



THAÍS SERRA MARTINS

**UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS NA
MODELAGEM DAS CINÉTICAS DE SECAGEM DA CASCA
DE CAMARÃO**

São Luís
2018

THAÍS SERRA MARTINS

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA
MODELAGEM DAS CINÉTICAS DE SECAGEM DA CASCA
DE CAMARÃO**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Química do Centro de Ciências Exatas e Tecnologia da Universidade Federal do Maranhão, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Química.

Orientador: Prof. Dr. Harvey Alexander Villa Vélez

São Luís
2018

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Martins, Thaís Serra.

Utilização de redes neurais artificiais na modelagem das cinéticas de secagem da casca de camarão / Thaís Serra Martins. - 2018.

50 f.

Orientador(a): Harvey Alexander Villa Vélez.

Monografia (Graduação) - Curso de Engenharia Química, Universidade Federal do Maranhão, Centro de Ciências Exatas e Tecnologia, São Luís, 2018.

1. Cascas de camarão. 2. Cinética de secagem. 3. Redes neurais artificiais. I. Villa Vélez, Harvey Alexander. II. Título.

BANCA EXAMINADORA:

Prof. Dr. HARVEY ALEXANDER VILLA VÉLEZ
Orientador – COEQ/CCET/UFMA

Prof^a. Dr^a. AUDIRENE AMORIM SANTANA
COEQ/CCET/UFMA

Prof. Dr. WENDELL FERREIRA DE LA SALLES
DETEQI/CCET/UFMA

11 de Julho de 2018

Dedico este trabalho a Deus, aos meus pais Marinilde e Luiz (*in memoriam*), a minha irmã Laís e ao meu namorado Jamilson.

AGRADECIMENTOS

Acima de tudo agradeço a Deus, pela sua infinita bondade e por aliviar meu coração durante minhas orações, renovando o sentimento de que vale a pena prosseguir.

A minha mãe Marinilde, que sempre deu seu máximo para que não faltasse amor e respeito na nossa família. Por não medir esforços para que eu e minha irmã tivéssemos uma boa educação e por ser a maior incentivadora dos nossos sonhos. Mãe, você é minha razão!

A memória do meu pai Luíz, que quando em vida, sempre acreditou na educação como instrumento transformador, por isso sempre torceu e apoiou para que suas filhas ingressassem na Universidade. Pai, eu te amo!

A minha irmã Laís, que sempre esteve ao meu lado, principalmente nos momentos difíceis, encorajando e fazendo-me sentir que tudo ia dar certo.

Ao meu namorado Jamilson, por seu amor, carinho, companheirismo e por sempre me compreender quando não pude estar presente.

Ao meu orientador, Professor Harvey Alexander Villa Vélez, pela orientação, conselhos, confiança e disponibilidade que tornaram possível a realização deste trabalho.

Aos Professores, Audirene Amorim Santana e Wendell Ferreira de La Salles, por aceitarem o convite de participarem da banca examinadora. A vocês, meu muito obrigada!

Agradeço também, aos demais professores do curso de Engenharia Química e do Departamento de Tecnologia, por todo aprendizado.

A minha amiga Roberta, que esteve presente nos momentos bons e difíceis. Seu apoio foi de suma importância ao longo dessa jornada.

Aos demais amigos que fiz durante esses cinco anos de graduação, em especial Paulo, Marcos, Thiago, Vanessa, Danielle e Adriana. Vou sempre lembrar de vocês com muito carinho!

“Quanto mais conscientes do que somos, fazemos e podemos, muito mais próximos estaremos da realização para qual fomos projetados.”

Pe. Fábio de Melo

MARTINS, T. S. **Utilização de redes neurais artificiais na modelagem das cinéticas de secagem da casca de camarão**. 2018. 50 f. Trabalho de Conclusão de Curso de Engenharia Química do Centro de Ciências Exatas e Tecnologia da Universidade Federal do Maranhão, São Luís, 2018.

RESUMO

Arelado ao desenvolvimento da aquicultura no Brasil, surgem novos desafios em torno dos impactos negativos gerados ao ambiente, tendo em vista o aumento da quantidade de resíduos, que, muitas vezes, não possuem uma destinação adequada. Como rejeitos provenientes da carcinicultura, tem-se as cascas de camarão, que são materiais riquíssimos em quitina e carbonato de cálcio. Eles possuem inúmeras aplicabilidades na agricultura, biomateriais e nas indústrias alimentícia, farmacêutica e de cosmético. O objetivo do presente trabalho foi aplicar o método de regressão não linear por redes neurais artificiais na cinética de secagem da casca de camarão. As cinéticas das cascas *in natura* e com o sistema espumante foram realizadas utilizando um desidratador de alimentos nas temperaturas de 30, 45 e 60 °C. A umidade do material diminuiu com o incremento de tempo para todas as temperaturas estudadas. Na cinética da casca de camarão *in natura*, tanto na rede do tipo *feed-forward* quanto a *cascade-forward* apresentaram boa precisão, com valores de R^2_{adj} iguais a 0,998 e MRE inferiores a 4 %. Para ambas arquiteturas, a função de transferência *tansig* com seis neurônios foi a que apresentou melhor ajuste em relação às outras funções estudadas. Já para a cinética da casca de camarão em espuma, os melhores resultados para as redes *feed-forward* e *cascade-forward* foram com cinco neurônios, cujas funções de transferências foram *softmax* e *logsig*, respectivamente, com valores de R^2_{adj} iguais a 0,997 e MRE um pouco superior a 12 %.

Palavras-chave: Cascas de camarão. Cinética de secagem. Redes neurais artificiais.

MARTINS, T. S. **Utilization of artificial neural network to modeling drying kinetics of shrimp shell**. 2018. 50 f. Graduate Work (Graduate in Chemical Engineering) - Curso de Engenharia do Centro de Ciências Exatas e Tecnologia da Universidade Federal do Maranhão, São Luís, 2018.

ABSTRACT

Linked to the development of aquaculture in Brazil, new challenges arise around negative impacts generated to the environment, in view of the increase amount of waste, which often do not have an appropriate destination. Wastes from the shrimp farming, produces shrimp shells, that are very rich in chitin and calcium carbonate. They have various applications in agriculture, biomaterials, food, pharmaceutical and cosmetic industries. The objective of the present work was to apply to the nonlinear regression method by artificial neural networks in the drying kinetics of shrimp shell. Both in natura and foaming system drying kinetics were made with a food dehydrator at temperatures of 30, 45 and 60 °C. The moisture content of the material decreased with increasing time for all temperatures studied. In the in natura shrimp shell drying kinetics, the feed-forward and cascade-forward networks present good fitting, with R^2_{adj} equal to 0,998 and MRE of less than 4 %. For both architectures, the transfer function tansig with six neurons was the best fitting in relation to the other functions studied. For foam-mat drying kinetics of shrimp shell, the best results for feed-forward and cascade-forward networks were with five neurons, whose transfer function were softmax and logsig, respectively, with R^2_{adj} equal to 0,997 and MRE a little more than 12 %.

Keywords: Shrimp shell. Drying kinetics. Artificial neural network.

LISTA DE FIGURAS

Figura 1: Arquitetura de redes neurais do tipo feed-forward de camada única.	11
Figura 2: Arquitetura de redes neurais do tipo feed-forward de camadas múltiplas.....	11
Figura 3: Arquitetura de redes recorrentes.	11
Figura 4: Curva da cinética de secagem da casca de camarão in natura para as temperaturas de 30 °C (■), 45 °C (▲) e 60 °C (●).	20
Figura 5: Curva da cinética de secagem da casca de camarão em espuma para as temperaturas de 30 °C (■), 45 °C (▲) e 60 °C (●).	20
Figura 6: Arquitetura dos melhores resultados das redes feed-forward (a) e cascade-forward (b) da cinética de secagem in natura da casca de camarão.	23
Figura 7: Arquitetura dos melhores resultados das redes feed-forward (a) e cascade-forward (b) da cinética de secagem em espuma da casca de camarão.	23
Figura 8: Análise residual entre as curvas de secagem experimental e calculada da casca de camarão in natura.	25
Figura 9: Análise residual entre as curvas de secagem experimental e calculada da casca de camarão em espuma.	26

LISTA DE TABELAS

Tabela 1: Composição físico-química da casca de camarão*.....	17
Tabela 2: Valores experimentais da cinética de secagem da casca de camarão in natura*.....	18
Tabela 3: Valores experimentais da cinética de secagem em espuma da casca de camarão*.....	19
Tabela 4: Melhores resultados e validação estatística das análises de redes neurais artificiais da cinética de secagem in natura da casca de camarão.....	21
Tabela 5: Melhores resultados e validação estatística das análises de redes neurais artificiais da cinética de secagem em espuma da casca de camarão.....	22

SUMÁRIO

AGRADECIMENTOS	v
RESUMO	vii
ABSTRACT	viii
LISTA DE FIGURAS	ix
LISTA DE TABELAS	x
1 INTRODUÇÃO	1
2 OBJETIVOS	3
2.1 Objetivo geral	3
2.2 Objetivos específicos	3
3 REVISÃO BIBLIOGRÁFICA	4
3.1 A aquicultura	4
3.2 O camarão	4
3.3 Quitina e quitosana	5
3.3.1 APLICAÇÃO DA QUITOSANA E QUITINA.....	6
3.4 Carbonato de cálcio	7
3.5 O processo de secagem	7
3.5.1 SECAGEM POR ESPUMA OU <i>FOAM-MAT DRYING</i>	8
3.6 Modelagem do processo de secagem por modelos de camada fina	8
3.7 Modelagem por redes neurais artificiais (RNA)	9
3.7.1 ASPECTOS GERAIS SOBRE RNA	9
3.7.2 ARQUITETURAS DE REDES NEURAI ARTIFICIAIS.....	10
3.7.3 APLICAÇÕES DE REDES NEURAI ARTIFICIAIS.....	12
4 MATERIAL E MÉTODOS	13
4.1 Material	13
4.2 Equipamentos utilizados	13
4.3 Caracterização química	13
4.4 Procedimento experimental	14
4.4.1 PREPARAÇÃO DA CASCA DE CAMARÃO	14
4.4.2 PREPARAÇÃO DO SISTEMA ESPUMANTE COM A CASCA DE CAMARÃO	
.....	14
4.4.3 CONSTRUÇÃO DAS CINÉTICAS DE SECAGEM EXPERIMENTAIS.....	14
4.5 Modelagem matemática	15

4.6 Análise estatística	16
5 RESULTADOS E DISCUSSÃO	17
5.1 Caracterização química	17
5.2 Cinética de secagem	17
5.3 Modelagem com redes neurais artificiais	21
6 CONCLUSÕES.....	27
REFERÊNCIAS	28
APÊNDICE A – CASCAS DE CAMARÃO UTILIZADAS NA ANÁLISE FÍSICO-QUÍMICA	33
APÊNDICE B – CINÉTICAS DE SECAGEM DA CASCA DE CAMARÃO	34
ANEXO A – PROGRAMAÇÃO NO MATLAB PARA MODELAGEM POR REDES NEURAS ARTIFICIAIS	35

1 INTRODUÇÃO

A aquicultura se destaca como uma das atividades agropecuárias que mais cresce em todo o mundo, contribuindo para a expansão do comércio de espécies de grande valor, tais como peixes e camarões, e de valor inferior, como por exemplo, as tilápias (FAO, 2014; SEBRAE, 2015). No contexto mundial, a carcinicultura marinha tem se sobressaído frente a outros tipos de cultivos, no qual, entre os anos de 1977 e 2007, a sua produção aumentou expressivamente, passando de 3 % para 51 % (NATORI et al., 2011; FAO, 2009). No que se refere ao Brasil, a produção aquícola deve-se, principalmente, ao cultivo de camarão na região Nordeste.

