: 4 neurônios na camada intermediária (3-4-4), função de transferência tangente hiperbólica e *Softmax* entre a camada de entrada e a camada intermediária e entre a camada intermediária e a camada de saída do modelo respectivamente, e taxa de aprendizagem igual a 0,24. A partir dessa configuração o modelo apresentou precisão de reconhecimento dos regimes de fluxo maiores que 80%.

Foi verificado através da comparação entre os índices de desempenho obtidos para os modelos neurais (MN-1 e MN-2), com os obtidos por modelos já publicados na literatura, que os modelos desenvolvidos no trabalho atual obtiveram índices de desempenho satisfatórios. Através então do teste F, foi comprovado que tais modelos neurais representam bem o processo de secagem dos pedaços de goiaba em leito de jorro, tanto com relação a predição das propriedades físicas do material, quanto com relação ao reconhecimento dos regimes de fluxo.

Ao que se refere ao modelo híbrido, foi possível observar que o modelo foi capaz de descrever os fenômenos de transferência de calor e massa envolvidos no processo de secagem dos pedaços de goiaba em leito de jorro. Observando-se que o leito de partículas atinge rapidamente o equilíbrio térmico, sendo então este fenômeno relacionado ao auto grau de mistura no leito que por sua vez proporciona a obtenção de elevadas taxas de transferência de calor entre o ar e as partículas, já para a temperatura do ar na saída do secador o calor perdido por esse durante o processo tem grande influência na sua variação. Para os fenômenos de transferência de massa foi observado que o mecanismo responsável por controlar a perda de umidade das partículas é a difusão interna da água.

Tendo em vista o desempenho satisfatório dos modelos neurais e híbrido desenvolvidos, é possível concluir que as técnicas de modelagem utilizadas conseguiram descrever as características dinâmicas do processo de secagem de pedaços de goiaba em leito de jorro, levando em consideração a deformabilidade das partículas durante esse processo. Com isso os modelos propostos nesse trabalho, podem auxiliar no desenvolvimento de projetos de novos secadores, bem como de sistemas de controle para esses, afim de aumentar a eficiência do processo.

Sugestões para trabalhos futuros:

- Realizar a validação do modelo híbrido através de ensaios no leito de jorro na secagem dos pedaços de goiaba;
- Realizar a secagem de outros tipos de frutas e legumes que possam apresentar durante o processo de secagem deformabilidade, afim de ampliar o banco de dados para construção dos modelos neurais;
- Realizar o controle preditivo das variáveis operacionais de um secador do tipo leito de jorro durante o processo de secagem de partículas deformáveis, utilizando as técnicas de modelagem desenvolvidas;