Com o crescimento da produção de camarões, surgem os problemas ligados ao volume de resíduos gerados, tendo em vista que esse alimento é constituído, na sua maioria, por parte não comestíveis, tais como cabeças, caudas e cascas. A partir do conhecimento de que tais rejeitos são compostos por quitina, proteínas, carbonato de cálcio e pigmentos, tem sido cada vez mais estudadas maneiras de reaproveitá-los, gerando produtos de valor agregado para diferentes áreas de aplicações, e conseqüentemente, minimizando as agressões ao ambiente (BESSA-JUNIOR; GONÇALVES, 2013; CRAVEIRO et al., 2004).

De modo geral, a secagem é empregada a fim de garantir maior estabilidade dos produtos para que possam ser armazenados durante longos períodos de tempo até seu processamento. Além disso, ela possibilita obter maior facilidade de manejo e redução de custo com transporte. Sendo assim, a aplicação desse método para reutilização ou tratamento de resíduos tem sido amplamente investigados (HONORATO, 2006; FERNANDES, 2009).

Ligado a avaliação da cinética do processo de secagem, está o desenvolvimento de modelos matemáticos que melhoram a modelagem cinética em estudo. A utilização de modelagens adequadas pode gerar resultados rápidos, precisos e, por vezes, inesperados, o que possibilita a geração de informações valiosas para a solução ou investigação de determinado fenômeno ainda pouco explorado (FÁVERO et al., 2009). Além disso, elas permitem fazer previsões, facilitar as tomadas de decisões, estimular novas ideias e técnicas experimentais, e preencher lacunas onde existem falta de dados experimentais (BASSANEZI, 2011).

Nesse contexto, ressalta-se a modelagem por redes neurais artificiais (RNA), que desde seu ressurgimento em 1980 até os dias atuais, passaram por grandes transformações (BRAGA et al., 2007). O atrativo principal da solução de problemas por meio de RNA's deve-se a sua estrutura paralelamente distribuída, a sua capacidade de aprender através de exemplos e generalizar a informação aprendida (HAYKIN, 2001; BRAGA et al., 2007). Dessa forma, as aplicações das redes neurais artificiais permeiam por diversas áreas do conhecimento. Embora

tenha aumentado o interesse pelo estudo de RNA, há poucos registros sobre a sua aplicação em cinéticas de secagem, o que ratifica a importância desse trabalho.

2 OBJETIVOS

2.1 Objetivo geral

Aplicar o método de regressão não linear por redes neurais artificiais na modelagem das cinéticas de secagem da casca de camarão provenientes de feiras livres da cidade de São Luís/MA.

2.2 Objetivos específicos

- Aprender os conceitos básicos, funcionamento e aplicações das redes neurais artificiais;
- Determinar a composição centesimal da casca de camarão;
- Construir as cinéticas de secagem da casca de camarão em diferentes temperaturas;
- Modelar as cinéticas de secagem através de modelos obtidos por redes neurais artificiais.

3 REVISÃO BIBLIOGRÁFICA

3.1 A aquicultura

A disponibilidade hídrica, dimensão territorial e diversidade climática são alguns dos fatores que deixam o Brasil em lugar de destaque frente a outros países no que se refere ao desenvolvimento da aquicultura. Quando comparada a outras atividades, como, por exemplo, a pesca extrativa, a produção aquícola mundial se sobressai devido a sua capacidade de responder bem ao aumento da população e conseqüentemente, à crescente demanda por proteína animal, no qual apresenta um crescimento de 43% em relação a outras atividades, tais como pesca, avicultura, suinocultura e bovinocultura. Nos últimos 12 anos, a taxa de crescimento da aquicultura brasileira foi de 56 % e a dimensão econômica do negócio aproximou-se de 3 bilhões de reais ao ano. Em relação aos segmentos produtivos, em 2013, a carcinicultura foi responsável por cerca de 13 % da produção nacional, ficando atrás apenas da piscicultura com 82 % (SEBRAE, 2015).

Atrelado ao desenvolvimento da aquicultura, surgem novos desafios em torno dos impactos negativos decorrentes do aumento dos resíduos gerados. No que tange à indústria pesqueira, tem-se como rejeitos as cascas e cabeças de camarão, que contém de 15 a 20 % de quitina, 25 a 40 % de proteínas e 40 a 55 % de carbonato de cálcio (MATHUR; NARANG, 1990; ASSIS et al., 2008). Na sua maioria, esses coprodutos são descartados diretamente nos solos, mares ou rios (ASSIS et al., 2008). Partindo disso, nota-se a relevância do reaproveitamento desses resíduos sólidos através de alternativas que atribuam valor agregado aos seus coprodutos.

3.2 O camarão

O camarão é um crustáceo pertencente à ordem decapoda. Seu corpo tende a ser cilíndrico ou lateralmente comprimido, com abdome bem desenvolvido. O cefalotórax geralmente é portador de um rostro serrilhado em forma de quilha, as pernas são delgadas e seu exoesqueleto é fino e flexível (BARNES, 1984).

Os principais camarões marinhos costeiros de interesse econômico do Brasil, pertencem às famílias Penaeidae e Solenoceridae. Na primeira, estão alocados os gêneros *Farfantepenaeus* e *Litopenaeus* em que são inseridas as espécies brasileiras. As espécies comumente encontradas na costa norte brasileira são: *Farfantepenaeus subtilis* Pérez Farfantes e *Farfantepenaeus*

brasiliensis Latreille, sendo que o primeiro é responsável por mais 95 % da produção industrial (DIAS-NETO, 2010). Além dessas, estão presentes as espécies *Xiphopenaeus kroyeri* Heller e *Lithopenaeus schmitti* Burkenroad, conhecidos como camarão-de-sete-barbas e camarão-branco, respectivamente. Este último tem maior recorrência na área de Tutóia-MA (DIAS-NETO, 2010; DIAS-NETO; DAMASCENO; ISAAC, 1992). Monteles et al. (2010) relataram a presença das espécies *Xiphopenaeus kroyeri* e *Litopenaeus schmitti*, conhecidos respectivamente como camarão piticaia e camarão branco, no município de Primeira Cruz do Estado do Maranhão.

Segundo os dados de 2013, o Nordeste destacou-se com 29 % da produção aquícola nacional, devido principalmente ao cultivo de camarões. Dentre os estados nordestinos, o Maranhão situou-se em terceiro lugar, com aproximadamente 17 mil toneladas, sendo as duas primeiras posições ocupadas pelo Ceará e Rio Grande do Norte, respectivamente (SEBRAE, 2015). Embora esses resultados sejam positivos, há muito a ser explorado quanto à carcinicultura marinha, pois a região nordeste possui 99 % da área de cultivo de camarões no País, no entanto, apenas 2,5 % dos hectares disponíveis são utilizados (ROCHA, 2017).

3.3 Quitina e quitosana

A quitina é um copolímero abundante na natureza, constituído em grande parte por meros de N-acetil-D-glicosamina e resíduos de D-glicosamina. Como polissacarídeo apresenta função estrutural e protetora, podendo ser encontrada no exoesqueleto de vários crustáceos, tais como caranguejos e camarões, além de outros organismos. Ela é altamente hidrofóbica e insolúvel na maioria dos solventes orgânicos. Já a sua forma desacetilada, quitosana, apresenta solubilidade em soluções diluídas de ácidos orgânicos e inorgânicos. Além dessas características, o que as diferenciam são as massas moleculares médias e os graus médios de acetilação, sendo assim, para um grau médio de acetilação até 40 %, considera-se quitosana, caso contrário é considerada quitina (RINAUDO, 2006; FELIPE et al., 2017; KUMAR; MAJETI, 2000).

Como a quitina do exoesqueleto de crustáceos encontra-se associada às proteínas, lipídeos, materiais inorgânicos e pigmentos, são necessárias algumas etapas para sua extração. São elas: desmineralização, para retirada, principalmente, de CaCO_3 ; desproteinização, para remoção de proteínas; e despigmentação, para retirada da astaxantina (ASSIS et al., 2008; CAMPANA-FILHO et al., 2007). A quitosana é posteriormente obtida pelo processo de desacetilação da quitina, que pode ser realizada por meio da ação química, através da hidrólise

alcalina dos grupos acetoamidos; ou enzimática, através das quitinases. A primeira rota citada é a mais frequente para se obter a quitosana (CAMPANA-FILHO et al., 2007; FELIPE et al., 2017).

A hidrólise alcalina é uma reação simples, contudo ela não ocorre de maneira homogênea e completa ao longo de todas as cadeias, podendo até ocorrer concomitantemente a despolimerização e reações colaterais. Tal fato acontece devido à estrutura semicristalina da quitina e da limitação ao acesso aos sítios reativos. Como resultado, tem-se copolímeros de composição e massa molecular variáveis (CAMPANA-FILHO et al., 2007).

Entre os países produtores da aquicultura, a China, a Tailândia e o Equador são os que possuem indústrias de quitina e quitosana bem estabelecidas. Estimativas apontam que em 2018 o mercado global de quitina poderá ser de 118 mil toneladas em termos de peso do produto (FAO, 2014).

3.3.1 APLICAÇÃO DA QUITOSANA E QUITINA

A quitosana possui um conjunto de propriedades, tais como capacidade de ser atóxica, bioativa, biocompatível, habilidades quelantes, emulsificante e antimicrobiana, que permitem uma ampla possibilidade de aplicações na agricultura, biomateriais, indústria alimentícia, farmacêutica e de cosmético. A sua versatilidade é ainda melhor, devido a possibilidade de sua preparação ser na forma de soluções de viscosidade controlada, géis, filmes, microesferas ou nanopartículas (ASSIS et al., 2008; CAMPANA-FILHO et al., 2007; FELIPE et al., 2017).

Na indústria de cosmético e de higiene pessoal, a quitosana é utilizada como esfoliante para a pele, tratamento de acne, hidratante capilar e creme dental; na agricultura como mecanismo defensivo e estimulante para o crescimento de plantas, revestimento de sementes, liberação de fertilizantes e nutrientes no solo; na indústria de alimentos como aditivo orgânico, embalagens ativas, agente antioxidante, emulsificante e estabilizante; e quando aplicada no tratamento de água e resíduos, ela é empregada como agente floculante para clarificar a água; na remoção de íons metálicos e redução de odores (ASSIS et al., 2008; RINAUDO, 2006; FELIPE et al., 2017).

A quitina se assemelha com a quitosana em muitas propriedades e aplicações. Ela pode ser utilizada para imobilizar enzimas, que na indústria de alimentos servem para clarificação de suco de frutas; no tratamento de poluentes industriais; como material para curativos de feridas e na liberação controlada de fármacos (RINAUDO, 2006; FELIPE et al., 2017).

3.4 Carbonato de cálcio

O carbonato de cálcio é um mineral inorgânico comumente encontrado no exoesqueleto de invertebrados para construção de estruturas rígidas. Nos crustáceos são requeridas maiores quantidades desse mineral, pois o exoesqueleto é trocado regularmente para permitir o aumento de tamanho corpóreo. Nesse caso, há uma contínua alternância entre reabsorção de cálcio do exoesqueleto antigo e a deposição no novo, como resultado, tem-se um metabolismo de cálcio mais ativo em crustáceos do que em outros invertebrados (GREENAWAY, 1985).

Assim como a quitosana, as nanopartículas de carbonato de cálcio têm um potencial significativo em aplicações biomédicas, incluindo remineralização de esmalte e terapias de câncer (RUDZINSKI et al., 2016; HE et al., 2008).

3.5 O processo de secagem

A secagem é um processo bastante utilizado na preservação de materiais biológicos, uma vez que diminui consideravelmente a atividade de água do material e reduz a atividade microbológica, permitindo que o mesmo possa ser armazenado por um período de tempo mais prolongado. Outra vantagem que merece ser destacada é a redução com o custo do transporte, haja vista a mudança na forma e diminuição do tamanho decorrentes da perda de água e aquecimento (GEANKOPLIS, 1998; MAYOR; SERENO, 2004).

Quando um sólido úmido é submetido à secagem, dois processos ocorrem simultaneamente: o primeiro é uma transferência de energia, principalmente na forma de calor, do ambiente circundante para evaporar a umidade da superfície; e o segundo é a transferência da umidade interna para a superfície do sólido e sua subsequente evaporação devido ao processo anterior. A taxa de secagem é governada pela velocidade na qual esses dois processos ocorrem. Os mecanismos de transferência de energia envolvidos podem ser por convecção, condução e/ou radiação (MUJUMDAR, 2006).

Através da cinética de secagem é que se estabelecem as equações de umidade em função do tempo para os diferentes períodos e taxas de secagem, possibilitando ainda a determinação do mecanismo predominante na transferência de massa do material para o fluido e as respectivas equações matemáticas correspondentes (FERREIRA, 2004; CASTRO, 2016). Além disso, o processo permite conhecer o comportamento do material ao longo do processo e a predição do tempo de secagem. Já a modelagem é fundamental para o desenvolvimento e a otimização dos

secadores, bem como a padronização do processo (VIGANÓ, 2012). Dessa forma, é cada vez mais importante o emprego de modelos matemáticos para descrição do processo.

3.5.1 SECAGEM POR ESPUMA OU *FOAM-MAT DRYING*

A secagem por espuma tem se destacado nos últimos anos devido à sua capacidade adicional de processar materiais difíceis de secar para gerar produtos com propriedades desejadas (KUDRA; RATTI, 2005). Ela aumenta a área de superfície disponível para secagem e dessa forma, os tempos de secagem são significativamente reduzidos. Outras vantagens desse método são as melhorias na qualidade do produto final, tendo em vista que a temperatura de secagem é inferior aos métodos de secagem convencionais, e na taxa de secagem (MUTHUKUMARAN, 2007).

Na secagem por espuma, uma mistura é batida para formar espumas estáveis, sendo posteriormente desidratados através de processos térmicos. Alguns agentes espumantes utilizados são: proteínas, gomas e vários emulsionantes, tais como monoestearato de glicerina, monoestearato de propilenoglicol e carboximetilcelulose (BRIGIDYR et al., 1977). Como agentes espumantes de proteína mais utilizados, citam-se a clara de ovo, gelatina, proteínas do leite como a caseína, a proteína do soro do leite e a proteína da soja (ZAYAS, 1997).

3.6 Modelagem do processo de secagem por modelos de camada fina

Os modelos de secagem de camada fina se encaixam principalmente em três categorias: teórico, semi-empírico e empírico (FORTES; OKOS, 1981). Os modelos teóricos levam em consideração os mecanismos de transferência em diferentes misturas e envolvem soluções de sistemas de equações linearmente independentes ou dependentes de transferência de calor e massa. Os modelos semi-empíricos geralmente são fundamentados na lei do resfriamento de Newton aplicados à transferência de massa e secagem isotérmica (ABALONE, 2006), eles requerem um tempo pequeno comparado aos modelos teóricos de camada fina e não precisam de suposições da geometria do alimento, de sua difusividade mássica e condutividade (PARRY, 1985). Os modelos empíricos produzem uma relação direta entre conteúdo de umidade e o tempo de secagem, negligenciando os fundamentos do processo de secagem (ABALONE, 2006) e seus parâmetros não tem significado físico, portanto, eles não podem dar uma visão clara e precisa dos importantes processos que ocorrem durante a secagem, embora possam descrever a curva de secagem para as condições do experimento (KEEY, 1972).

Vários modelos têm sido propostos para descrever a taxa de perda de umidade durante a secagem de camada fina de materiais biológicos (JAYAS et al., 1991), tais como os modelos de Lewis ou exponencial; Henderson-Pabis; Page e exponencial de dois termos. Esses estudos são fundamentais no desenvolvimento da modelagem e simulação de processos de secagem (KASHANINEJAD et al., 2007).

3.7 Modelagem por redes neurais artificiais (RNA)

3.7.1 ASPECTOS GERAIS SOBRE RNA

As redes neurais são uma tentativa de criar máquinas que funcionem de maneira semelhante ao cérebro humano, usando para isso componentes que se comportem como neurônios biológicos (PICTON, 2000). Desta forma, elas podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por diversas sinapses artificiais. Suas estruturas foram desenvolvidas a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano (SILVA et al., 2010).

De maneira geral, as RNA's podem ser divididas em três elementos, são eles: camada de entrada, responsável pelo recebimento dos dados, sinais, características ou medições advindas do meio externo; camada oculta, composta de neurônios, cuja função é extrair as características associadas ao processo a ser inferido; e camada de saída, também constituída de neurônios, sendo responsável pela produção e apresentação dos resultados finais da rede (SILVA et al., 2010).

As redes neurais artificiais podem representar processos não-lineares com estruturas complexas, podendo até fornecer melhores resultados que as correlações empíricas (HIMMELBLAU, 2008). Para sua aplicação não é necessário um conhecimento prévio das relações entre as variáveis sob investigação. Nas RNA's as entradas são usadas para calcular as respostas e compará-las com o padrão fornecido. Esse processo é realizado até que as entradas da rede estejam em bom acordo com os padrões a um determinado nível especificado de precisão (KARIMI et al., 2012).

Outra vantagem é que caso o processo sob análise se modifique, não é preciso determinar novos modelos ou regras, pois é possível que novos dados sejam adicionados e a rede neural pode ser treinada novamente. Quando comparada com a metodologia da superfície de resposta, as RNA's têm dificuldades em explicar a relação entre variáveis independentes e

dependentes. Em contraste, a superfície de resposta, plotada por gráficos tridimensionais, pode fornecer uma boa maneira de se visualizar as interações dos parâmetros para a análise do processo projetado (KARIMI et al., 2012).

3.7.2 ARQUITETURAS DE REDES NEURAIS ARTIFICIAIS


A arquitetura de uma rede neural artificial define a forma como os seus diversos neurônios estão arranjados uns em relação aos outros (SILVA et al., 2010). Essa maneira, na qual eles estão estruturados, está intimamente ligada ao algoritmo de aprendizagem usado para treinar a rede (HAYKIN, 2001). Em geral, considerando a disposição de seus neurônios, formas de interligação e a constituição de suas camadas, tem-se como principais arquiteturas as redes: *feed-forward* de camada simples, *feed-forward* de camadas múltiplas e recorrentes (SILVA et al., 2010).

Na rede *feed-forward* de camada simples (Figura 1) tem-se apenas uma camada de entrada e uma única camada de neurônios, que é a própria camada de saída, na qual o fluxo de informações segue sempre numa única direção. A quantidade de saídas nas redes pertencentes à arquitetura sempre coincidirá com o número de neurônios. Essas redes são tipicamente empregadas em problemas envolvendo classificação de padrões e filtragem linear (SILVA et al., 2010).

As redes *feed-forward* (Figura 2) de camadas múltiplas são constituídas de uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas. Esses neurônios têm como função intervir entre a entrada externa e a saída da rede de maneira útil (HAYKIN, 2001). Esses tipos de redes são aplicados na solução de problemas relacionados à aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, ao controle de processos, dentre outros (SILVA et al., 2010).


As redes recorrentes (Figura 3) se distingue de uma rede neural *feed-forward* por ter pelo menos um laço realimentando as saídas dos neurônios como sinais de entrada para outros neurônios (HAYKIN, 2001; SILVA et al., 2010). Através do processo de realimentação, são produzidas saídas atuais levando-se também em consideração os valores das saídas anteriores. Essas redes podem ser aplicadas em sistemas que variam com o tempo, como previsão de séries temporais, otimização e identificação de sistemas e controle de processos (SILVA et al., 2010).

Figura 1: Arquitetura de redes neurais do tipo *feed-forward* de camada única.



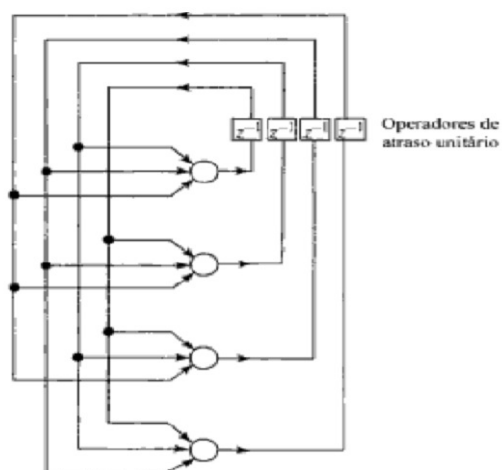
Fonte: Haykin (2001, p. 47).

Figura 2: Arquitetura de redes neurais do tipo *feed-forward* de camadas múltiplas.



Fonte: Haykin (2001, p. 48).

Figura 3: Arquitetura de redes recorrentes.



Fonte: Haykin (2001, p. 48).

3.7.3 APLICAÇÕES DE REDES NEURAIIS ARTIFICIAIS

As potencialidades das redes neurais artificiais permitem sua utilização em diversas áreas do conhecimento, tais como: na medicina, para classificação e predições de câncer baseado no perfil genético do indivíduo; na química, para obtenção de novos compostos poliméricos; na biologia, para identificação de espécies de morcegos a partir de seus sinais de ecolocalização emitidos durante os voos; e na farmácia, para auxiliar na elaboração de fórmulas (SILVA et al., 2010).