REFERÊNCIAS BIBLIOGRÁFICAS

- AGHBASHLO, M.; HOSSEINPOUR, S.; MUJUMDAR, A. S. Application of Artificial Neural Networks (ANNs) in Drying Technology: A Comprehensive Review. *Drying Technology*, v. 33, n. 12, p. 1397–1462, 2015.
- AGHBASHLO, M.; KIANMEHR, M. H.; NAZGHELICHI, T.; RAFIEE, S. Optimization of an Artificial Neural Network Topology for Predicting Drying Kinetics of Carrot Cubes Using Combined Response Surface and Genetic Algorithm. *Drying Technology*, v. 29, n. 7, p. 770–779, 2011.
- ALMEIDA, M. M. Secagem de fatias e pedaços cúbicos de goiaba (*Pisidium guajava* L). Tese de Doutorado em Engenharia de Processos- Centro de Ciências e Tecnologia, Universidade Federal de Campina Grande, Campina Grande, Paraíba, 2004.
- ALMEIDA, M. M.; SILVA, O. S.; ALSINA, O. L. S. Fluid-Dynamic Study of Deformable Materials in Spouted-Bed Dryer. *Drying Technology*, v. 24, n. 4, p. 499–508, 2006.
- ALMEIDA, M. M.; SILVA, O. S.; ALSINA, O. L. S. Fluid-Dynamic Study of Deformable Materials in Spouted-Bed Dryer. p. 499–508, 2006.
- AMEER, K.; BAE, S.; JO, Y.; LEE, H.; AMEER, A.; KWON, J. Optimization of microwave-assisted extraction of total extract, stevioside and rebaudioside-A from *Stevia rebaudiana* (Bertoni) leaves, using response surface methodology (RSM) and artificial neural network (ANN) modelling. *Food Chemistry*, 2017.
- ARAÚJO, W. D.; GONELI, A. L. D.; SOUZA, C. M. A.; GONÇALVES, A. A.; VILHASANTI, H. C. B. Propriedades físicas dos grãos de amendoim durante a secagem. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 18, n. 3, p. 279–286, 2014.
- BARROZO, M. A. S. Transferência de calor e massa entre o ar e sementes de soja em leito deslizante e escoamento cruzado. Tese de Doutorado em Engenharia Química – Centro de Ciências Exatas e Tecnológicas, Universidade Federal de São Carlos, São Paulo, 1995.
- BEZERRA, C. V.; AMANTE, E. R.; OLIVEIRA, D. C. RODIGUES, A. M. C.; SILVA, L. H. M. Green banana (*Musa cavendishii*) flour obtained in spouted bed - Effect of drying on physico-chemical, functional and morphological characteristics of the starch. *Industrial Crops and Products*, v. 41, n. 1, p. 241–249, 2013.
- BIALOBRZEWSKI, I.; ZIELINSKA, M.; MUJUNDAR, A.; MARKOWSKI, M. Heat and mass

- transfer during drying of a bed of shrinking particles - Simulation for carrot cubes dried in a spout-fluidized-bed drier. *International Journal of Heat and Mass Transfer*, v. 51, n. 19–20, p. 4704–4716, 2008.
- CARVALHO, M. R. DE. Uma Análise da Otimização de Redes Neurais MLP por Enxames de Partículas. Dissertação de Mestrado- Centro de Informática, Universidade Federal de Pernambuco, 2007.
- CHATTERJEE, A.; ADUSUMILLI, R. S. S.; DESHMUKH, A. V. Wall-to-bed heat transfer characteristics of spout-fluid beds. *The Canadian Journal of Chemical Engineering*, v. 61, n. 3, p. 390–397, 1983.
- CHURCHILL, S. W.; CHU, H. H. S. Correlating equations for laminar and turbulent free convection from a vertical plate. *International Journal of Heat and Mass Transfer*, v. 18, p. 1323–1329, 1975.
- COSTA, A. B. S. Secagem convectiva de folhas de hortelã: análise baseada no ajuste de correlações empíricas, superfícies de resposta e redes neurais. Dissertação de Mestrado- Programa de Pós Graduação em Engenharia Química, Universidade Federal de São Carlos, São Carlos- SP, 2013.
- CUBILLOS, F.A.; ALVAREZ, P. I.; PINTO, J. C.; LIMA, E. L. Hybrid-neural modeling for particulate solid drying processes. *Powder Technology*, v. 87, p. 153–160, 1996.
- CUBILLOS, F. A.; VYHMEISTER, E.; ACUÑA, G.; ALVAREZ, P. I. Rotary Dryer Control Using a Grey-Box Neural Model Scheme Rotary Dryer Control Using a Grey-Box Neural Model Scheme. *Drying Technology*:, v. 29, n. July 2013, p. 1820–1827, 2011.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, v. 2, p. 303–314, 1989.
- DAS, G.; KUMAR, P.; KUMARI, S. Expert Systems with Applications Artificial Neural Network trained by Particle Swarm Optimization for non-linear channel equalization. *Expert Systems With Applications*, 2013.
- DIAS, R. A. L. Extração de fenóis e taninos totais da casca da romã (*Punica granatum*, L.) Efeito da secagem em leito de jorro sobre a extração de fenóis e taninos totais da casca da romã (*Punica granatum*, L.). Tese de Doutorado- Departamento de Engenharia Química, Universidade Federal de Campina Grande, 2015.
- EPSTEIN, N.; GRACE, J. R. Spouted and Spout-Fluid Beds. Cambridge University Press, Cambridge, 2011.: [s.n.].

- FATHI, M.; MOHEBBI, M.; RAZAVI, S. M. A. Application of Fractal Theory for Prediction of Shrinkage of Dried Kiwifruit Using Artificial Neural Network and Genetic Algorithm. *Drying Technology*, v. 29, n. 8, p. 918–925, 2011.
- FOUST, ALAN S.; CLAMP, C. W. *Princípios de Operações Unitárias*. 2ª ed. LTC, 1982.
- FREIRE, J. T.; FREIRE, F. B.; FERREIRA, M. C.; NASCIMENTO, B. S. A Hybrid Lumped Parameter/Neural Network Model for Spouted Bed Drying of Pastes with Inert Particles. *Drying Technology*, v. 30, n. 11–12, p. 1342–1353, 2012.
- GHAHDARIJANI, A. M.; HORMOZI, F.; ASL, A. H. Convective heat transfer and pressure drop study on nanofluids in double-walled reactor by developing an optimal multilayer perceptron artificial neural network. *International Communications in Heat and Mass Transfer*, v. 84, p. 11–19, 2017.
- HAGAN, M. T. Training Feedforward Networks with the Marquardt Algorithm. *IEEE Trans. on Neural Networks*, v. 5, p. 989–993, 1994.
- HAYKIN, S. *Redes Neurais – Princípios e Prática*. 2ª ed. Porto Alegre, Bookman, 2001.
- HUSSAIN, M. A.; SHAFIUR RAHMAN, M.; NG, C. W. Prediction of pores formation (porosity) in foods during drying: Generic models by the use of hybrid neural network. *Journal of Food Engineering*, v. 51, n. 3, p. 239–248, 2002.
- IBGE. *Produção agrícola municipal – Culturas temporárias e permanentes*. v. 40, p. 99, 2013.
- KAHYAOGLU, L. N.; SAHIN, S.; SUMNU, G. Physical properties of parboiled wheat and bulgur produced using spouted bed and microwave assisted spouted bed drying. *Journal of Food Engineering*, v. 98, n. 2, p. 159–169, 2010.
- KALANI, H.; SARDARABADI, M.; PASSANDIDEH-FARD, M. Using artificial neural network models and particle swarm optimization for manner prediction of a photovoltaic thermal nanofluid based collector. *Applied Thermal Engineering*, v. 113, p. 1170–1177, 2017.
- KARIMI, F.; RAFIEE, S.; TAHERI- GARAVAND, A.; KARIMI, M. Optimization of an air drying process for Artemisia absinthium leaves using response surface and artificial neural network models. *Journal of the Taiwan Institute of Chemical Engineers*, v. 43, n. 1, p. 29–39, 2012.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. Proc. IEEE Intl. Conf. on Neural Network. Perth, Australia: 1995
- KERDPIBOON, S.; KERR, W. L.; DEVAHASTIN, S. Neural network prediction of physical