Dentro da área de secagem, pode-se destacar a utilização das redes neurais na predição da cinética de secagem da uva (KHAZAEI et al., 2013); da *Lasagnas angustifolia* L. (ABBASZADEH, et al., 2011); das maçãs (MENLIK; ÖZDEMIR; KIRMACI, 2010); de batata doce (SINGH; PANDEY, 2011); dos resíduos sólidos orgânicos (PERAZZINI; FREIRE; FREIRE, 2013) e das folhas de *Artemisia absinthium* (KARIMI et al., 2012).

4 MATERIAL E MÉTODOS

4.1 Material

As cascas de camarão foram obtidas de feiras livres da cidade de São Luís - Maranhão. Para preparar o sistema espumante foram utilizados a albumina (Salto's, São Paulo, Brasil), o amido de milho (Unilever, São Paulo, Brasil) e maltodextrina (Neonutri, Minas Gerais, Brasil).

4.2 Equipamentos utilizados

Os equipamentos utilizados foram: balança semi-analítica (modelo BL320H, Shimadzu, Japão); desidratador de alimentos (modelo PE 14, PardalTec, Brasil); termo-higrômetro (modelo 7664.01.0.00, Incoterm, China); liquidificador (modelo 4126, Oster, México); mixer (modelo FPSTHB2615R, Oster, USA), paquímetro (modelo Vis, Polônia); e estufa de secagem e esterilização (modelo 100/1000, Solab, Brasil).

4.3 Caracterização química

Resíduos de casca de camarão (Apêndice A) foram caracterizados quimicamente, em triplicata, de acordo com os métodos de análises da AOAC (2007) (Quadro 1). Os resultados são expressos com a média das triplicatas e seu desvio padrão.

Quadro 1. Métodos de análise para determinação da composição química dos resíduos de crustáceos *in natura*.

Análise	Número AOAC	Método	Técnica
Umidade	926.12	Secagem em estufa a vácuo	Determinação gravimétrica da água contida por diferença de peso
Proteína	920.152 e 955.04c	Micro-Kjeldahl	Desnaturação do material orgânico e determinação titulométrica (meio ácido) empregando o Fator F = 6.25
Cinza	900.02	Incineração por mufla	Determinação gravimétrica por diferença de peso
Lipídeos	945.16 e 963.15	Método de Soxhlet	Determinação gravimétrica do estrato etéreo seco por diferença de peso
Carboidratos totais		Indireto	Determinação pelo cálculo: Carboidratos totais = 100 – (Umidade + Proteína + Cinza + Lipídeos)

Fonte: Próprio Autor (2018).

4.4 Procedimento experimental

4.4.1 PREPARAÇÃO DA CASCA DE CAMARÃO

Inicialmente, as cascas de camarão passaram por um processo de limpeza, que consistiu na retirada manual de sujidades, lavagem com água corrente e escoamento da mesma. Posteriormente, foram colocadas em sacos plásticos limpos e armazenadas no freezer até as realizações das secagens e determinação do conteúdo de umidade, em que o material foi triturado no liquidificador.

4.4.2 PREPARAÇÃO DO SISTEMA ESPUMANTE COM A CASCA DE CAMARÃO

As proporções do sistema espumante foram determinadas a partir de estudos reológicos feitos anteriormente. Sendo assim, o mesmo foi preparado na proporção 4:2:1 (p/p) de albumina, amido de milho e maltodextrina, respectivamente. Com o auxílio do mixer, a albumina foi misturada com água destilada na proporção 1:3,75 (p/v), respectivamente, e batida durante 4,5 minutos, quando se formou o chamado ponto de neve. Em seguida foram adicionados e misturados, com o auxílio do fuê, o amido e a maltodextrina por mais 1,5 minuto. Feito isso, misturou-se a casca de camarão, por mais 1 minuto, na qual foi utilizada uma quantidade referente a 60% do peso do sistema preparado.

4.4.3 CONSTRUÇÃO DAS CINÉTICAS DE SECAGEM EXPERIMENTAIS

As cinéticas de secagem da casca de camarão foram realizadas *in natura* e com sistema espumante nas temperaturas de 30, 45 e 60 °C. Nesta última cinética, a mistura da casca com o sistema espumante foi devidamente pesada e colocada em quatro placas cilíndricas de alumínio, com diâmetro de 9,2 cm e altura de 2,5 cm. Com o auxílio do paquímetro, foram medidas as espessuras em diferentes posições de cada amostra. Posteriormente, as placas foram dispostas no centro do desidratador, no qual a temperatura foi previamente ajustada, e em intervalos de tempo pré-estabelecidos, foram medidos os pesos. Além disso, foram registradas a umidade relativa e a temperatura através do termo-higrômetro anteriormente instalado. Ao final da secagem, mediram-se novamente as espessuras de cada amostra. Já para a primeira cinética, as cascas foram pesadas e colocadas nas placas. Depois, procedeu-se de forma similar à secagem anteriormente descrita.

Para que os resultados das cinéticas de secagem fossem expressos em termos do conteúdo de água na base seca, b.s., determinaram-se as umidades iniciais das cascas *in natura* e em espuma, na qual foram pesadas aproximadamente 2,0 g de cada amostra, em triplicata. Em seguida foram aquecidas em estufa a 105 °C por 24 horas e posteriormente pesadas. A umidade foi determinada segundo a Equação 1:

$$W = \left(\frac{m_i - m_f}{m_i} \right) \cdot 100 \quad (1)$$

onde W é a porcentagem de umidade, em base úmida; m_i e m_f são, respectivamente, as massas inicial e final do material.

4.5 Modelagem matemática

O primeiro tratamento dos dados foi realizado no Excel 2016, no qual foram calculados os conteúdos de umidade em base seca e geradas as curvas cinéticas de secagem *in natura* e em espuma da casca de camarão. Além disso, neste trabalho foram utilizadas diferentes funções da biblioteca da *Statistic Toolbox* do *Matlab*® 7.1 (The Mathworks Inc., Natick, MA, USA), para modelar e simular as curvas da cinética de secagem da casca de camarão em diferentes temperaturas. Como modelo de ajuste, empregaram-se as redes neurais artificiais (RNA), nas quais foram consideradas as arquiteturas *feed-forward* e *cascade-forward* de redes de regressão com uma camada oculta. Assim, a função de treinamento de Levenberg-Marquardt (*trainlm*) e as funções de transferências: *tansig* (Equação 2), *logsig* (Equação 3), *softmax* (Equação 4) e *radbax* (Equação 5) foram avaliadas para cada arquitetura de rede (VILLA-VÉLEZ et al., 2015a). Os números de neurônios de camada oculta, que variaram de cinco a dez, foram testados para cada RNA.

$$tansig(n) = \frac{2}{[1 + \exp(-2n)] - 1} \quad (2)$$

$$logsig(n) = \frac{1}{[1 + \exp(-n)]} \quad (3)$$

$$softmax(n) = \frac{\exp(n)}{\text{sum}(\exp(n))} \quad (4)$$

$$radbas(n) = \exp(-n^2) \quad (5)$$

onde n é a matriz dos vetores de entrada de rede (coluna).

Os dados de entrada e saída foram divididos em dois subgrupos: o primeiro correspondente aos quatro dados experimentais para cada temperatura, e o segundo, relacionado à média dos quatro dados experimentais em cada nível de temperatura, usando treinamento e validação das redes neurais, respectivamente. Dessa maneira, para cada rede neural, número de neurônios e função de transferência foi realizada uma análise utilizando um *loop* de oito ciclos a fim de determinar os melhores desempenhos da rede neural e das condições dos parâmetros.

4.6 Análise estatística

Para as análises estatísticas, também foi utilizado o *Software Matlab® 7.1*. Os coeficientes de determinação ajustados, R^2_{adj} (Equação 6); o erro médio relativo, MRE (Equação 7); e o erro médio quadrático, mse (Equação 8), foram empregados para avaliar quão bem-sucedido o modelo é, baseado no número de parâmetros, proximidade entre os dados experimentais e calculados, e a qualidade de um estimador ou conjunto de predições em termos de sua variação e grau de liberdade na rede neural ou modelo predito, respectivamente. Além disso, as funções *regstats* e *lillietest* foram usadas para observar os valores residuais entre os dados experimentais e calculados, e para determinar se os resíduos seguiam uma distribuição normal, respectivamente (VILLA-VÉLEZ et al., 2015a).

$$R^2_{adj} = 1 - (1 - R^2) \frac{n - 1}{n - m} \quad (6)$$

$$MRE = \frac{100}{n} \sum_{n=1}^{\infty} \frac{|x_i^* - x_i|}{x_i} \quad (7)$$

$$mse = \frac{1}{n} \sum_{i=1}^n (x_i^* - x_i)^2 \quad (8)$$

Nas Equações (6) a (8), x_i^* representa os valores experimentais; x_i os valores estimados; n é o número de valores experimentais, m é o número de parâmetros estimados e R^2 é o coeficiente de determinação. Um modelo com MRE abaixo de 10% é considerado com boa precisão, enquanto que um modelo com MRE entre 10 e 15% é considerado aceitável (SABLANI; BAIK; MARCOTTE, 2002).

5 RESULTADOS E DISCUSSÃO

5.1 Caracterização química

Na Tabela 1 foram organizados os valores médios, dados em base úmida, referentes ao conteúdo de umidade, proteínas, cinzas, lipídeos e carboidratos presentes na casca de camarão.

Tabela 1: Composição físico-química da casca de camarão*.

Composição	Casca de camarão
Umidade (%)	6,702 ± 0,374
Proteínas (%)	39,107 ± 1,791
Cinzas (%)	23,575 ± 0,466
Lipídeos (%)	2,612 ± 0,887
Carboidratos (%)	28,004 ± 1,963

*correspondentes às porcentagens médias ± desvio padrão da triplicata

Fonte: Próprio Autor (2018).

Analisando a composição físico-química da casca do camarão, notou-se que o valor médio de umidade encontrado, 6,70 % ± 0,37, foi muito próximo dos 5,77% encontrados por Fernandes (2009) e da faixa de 5 a 9 % encontrada por Castro e Pagani (2004). Em relação à quantidade de proteínas presente, observou-se um valor proteico, 39,11 % ± 1,79 inferior ao encontrado por Fernandes (2009), cerca de 50,0%; no entanto, quando comparado ao Castro e Pagani (2004), 35,9 a 39,7 %, essa diferença foi ínfima. O valor médio de 23,57 % ± 0,47 de cinzas, indicou que as cascas continham apreciáveis quantidades de elementos minerais. Dentre os minerais inorgânicos que constituem as cascas e carapaças de crustáceos, destaca-se o carbonato de cálcio. Fernandes (2009) encontrou aproximadamente 21,0 % de resíduo mineral fixo. Já as porcentagens médias de lipídeos e carboidratos encontrados foram por volta de 2,61% ± 0,89 e 28,00 % ± 1,96, respectivamente. A quantidade de lipídeo encontrada neste trabalho, foi um pouco superior aos valores achados por Casto e Pegani, menos de 1,0 %, contudo inferior ao 9,3 % relatado por Fernandes (2009).

5.2 Cinética de secagem

As ilustrações das amostras das cinéticas da casca de camarão podem ser visualizadas no Apêndice B.

Os valores médios do conteúdo de umidade, em base úmida, da casca de camarão *in natura* e em espuma foram 76,69 % e 70,48 %, respectivamente. O resultado obtido para a casca *in natura*, foi muito próximo dos 78,4 % encontrados por Ramaswamy et al. (1982), dos 77,5 % relatados por Castro e Pagani (2004) e dos 75,47 % obtido por Fernandes (2009) em seus trabalhos sobre secagem de camarão. Os elevados conteúdos de umidade obtido indicam a potencial perecibilidade do coproduto, uma vez que implica no aumento da atividade de água, deixando-o mais propício ao desenvolvimento de microrganismo e conseqüentemente a alteração de suas características (ARNAU et al., 1987).

Nas Tabelas 2 e 3, foram organizados os valores médios do conteúdo de umidade, em base seca, das respectivas secagens *in natura* e em espuma da casca de camarão em função do tempo, para as temperaturas de 30, 45 e 60 °C. Conforme observado, todos os experimentos mostram um período de taxa decrescente.

As umidades relativas registradas ao longo das secagens da casca *in natura*, foram entre 37 e 48 % a 30 °C; de 16 a 49,9 % a 45 °C e iguais a 10 % a 60 °C. Já as espessuras para essas respectivas temperaturas foram entre 0,885 e 1,118 cm; 0,952 e 0,986 cm, e de 0,910 a 1,019 cm. No que tange às secagens da casca em espuma, os valores da umidade relativa foram na faixa de 33 a 52 % a 30 °C; 10 a 32 % a 45 °C e iguais a 10 % a 60 °C, enquanto que as espessuras foram de 0,586 a 0,638 cm; 0,730 a 0,765 cm e 0,663 a 0,913 cm para respectivas temperaturas supracitadas.

Tabela 2: Valores experimentais da cinética de secagem da casca de camarão *in natura**.

Tempo (s)	X (kg/kg, b.s.)		
	30 °C	45 °C	60 °C
0	3,290 ± 0,000	3,290 ± 0,000	3,290 ± 0,000
300	3,212 ± 0,007	3,192 ± 0,003	3,155 ± 0,012
600	3,147 ± 0,013	3,072 ± 0,011	2,989 ± 0,028
900	3,089 ± 0,017	2,955 ± 0,018	2,828 ± 0,034
1200	3,030 ± 0,020	2,780 ± 0,032	2,680 ± 0,037
1500	2,965 ± 0,025	2,675 ± 0,036	2,537 ± 0,039
1800	2,915 ± 0,026	2,564 ± 0,060	2,395 ± 0,044
2400	2,823 ± 0,027	2,396 ± 0,047	2,138 ± 0,047
3000	2,730 ± 0,029	2,230 ± 0,052	1,884 ± 0,052
3600	2,651 ± 0,025	2,074 ± 0,056	1,649 ± 0,051
4200	2,571 ± 0,027	1,923 ± 0,057	1,431 ± 0,053
4800	2,489 ± 0,028	1,780 ± 0,059	1,228 ± 0,053
5400	2,399 ± 0,027	1,630 ± 0,060	1,041 ± 0,053

Tabela 2: Valores experimentais da cinética de secagem da casca de camarão *in natura**.

6000	2,301 ± 0,029	1,504 ± 0,058	0,876 ± 0,052
6600	2,208 ± 0,031	1,383 ± 0,062	0,730 ± 0,051
7200	2,133 ± 0,028	1,300 ± 0,064	0,599 ± 0,047
8400	1,976 ± 0,034	1,033 ± 0,069	0,394 ± 0,038
9600	1,848 ± 0,031	0,863 ± 0,072	0,254 ± 0,022
10800	1,720 ± 0,034	0,705 ± 0,077	0,169 ± 0,013
12000	1,608 ± 0,035	0,572 ± 0,079	0,121 ± 0,014
13200	1,491 ± 0,034	0,460 ± 0,078	0,097 ± 0,015
14400	1,367 ± 0,035	0,369 ± 0,075	0,083 ± 0,011
16200	1,212 ± 0,033	0,273 ± 0,073	0,075 ± 0,008
18000	1,066 ± 0,034	0,207 ± 0,063	0,072 ± 0,008
19800	0,929 ± 0,030	0,170 ± 0,054	0,072 ± 0,008
21600	0,805 ± 0,036	0,151 ± 0,041	0,071 ± 0,008

*correspondentes às médias ± desvio padrão da quadruplicata

Fonte: Próprio Autor (2018).

Tabela 3: Valores experimentais da cinética de secagem em espuma da casca de camarão*.

Tempo (s)	X (kg/kg, b.s.)		
	30 °C	45 °C	60 °C
0	2,387 ± 0,000	2,387 ± 0,000	2,387 ± 0,000
300	2,328 ± 0,004	2,306 ± 0,001	2,271 ± 0,011
600	2,287 ± 0,006	2,235 ± 0,004	2,143 ± 0,027
900	2,245 ± 0,009	2,174 ± 0,019	2,021 ± 0,036
1200	2,198 ± 0,012	2,092 ± 0,010	1,905 ± 0,043
1500	2,150 ± 0,015	2,015 ± 0,014	1,791 ± 0,047
1800	2,105 ± 0,018	1,941 ± 0,016	1,691 ± 0,053
2400	2,016 ± 0,024	1,796 ± 0,017	1,491 ± 0,058
3000	1,932 ± 0,031	1,658 ± 0,017	1,309 ± 0,058
3600	1,853 ± 0,037	1,527 ± 0,015	1,145 ± 0,054
4200	1,777 ± 0,041	1,408 ± 0,014	1,002 ± 0,050
4800	1,696 ± 0,045	1,301 ± 0,013	0,869 ± 0,046
5400	1,616 ± 0,047	1,203 ± 0,011	0,748 ± 0,048
6000	1,548 ± 0,052	1,113 ± 0,011	0,636 ± 0,050
6600	1,472 ± 0,052	1,030 ± 0,013	0,529 ± 0,054
7200	1,405 ± 0,054	0,953 ± 0,016	0,424 ± 0,064
8400	1,285 ± 0,054	0,814 ± 0,019	0,235 ± 0,076
9600	1,176 ± 0,053	0,693 ± 0,020	0,082 ± 0,072


*correspondentes às médias ± desvio padrão da quadruplicata

Fonte: Próprio Autor (2018).

A partir dos dados tabelados, plotaram-se as Figuras 4 e 5, que representam as curvas das cinéticas de secagem da casca de camarão *in natura* e em espuma, respectivamente. Em


ambas as figuras, pôde-se observar que o incremento de temperatura favoreceu o aumento da taxa de secagem, resultando na diminuição do tempo da cinética. O mesmo comportamento foi observado por Djaeni et al. (2013), em seu trabalho sobre secagem em espuma de carragenina, e por Ajala e Ajala (2014) e Ramaswamy, Lo e Staley (1982), em estudos sobre as características da cinética de secagem de camarão.

Figura 4: Curva da cinética de secagem da casca de camarão *in natura* para as temperaturas de 30 °C (■), 45 °C (▲) e 60 °C (●).



Fonte: Próprio Autor (2018).

Figura 5: Curva da cinética de secagem da casca de camarão em espuma para as temperaturas de 30 °C (■), 45 °C (▲) e 60 °C (●).



Fonte: Próprio Autor (2018).

Ao comparar os resultados das Tabelas 2 e 3 e Figuras 4 e 5, notou-se que as secagens em espuma foram as que apresentaram tempos de secagem mais curtos. Venkatachalam et al. (2014), explicam que a formação de espuma torna o material mais poroso e mais suscetível a secar nas suas camadas mais internas, devido ao movimento de umidade pelas forças capilares através da película líquida que separam as bolhas da espuma.

Franco et al. (2015), em seus estudos sobre secagem em espuma de suco de yacon, e Djaeni et al. (2013), destacaram a espessura da espuma como uma variável que influencia substancialmente no tempo de secagem. Em ambos os trabalhos, foram observados uma relação de proporcionalidade entre essas variáveis. Isso porque, o aumento da espessura requer um caminho mais longo a ser percorrido pela água para alcançar a superfície do produto. Além disso, a transferência de calor torna-se menos eficiente devido à dificuldade de penetração do calor.

5.3 Modelagem com redes neurais artificiais

A partir da modelagem com redes neurais artificiais da secagem da casca de camarão *in natura*, construiu-se a Tabela 4, na qual foram dispostos os melhores resultados para as funções de transferência estudadas, bem como suas validações estatísticas. Os valores obtidos, mostraram uma boa validação para ambas as arquiteturas, sendo que, a função tangente hiperbólica (*tansig*) com seis neurônios na camada oculta foi a que apresentou as melhores avaliações para a rede *feed-forward*, com $R^2_{adj} = 0,998$, $MRE = 3,516$ e $mse = 0,023$; e para rede *cascade-forward*, com $R^2_{adj} = 0,998$, $MRE = 3,347$ e $mse = 0,023$.

Tabela 4: Melhores resultados e validação estatística das análises de redes neurais artificiais da cinética de secagem *in natura* da casca de camarão.

Arquitetura	Função de transferência	Neurônio	Número de parâmetro	R	R^2_{adj}	MRE (%)	mse
Feed-forward	<i>tansig</i>	6	25	0,999	0,998	3,516	0,023
	<i>softmax</i>	7	29	0,999	0,998	3,321	0,023
	<i>logsig</i>	8	33	0,999	0,999	3,300	0,023
	<i>radbas</i>	8	33	0,999	0,998	3,356	0,023
Cascade-forward	<i>tansig</i>	6	27	0,999	0,998	3,347	0,023
	<i>softmax</i>	7	31	0,999	0,998	3,399	0,023
	<i>logsig</i>	7	31	0,999	0,998	3,345	0,023
	<i>radbas</i>	7	31	0,999	0,998	3,306	0,023

Fonte: Próprio Autor (2018).

A seleção de seis neurônios na camada oculta como melhor resultado para a cinética de secagem da casca de camarão *in natura* foi determinado nos testes, para evitar os parâmetros superestimados obtidos com sete e oito neurônios. Braga et al. (2007) relatam que o número de neurônios, e conseqüentemente o número de parâmetros da rede é que determina a complexidade do modelo neural. Assim, quanto maior for o número de neurônios, maior será a abrangência da estrutura neural em termos de soluções possíveis para a solução de um determinado problema.