- property changes of dried carrot as a function of fractal dimension and moisture content. *Food Research International*, v. 39, n. 10, p. 1110–1118, 2006.
- KHASHEI, M.; BIJARI, M. Expert Systems with Applications An artificial neural network (p , d , q) model for timeseries forecasting. *Expert Systems With Applications*, v. 37, n. 1, p. 479–489, 2010.
- KHAYET, M.; COJOCARU, C;ESSALHI, M. . Artificial neural network modeling and response surface methodology of desalination by reverse osmosis. *Journal of Membrane*, v. 368, p. 202–214, 2011.
- KIM, K. B.; KANG, H. Y.; YOON, D. J.; CHOI, M. Y. Pattern classification of acoustic emission signals during wood drying by principal component analysis and artificial neural network. *Materials Science and Engineering*, v. 297–300, p. 1962–1967, 2005.
- KOÇ, B.; EREN, I.; KAYMAK ERTEKIN, F. Modelling bulk density, porosity and shrinkage of quince during drying: The effect of drying method. *Journal of Food Engineering*, v. 85, n. 3, p. 340–349, 2008.
- KUMAR, K. V.; PORKODI, K.; RONDON, R. L. A.; ROCHA, F. Neural Network Modeling and Simulation of the Solid/Liquid Activated Carbon Adsorption Process. *Industrial & Engineering Chemistry Research*, v. 47, n. 2, p. 486–490, 2007.
- KUNDU, P.; PAUL, V.; KUMAR, V.; MISHRA, I. M. Formulation development, modeling and optimization of emulsification process using evolving RSM coupled hybrid ANN-GA framework. *Chemical Engineering Research and Design*, v. 104, p. 773–790, 2015.
- LI, M.; HUANG, X.; LIU, H.; LIU, B.; WU, Y.; XIONG, A.; DONG, T. Prediction of gas solubility in polymers by back propagation artificial neural network based on self-adaptive particle swarm optimization algorithm and chaos theory. *Fluid Phase Equilibria*, v. 356, p. 11–17, 2013.
- LIMA, A. C. C.; ROCHA, S. C. S. Bean Drying in Fixed, Spouted and Spout-Fluid Beds: a Comparison and Empirical Modeling. *Drying Technology*, v. 16, n. 9–10, p. 1881–1901, 1998.
- LINKO, P.; ZHU, Y. . Neural network modelling for real-time variable estimation and prediction in the control of glucoamylase fermentation. *Process Biochemistry*, v. 27, p. 275–283, 1992.
- LITTMAN, H.; SLIVA, D. E. Gas-particle heat transfer coefficients in packed beds at low Reynolds number. *Heat Transfer*, v. 7, 1970.
- MARMO, L. Low temperature drying of pomace in spout and spout-fluid beds. *Journal of Food*

- Engineering*, v. 79, p. 1179–1190, 2007.
- MARTINS, M.; METTE, F.; MACEDO, G. utilização de redes neurais artificiais para a estimação dos preços da Petrobrás PN na Bovespa. *ConTexto*, v. 8, 2008.
- MATHUR, K. B. , GICHLER, P. E. A Technique of contacting gases with coarse solid particles. *AIChE Journal*, p. 157–171, 1955.
- MATHUR, K. B.; EPSTEIN, N. Spouted Beds. New York, Academic Press, 1955.
- MEDEIROS, M. DE F. D. DE. Influência da composição química dos materiais no desempenho do processo de secagem de polpas de frutas em leito de jorro. Tese de Doutorado -Faculdade de Engenharia Química, Universidade Estadual de Campinas, 2001.
- MENEZES, M. M. Ajuste de Parâmetros de Controladores Suplementares (POD) Através de Redes Neurais Artificiais em Dispositivos FACTS TCSC e SSSC. Universidade Estadual Paulista, Ilha Solteira - SP, 2010.
- MIHAJLOVIC, T.; IBRIC, S.; MLADENOVIC, A. Application of Design of Experiments and Multilayer Perceptron Neural Network in Optimization of the Spray-Drying Process. *Drying Technology*, v. 29, n. 14, p. 1638–1647, 2011.
- NASCIMENTO, B. S.; FREIRE, B. F.; FREIRE, J. T. Neuronal and grey modelling of milk drying in spouted bed. *Canadian Journal of Chemical Engineering*, v. 91, n. 11, p. 1815–1821, 2013.
- NASCIMENTO, B. S.; FREIRE, F.; FREIRE, J. T. Neuronal and grey modelling of milk drying in spouted bed. *Canadian Journal of Chemical Engineering*, v. 91, n. 11, p. 1815–1821, 2013.
- NASCIMENTO, B. S. Análise do efeito da composição química na secagem de pasta em leito de jorro. Tese de Doutorado- Universidade Federal de São Carlos, São Carlos-SP, 2013.
- NASR, N.; HAFEZ, H.; EL, M. H.; NAKHLA, G. Application of artificial neural networks for modeling of biohydrogen production. *International Journal of Hydrogen Energy*, v. 38, n. 8, p. 3189–3195, 2013.
- NIAMNUY, C.; DEVAHASTIN, S.; SOPONRONNARIT, S.; VIJAYA RAGHAVAN, G. S. Modeling coupled transport phenomena and mechanical deformation of shrimp during drying in a jet spouted bed dryer. *Chemical Engineering Science*, v. 63, n. 22, p. 5503–5512, 2008.
- OLDEN, J. D.; JACKSON, D. A. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, v. 154, n. 1, p. 135–150, 2002.

- OLIVEIRA, G. R.; SANTOS, A. V.; LIMA, A. S.; SOARES, C. M. F.; LEITE, M. S. Neural modeling in adsorption column of cholesterol-removal efficiency from milk. *LWT - Food Science and Technology*, v. 64, n. 2, p. 632–638, 2015.
- OLIVEIRA, M.J.R.; SIMÕES, M.J.S.; SASSI, C. R. R. Fitoterapia no Sistema de Saúde Pública (SUS) no Estado de São Paulo, Brasil. *Revista Brasileira de Plantas Mediciniais*, v. 8, p. 39–41, 2006.
- OLIVEIRA, W. P.; LIM, C. J.; GRACE, J. R. Evaluation of Flow Regimes in a Semi-Cylindrical Spouted Bed Through Statistical , Mutual Information , Spectral and Hurst’s Analysis. *The Canadian Journal of Chemical Engineering*, v. 86, n. June, 2008.
- PSICHOGIOS, D.C.; UNGAR, L. H. No Title A hybrid neural network - first principles approach to process modeling. *American Institute of Chemical Engineering Journal*, v. 38, p. 1499, 1992.
- QUEIROZ, V. A. V. Teores de Na, K, Ca, Mg, Fe, Zn, Cu e Se em frutas consumidas na região Norte Fluminense. Dissertação de mestrado - Universidade Estadual do Norte Fluminense Darcy Ribeiro, Macaé-RJ, 2004.
- ROBBINS, P. T.; FRYER, P. J. The spouted-bed roasting of barley: Development of a predictive model for moisture and temperature. *Journal of Food Engineering*, v. 59, n. 2–3, p. 199–208, 2003.
- ROCHA, S. C. S.; SOUZA, J. S.; ALSINA, O. L. S.; MEDEIROS, M. F. D. Drying of Tropical Fruit Pulps: Spouted Bed Process Optimization as a Function of Pulp Composition. *Drying Technology*, v. 29, n. 13, p. 1587–1599, 2011.
- RUSSO, P.; ADILETTA, G.; MATTEO, M. DI. The influence of drying air temperature on the physical properties of dried and rehydrated eggplant. *Food and Bioproducts Processing*, v. 91, n. 3, p. 249–256, 2013.
- SILVA, B G; FILETI, A M F; TARANTO, O. P. Drying of Brazilian Pepper-Tree Fruits (*Schinus terebinthifolius* Raddi): Development of Classical Models and Artificial Neural Network Approach. *Chemical Engineering Communications*, v. 202, n. 8, p. 1089–1097, 2015.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais artificiais: para engenharia e ciências aplicadas. São Paulo: Artiliber, 2010.
- SILVA COSTA, A. B.; FREIRE, F. B.; FREIRE, J. T.; FERREIRA, M. C. Modelling drying pastes in vibrofluidized bed with inert particles. *Chemical Engineering and Processing: Process Intensification*, v. 103, p. 1–11, 2016.