A Tabela 5 exhibe os melhores resultados para as funções de transferência empregadas e suas validações estatísticas para secagem cinética em espuma da casca de camarão. A partir dos resultados obtidos, notou-se que os erros médios relativos (*MRE*), para ambas as arquiteturas, apresentaram valores inferiores a 15 %, indicando que o modelo pode ser considerado aceitável para as redes treinadas. Observou-se também que, para todas as funções de transferências, os melhores resultados determinados nos testes apresentaram cinco neurônios na camada oculta. Dentre esses, destacaram-se para as arquiteturas *feed-forward* e *cascade-forward*, as funções competitiva softmax (*softmax*), com $R^2_{adj} = 0,997$, $MRE = 12,043$ e $mse = 0,019$, e sigmoide (*logsig*), com $R^2_{adj} = 0,997$, $MRE = 12,300$ e $mse = 0,019$, respectivamente.

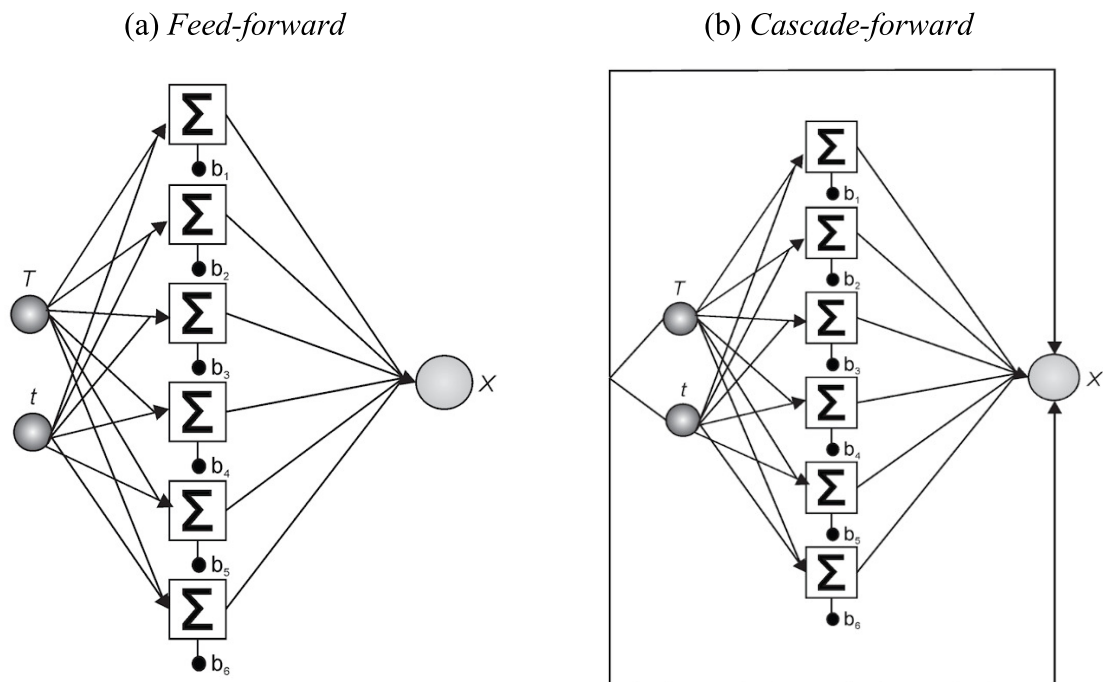
Tabela 5: Melhores resultados e validação estatística das análises de redes neurais artificiais da cinética de secagem em espuma da casca de camarão.

Arquitetura	Função de transferência	Neurônio	Número de parâmetro	R	R^2_{adj}	MRE (%)	mse
<i>Feed-forward</i>	<i>tansig</i>	5	21	0,997	0,997	12,301	0,019
	<i>softmax</i>	5	21	0,997	0,997	12,043	0,019
	<i>logsig</i>	5	21	0,997	0,997	12,301	0,019
	<i>radbas</i>	5	21	0,997	0,997	12,371	0,019
<i>Cascade-forward</i>	<i>tansig</i>	5	23	0,997	0,997	12,329	0,019
	<i>softmax</i>	5	23	0,997	0,997	12,359	0,019
	<i>logsig</i>	5	23	0,997	0,997	12,300	0,019
	<i>radbas</i>	5	23	0,997	0,997	12,453	0,019

Fonte: Próprio Autor (2018).

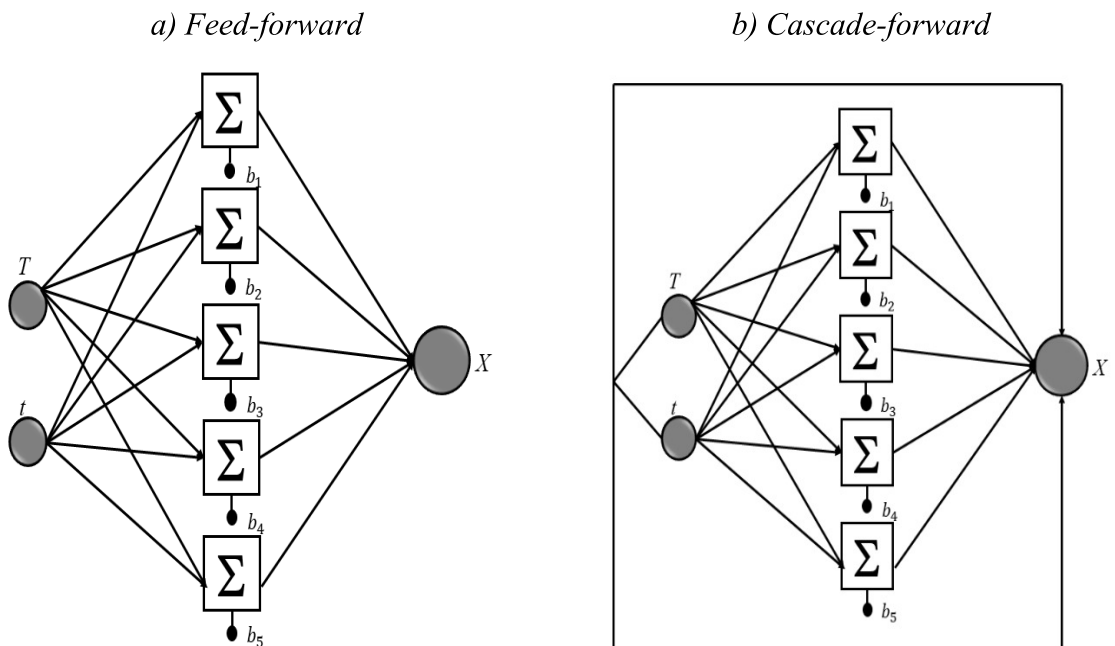
A Figura 6 ilustra as estruturas das redes *feed-forward* e *cascade-forward* das secagens das cascas *in natura* compostas por duas entradas, uma saída e seis neurônios na camada oculta. Já a Figura 7 exhibe as redes *feed-forward* e *cascade-forward* das secagens das cascas em espuma compostas por duas entradas, uma saída e cinco neurônios na camada oculta.

Figura 6: Arquitetura dos melhores resultados das redes *feed-forward* (a) e *cascade-forward* (b) da cinética de secagem *in natura* da casca de camarão.



Fonte: Próprio Autor (2018).

Figura 7: Arquitetura dos melhores resultados das redes *feed-forward* (a) e *cascade-forward* (b) da cinética de secagem em espuma da casca de camarão.



Fonte: Próprio Autor (2018).

Em ambas as arquiteturas utilizadas neste trabalho, os melhores ajustes para o conjunto de dados de treinamento da cinética de secagem da casca de camarão *in natura* e em espuma foram obtidos com seis e cinco neurônios na camada oculta, respectivamente. Perazzini, Freire e Freire (2013) ao utilizarem a rede *feed-forward* para prever o comportamento do conteúdo de umidade ao longo do tempo de secagem de resíduos orgânicos, encontraram o número ideal de dois neurônios na camada intermediária, sendo que o tempo, a temperatura e velocidade do ar foram utilizados com entradas, e a umidade como saída para treinamento dessa rede. Hernández-Pérez et al. (2004) ao empregarem a rede *feed-forward* para prever a cinética do conteúdo de umidade durante a secagem da mandioca e manga, encontram como melhor ajuste três neurônios na camada oculta, sendo cinco as variáveis de entrada (temperatura do ar, velocidade do ar, encolhimento, tempo e umidade do ar) e duas de saída (temperatura e umidade de cada produto). Erenturk e Erenturk (2007), ao usarem essa mesma rede para estimar o comportamento dinâmico da cenoura, fizeram o treinamento com vinte e cinco neurônios na camada oculta, no qual a temperatura do ar, velocidade do ar, tempo de secagem e tamanho da raiz foram utilizadas como entradas, e o conteúdo de umidade como saída. Lashkarbolooki, Shafipour e Hezave (2013) ao utilizarem a rede *cascade-forward* para correlacionar o rendimento de extração obtido de óleo de hortelã em diferentes condições operacionais, encontraram treze neurônios na camada oculta como número igual. Já Villa-Vélez, Váquiro e Telis-Romero (2015b), ao empregarem essa rede na modelagem da taxa de hidrólise da biomassa lignocelulósica através de ultrassom de alta intensidade, acharam sete neurônios na camada intermediária como melhor ajuste.

As Equações (9) e (10) mostram o modelo matemático da arquitetura de *feed-forward* e *cascade-forward* resultantes das Figuras 6 e 7 respectivamente:

$$f_{(X)} = \psi \left[\left(\sum_{i,k=1}^n \varphi_i \omega_{ik} + \delta_k \right) + \sum_{j,k=1}^n \omega'_{jk} \right] \quad (9)$$