- SITTON, J. D.; ZEINALI, Y.; STORY, B. A. Rapid soil classification using artificial neural networks for use in constructing compressed earth blocks. *Construction and Building Materials*, v. 138, p. 214–221, 2017.
- SOUZA, G. F. M. V.; MIRANDA, R. F.; LOBATO, F. S.; BARROZO, M. A. S. Simultaneous heat and mass transfer in a fixed bed dryer. *Applied Thermal Engineering*, v. 90, p. 38–44, 2015.
- STRUMILLO, C.; KUDRA, T. Drying: principles applications and design. 1^a ed. Gordon and Breach Science Publishers, 1987.
- SUNPHORKA, S.; CHALERMSINSUWAN, B.; PIUMSOMBOON, P. Artificial neural network model for the prediction of kinetic parameters of biomass pyrolysis from its constituents. *Fuel*, v. 193, p. 142–158, 2017.
- TAYLOR, P.; DOGAN, O. M.; FREITAS, L. A. P.; LIM, C. J.; GRACE, J. R.; LUO, B. Hydrodynamics and Stability of Slot-Rectangular Spouted Beds. Part I: Thin Bed. *Chemical Engineering Communications*, v. 181, n. September 2014, p. 225–242, 2000.
- TURAN, N. G.; OZGONENEL, O. Artificial neural network (ANN) approach for modeling Zn (II) adsorption from leachate using a new biosorbent. *Chemical Engineering Journal*, v. 173, p. 98–105, 2011.
- VIEIRA, A. S. Secagem de resíduo de goiaba em secador convectivo de bandejas : modelagem matemática e análise do processo. Tese de Doutorado - Departamento de Engenharia Qu; Universidade Federal do Rio Grande do Norte; Natal-RN, 2014.
- WANG, C.; ZHONG, Z.; LI, R.; JIA-QIANG, E. Recognition of the flow regimes in the spouted bed based on fuzzy c -means clustering. *Powder Technology*, v. 205, n. 1–3, p. 201–207, 2011.
- WANG, C.; ZHONG, Z.; E, J. Flow regime recognition in spouted bed based on recurrence plot method. *Powder Technology*, v. 219, p. 20–28, 2012.
- XIE, T.; GHIAASIAAN, S. M.; KARRILA, S. Artificial neural network approach for flow regime classification in gas-liquid-fiber flows based on frequency domain analysis of pressure signals. *Chemical Engineering Science*, v. 59, n. 11, p. 2241–2251, 2004.
- XU, J.; BAO, X.; WEI, W.; SHI, G.; SHEN, S. Statistical and frequency analysis of pressure fluctuations in spouted beds. *Powder Technology*, v. 140, p. 141–154, 2004.
- YOUSEFI, G.; EMAM-DJOMEH, Z.; OMID, M.; ASKARI, G. R. Prediction of Physicochemical Properties of Raspberry Dried by Microwave-Assisted Fluidized Bed Dryer Using Artificial

- Neural Network. *Drying Technology*, v. 32, n. January 2015, p. 4–12, 2014.
- ZEINALI, Y.; STORY, B. Structural Impairment Detection Using Deep Counter Propagation Neural Networks. *Procedia Engineering*, v. 145, p. 868–875, 2016.
- ZENDEHBOUDI, S.; AHMADI, M. A.; JAMES, L.; CHATZIS, I. Prediction of Condensate-to-Gas Ratio for Retrograde Gas Condensate Reservoirs Using Artificial Neural Network with Particle Swarm Optimization. *Energy & Fuels*, v. 26, p. 3432–3447, 2012.
- ZHONG, W.; CHEN, X.; GRACE, J. R.; EPSTEIN, N.; JIN, B. Intelligent prediction of minimum spouting velocity of spouted bed by back propagation neural network. *Powder Technology*, v. 247, p. 197–203, 2013.
- ZHONG, W.; CHEN, X.; GRACE, J. R.; EPSTEIN, N.; JIN, B. Intelligent prediction of minimum spouting velocity of spouted bed by back propagation neural network. *Powder Technology*, v. 247, p. 197–203, 2013.
- ZHONG, W.; CHEN, X.; ZHANG, M. Hydrodynamic characteristics of spout-fluid bed: Pressure drop and minimum spouting/spout-fluidizing velocity. *Chemical Engineering Journal*, v. 118, n. 1–2, p. 37–46, 2006.
- ZIELINSKA, M.; MARKOWSKI, M. Drying Behavior of Carrots Dried in a Spout–Fluidized Bed Dryer. *Drying Technology*, v. 25, n. 1, p. 261–270, 2007.
- ZORZETTO, L. F. M.; MACIEL FILHO, R.; WOLF-MACIEL, M. R. Process modelling development through artificial neural networks and hybrid models. *Computers and Chemical Engineering*, v. 24, p. 1355, 2000.