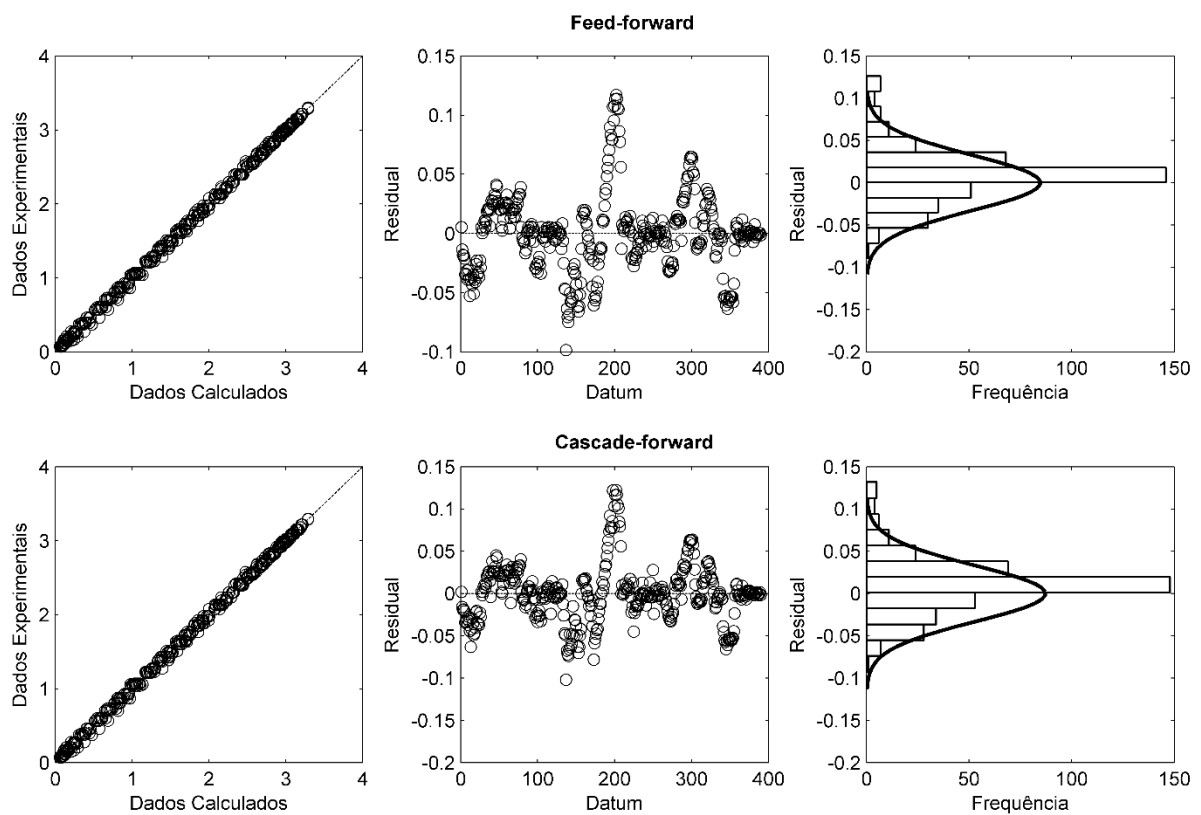
$$f_{(X)} = \sum_{i,j=1}^n \omega_{ij}^0 + \psi \left[\left(\sum_{i,k=1}^n \varphi_i \omega_{ik} + \delta_k \right) + \sum_{j,k=1}^n \omega'_{jk} \right] + \delta_j \quad (10)$$

onde ω_{ij}^0 são os pesos do produto entre as entradas (i) e saídas (j) da rede, φ_i são as entradas da rede, ω_{ik} são os pesos do produto entre as entradas e os neurônios da camada oculta, δ_k são os bias dos neurônios da camada oculta, ω'_{jk} são os pesos do produto entre os neurônios da camada oculta e saídas da rede, δ_j é o bias da rede de saída e ψ é a função de transferência *tansig*

$[2/(1+\exp(-2\alpha_i))+1]$ (LASHKARBOLOOKI et al., 2013; VILLA-VÉLEZ; VÁQUIRO; TELIS-ROMERO, 2015a).

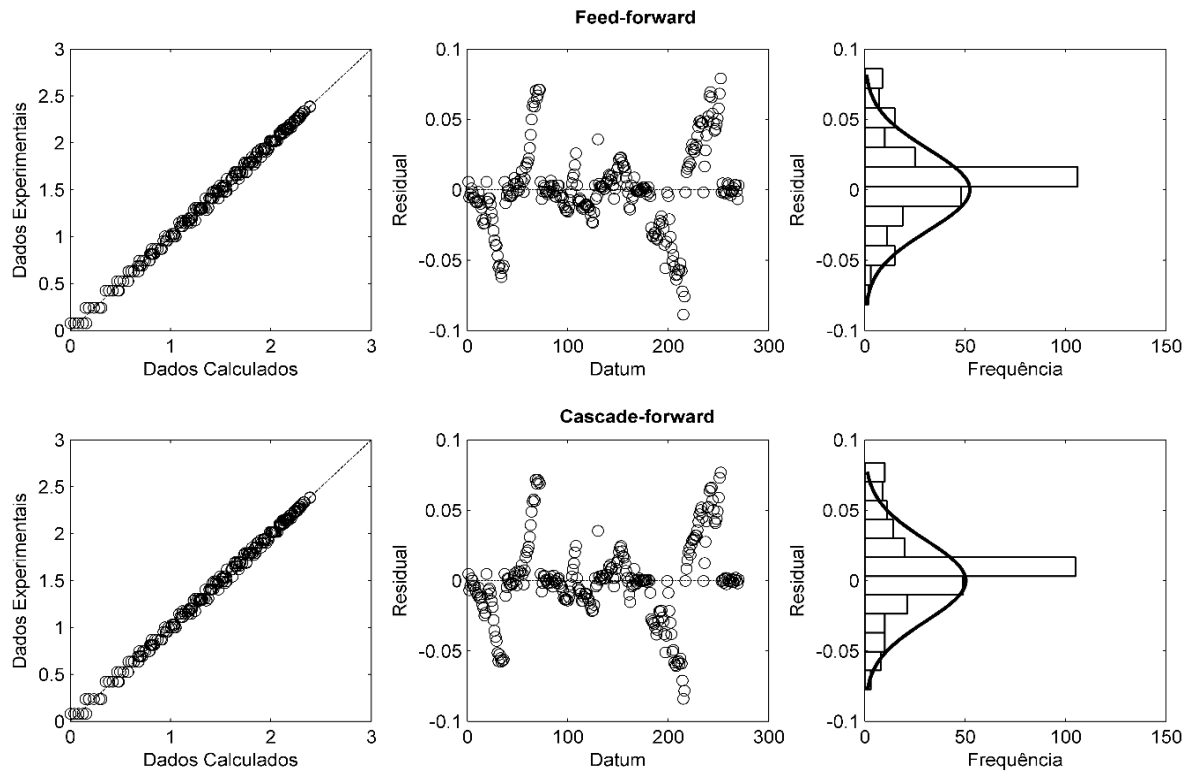
As Figuras 8 e 9 mostram o desempenho estatístico das redes neurais. Ambas as figuras apresentaram um bom ajuste da modelagem, o que indica que as arquiteturas estudadas, podem ser empregadas, dentro das condições em que este trabalho foi realizado, para simular as curvas cinéticas das cascas de camarão *in natura* e em espuma.

Figura 8: Análise residual entre as curvas de secagem experimental e calculada da casca de camarão *in natura*.



Fonte: Próprio Autor (2018).

Figura 9: Análise residual entre as curvas de secagem experimental e calculada da casca de camarão em espuma.



Fonte: Próprio Autor (2018).

6 CONCLUSÕES

Com base nos resultados químicos e das umidades de equilíbrio na secagem, pôde-se observar que tanto a casca de camarão *in natura* quanto em espuma, apresentaram valores elevados de umidade em sua composição, o que pode favorecer o desenvolvimento microbiano. Desta forma é importante ressaltar o uso de métodos de secagem e combinados, como o caso específico da secagem convectiva e por sistemas espumantes a fim de fornecer informações sobre a elaboração de novos produtos e, conseqüentemente, o aproveitamento total destes resíduos. Através da avaliação das cinéticas de secagens estudadas foi possível notar que além da temperatura ser uma variável importante no processo de secagem, a utilização de sistemas espumantes ajudam a obter maiores taxas de evaporação de água no material, ainda que realizada a baixa temperatura. Além disso, pode-se verificar que o emprego de redes neurais artificiais se mostrou muito eficaz no desenvolvimento da modelagem matemática da cinética da secagem das cascas de camarão, tendo em vista os resultados obtidos e a validação estatística. Dessa forma, infere-se que as redes *feed-forward* e *cascade-forward* podem ser utilizadas para simular as curvas de secagem na faixa de temperatura de 30 a 60 °C.

REFERÊNCIAS

- ABALONE, R.; GASTÓN, A.; CASSINERA, A.; LARA, M. A. Thin layer drying of amaranth seeds. **Biosystems engineering**, n. 93, v. 2, p. 179-188, 2006.
- ABBASZADEH, A. et al. Evaluation of thin-layer drying models and neural network for describing drying kinetics of *Lasagnas angustifolia* L. **International Food Research Journal**, v. 18, n. 4, p. 1321-1328, 2011.
- AJALA, A. S.; AJALA, F. A. A study on drying kinetics of shrimps. **International Journal of Innovation and Applied Studies**, v. 9, n. 4, p. 1778-1785, 2014.
- AOAC. Official methods of analysis Gaithersburg: AOAC International 2007.
- ARNAU, J.; HUGAS, M.; MONFORT, J. M. **El jamón curado: Aspectos técnicos Girona**, Itália, Grafis-Sant S. A. 1987, 352 p.
- ASSIS, A. S. de. Bioconversão de resíduos de camarão *Litopenaeus Vannamei* (Booner, 1931) para produção de biofilmes de quitosana **Revista Iberoamericana de Polímeros**. v. 9, n. 5, 2008.
- BARNES, R. D. **Zoologia dos invertebrados**. ed. 4. Roca: São Paulo, 1984.
- BASSANEZI, R. C. **Ensino-aprendizagem com modelagem matemática: uma nova estratégia**. 3 ed. São Paulo: Contexto, 2011. cap. 1, p. 31-32.
- BESSA-JUNIOR, A. P.; GONÇALVES, A. A. Análises econômica e produtiva da quitosana extraída do exoesqueleto de camarão. **Acta of Fisheries and Aquatic Resources**, v. 1, n. 1, p. 13-28, 2013.
- BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2 ed. Rio de Janeiro: LTC, 2007.
- BRYGIDYR, A.; RZEPECKA, M.; MCCONNELL, M.. Characterization and drying of tomato paste foam by hot air and microwave energy. **Can. Inst. Food Sci. Technol. J.** v. 10, p. 313–319, 1977.
- CAMPANA-FILHO, S. P. et al. Extração, estruturas e propriedades de α - e β -quitina. **Química Nova**, v. 30, n. 3, p. 644-650, 2007.
- CASTRO, A. A.; PAGANI, G. D. Secagem e composição química da cabeça de camarão (*Litopenaeus vannamei* Boone) a diferentes temperaturas. **Revista Brasileira de Produtos Agroindustriais**, v.6, n.2, p.123-129, 2004.
- CASTRO, D. S. de et al. Secagem de polpa de *Annona squamosa* L.: cinética e avaliação de modelos empíricos. **Magistra Cruz das Almas**, v. 28, n.3/4, p. 294-300, 2016.
- CRAVEIRO, A. A.; CRAVEIRO, A. C.; QUEIROZ, D. C. **Quitosana: a fibra do futuro**. Fortaleza: Parque de desenvolvimento tecnológico (Padetec), 2. ed., 2004.

DIAS-NETO, J. Gestão do uso dos recursos pesqueiros marinhos no Brasil. IBAMA: Brasília, 2010.

DIAS-NETO, J.; DAMASCENO, F. G.; ISAAC, V. J. Camarão-rosa da costa norte: biologia, dinâmica e administração pesqueira. IBAMA: Brasília, 1992. 187 p. Coleção meio ambiente. Série estudos pesca, 1.

DJAENI, M. et al. Application of foam-mat drying with egg White for carrageenan: drying rate and product quality aspects. **Journal of Food Science and Technology**, 2013.

ERENTURK, S.; ERENTURK, K. Comparison of genetic algorithm and neural network approaches for the drying process of carrot. **Journal of Food Engineering**, v. 78, p. 905-912, 2007.

FAO – Food and Agriculture Organization of the United Nations. The State of World Fisheries and Aquaculture: opportunities and challenges. Rome, 2014. 45, 75 p.

FAO – Food and Agriculture Organization of the United Nations. The State of World Fisheries and Aquaculture: opportunities 2008. Rome, 2009. 176 p.

FÁVERO, L. P. et al. **Análise de dados: modelagem multivariada para tomada de decisões**. Rio de Janeiro: Elsevier, 2009.

FELIPE, L. O. et al. Quitosana: da química básica à bioengenharia. **Quim. Nova Esc.**, v. 39, n. 4, 2017.

FERNANDES, T. M. **Aproveitamento dos subprodutos da indústria de beneficiamento do camarão na produção de farinha**. 2009. 84 f. Dissertação (Mestrado em Ciência e Tecnologia de Alimentos). Universidade Federal da Paraíba, João Pessoa, 2009.

FERREIRA, M. M. P. **Desenvolvimento, caracterização e secagem de sementes com cobertura artificial**. 2003. 264 f. Tese (Doutorado em Engenharia Química), Universidade Federal de São Carlos, São Carlos, 2003.

FORTES, M; OKOS, M. A non-equilibrium thermodynamics approach to heat and mass transfer in corn kernels. **Transactions of the ASAE**, v. 24, n.3, p. 761-769, 1981.

FRANCO, T. S. et al. Foam mat drying of yacon juice: experimental analysis and computer simulation. **Journal of Food Engineering**, v. 158, p. 48-57, 2015.

GEANKOPLIS, C. J. **Procesos de transporte y operaciones unitarias**. 3 ed. CECSA: México, 1998.

GREENAWAY, P. Calcium balance and moulting in the crustacea. **Biol. Rev**, v. 60, p. 425-454, 1985.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Bookman, 2001.

HE, X. W et al. Calcium carbonate nanoparticle delivering vascular endothelial growth factor-C siRNA effectively inhibits lymphangiogenesis and growth of gastric cancer vivo, **Cancer Gene Therapy**, v. 15, p. 193-202, 2008.

HERNÁNDEZ-PÉREZ, J. A. et al. Neural networks for the heat and mass transfer prediction during drying of cassava and mango. **Innovative Food Science and Emerging Technologies**, v. 5, p. 57-64, 2004.

HIMMELBLAU, D. M. **Ind. Eng. Chem. Res**, v. 47, p. 5782-5796, 2008.

HONORATO, G. C. **Concepção de um secador rotatório para secagem do cefalotórax do camarão**. 2006. 185 f. Tese (Doutorado em Engenharia Química), Universidade Federal do Rio Grande do Norte. 2006.

JAYAS, D. S. et al. Review of thin layer drying and wetting equations. **Drying Technology**, v. 9, n. 3, p. 551-588, 1991.

KARIMI, F. et al. 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, p. 29–39, 2012.

KASHANINEJAD, M. et al. Thin-layer drying characteristics and modeling of pistachio nuts. **Journal of Food Engineering**, v. 78, p. 98-108, 2007.

KEEY, R. B. **Drying: principles and practice**. New York: Pergamon Press, 1972.

KHAZAEI, N. B. et al. Applied machine vision and artificial neural network for modeling and controlling of the grape drying process. **Computers and Electronics in Agriculture**, v. 98, p. 205-213, 2013.

KUDRA, T.; RATTI, C. Foam-mat drying: Energy and cost analyses. **Can. Biosyst. Eng.**, v. 48, n. 3, p. 27–33, 2006.

KUMAR, R.; MAJETI, N. V. A review of chitin and chitosan applications. **Reactive e Functional Polymers**. v. 46, p. 1-27, 2000.

LASHKARBOLOOKI, M.; SHAFIPOUR, Z. S.; HEZAVE, A. Z. Trainable cascade-forward back-propagation network modeling of spearmint oil extraction in a packed bed using SC-CO₂. **Journal of Supercritical Fluids**, v. 73, p. 108-115, 2013.

MATHUR, N. K.; NARANG, C. K. Chitin and Chitosan: versatile Polysaccharides from marine animals, **J. Chem. Educ.**, v. 67, n. 11, 1990, 938 p.

MAYOR, L.; SERENO, A. M. Modelling shrinkage during convective drying of food materials: a review. **Journal of Food Engineering**, v. 61, p. 373-386, 2004.

MENLIK, T.; ÖZDEMİR, M. B.; KIRMACI, V. Determination of freeze-drying behaviors of apples by artificial neural network. **Expert Systems with Applications**, v. 37, p. 7669–7677, 2010.

MONTELES, J. S.; FUNO, I. C. de A.; CASTRO, A. C. L. de. Caracterização da pesca artesanal nos municípios de Humberto de Campos e Primeira Cruz - Maranhão. *Boletim do laboratório de hidrobiologia*, 23, p. 65-74, 2010.

MUJUMDAR, A. J. **Handbook of industrial drying**. 3 ed., CRC: 2006.

MUTHUKUMARAN, A. **Foam-mat freeze drying of egg white and mathematical modeling**. 2007. 93 f. Thesis (Master of Science) -Faculty of Graduate Studies and Research, McGill University, Montreal, 2007. 2 p.

NATORI, M. M. et al. Desenvolvimento da carcinicultura marinha no Brasil e no mundo: avanços tecnológicos e desafios. **Informações Econômicas**, v. 41, n. 2, 2011.

PARRY, J. L. Mathematical modeling and computer simulation of heat and mass transfer in agricultural grain drying. **Journal of Agricultural Engineering Research**, v. 32, p. 1–29, 1985.

PERAZZINI, H.; FREIRE, F. B.; FREIRE, J. T. Drying kinetics prediction of solid waste using semi-empirical and artificial neural network models. **Chemical Engineering Technology**, v. 36, n. 7, p. 1193-1201, 2013.

PICTON, P. **Neural Networks**. 2 ed. Palgrave, 2000. cap. 1, p. 1.

RAMASWAMY, H. S; LO, K. V.; STALEY, L. M. Air drying of shrimp. **Canadian Agricultural Engineering**, v. 24, n. 2, p. 123-128, 1982.

RINAUDO, M. Chitin and chitosan: Properties and applications. **Progress in Polymer Science**, v. 31, n. 7, p. 603-632, 2006.

ROCHA, I. Os fundamentos que justificam as restrições às importações de camarão pelo Brasil. **Revista Feed Food**, ano 10, n. 16, out 2017.

RUDZINSKI, W. E et al. Targeted delivery of small interfering RNA to colon cancer cells using chitosan and PEGylated chitosan nanoparticles, **Carbohydr**, v. 147, p. 323-332, 2016.

SABLANI, S. S.; BAIK, O.-D.; MARCOTTE, M. Neural networks for predicting thermal conductivity of bakery products. **Journal of Food Engineering**, v. 52, p. 299-304, 2002.

SEBRAE – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas. **Aquicultura no Brasil: série estudos mercadológicos**. Brasília, 2015.

SILVA, I. N. de; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático**. Artliber, 2010.

SINGH, N. J.; PANDEY, R. K. Neural network approaches for prediction of drying kinetics during drying of sweet potato. **Agricultural Engineering International**, v. 13, n. 1, 2011.

VENKATACHALAM, S. et al. Foam mat drying of food materials: a review. **Journal of Food Processing and Preservation**, 2014.

VIGANÓ, J. **Propriedades termodinâmicas de adsorção de água e cinética de secagem de subprodutos da industrialização de abacaxi (*Ananás comosus L.*) - Casca e cilindro central**. 2012. 89 f. Dissertação (Mestrado em Engenharia e Ciência de Alimentos). Universidade Estadual Paulista "Júlio de Mesquita Filho", São José do Rio Preto, 2012.

VILLA-VÉLEZ, H. A.; VÁQUIRO, H. A.; TELIS-ROMERO, J. et al. Study of the specific heat capacity of biomass from banana waste for application in the second-generation ethanol industry. **Environmental Progress & Sustainable Energy**, v. 34, n. 4, p. 1221-1228, 2015a.

VILLA-VÉLEZ; H. A.; VÁQUIRO, H. A.; TELIS-ROMERO, J. The effect of power-ultrasound on the pretreatment of acidified aqueous solutions of banana flower-stalk: structural, chemical and statistical analysis. **Industrial Crops and Products**, v. 66, p. 52-61, 2015b.

ZAYAS, J.F. Foaming properties of proteins. In: _____. **Functionality of proteins in food**. Springer – Verlag Berlin Heidelberg, 1997. p. 260–309.

APÊNDICE A – CASCAS DE CAMARÃO UTILIZADAS NA ANÁLISE FÍSICO-QUÍMICA

Figura A1 – Cascas de camarão lavadas.



Figura A2 – Cascas de camarão trituradas.



APÊNDICE B – CINÉTICAS DE SECAGEM DA CASCA DE CAMARÃO

Figura B1 – Amostras secas das cascas de camarão *in natura*.



Figura B2 – Amostras secas das cascas de camarão em espuma.



ANEXO A – PROGRAMAÇÃO NO MATLAB PARA MODELAGEM POR REDES NEURAIS ARTIFICIAIS

```

%===== Neural network =====%
format short g, format compact, warning ('off'), clc, clear all

eval(['load(''Dados_RNAECC.mat'')']);

Xinput=Input;          % Input data
Ytarget=Output;       % target data for silmultenous responses

% %Normalization
% for nIn=1:length(Input(:,1))
%     Xinput(nIn,:)=(Input(nIn,:)-min(Input(nIn,:)))/(max(Input(nIn,:))-
min(Input(nIn,:)));
% end;
% for nOu=1:length(Output(:,1))
%
%                                     Ytarget(nOu,:)=(Output(nOu,:)-
min(Output(nOu,:)))/(max(Output(nOu,:))-min(Output(nOu,:)));
% end;
% Input_MINMAX =[min(Input');max(Input')];
% Output_MINMAX=[min(Output');max(Output')];

%-----Network Properties-----%
nTrFcn={'tansig';'softmax';'logsig';'radbas'};
nNType={'newcf';'newff'};
for ntype=1:length(nNType)
fprintf(['\n\nNET TYPE: ' nNType{ntype} '\n']);
nHN=5:1:10;
for TF=1:4
fprintf(['\nTransf.Fcn: ' nTrFcn{TF} '\n']);
    for HN=1:length(nHN)
        for rep=1:8
            numHiddenNeurons = nHN(HN); % Adjust as desired
            eval(['net = ' nNType{ntype}
'(Xinput,Ytarget,numHiddenNeurons);']);

                net.divideFcn='divideind';
%
%     net.divideParam.trainInd = [1:26 131:156 261:286 27:52 157:182
286:312 53:78 183:208 313:338 79:104 209:234 339:364]; % Camarão
%
%     net.divideParam.trainInd = [1:23 116:138 231:253 24:46
net.divideParam.trainInd = [1:18 91:108 181:198 19:36 109:126
199:216 37:54 127:144 217:234 55:72 145:162 235:252]; % Espumante camarão
%net.divideParam.valInd = 28:54; % Adjust as desired
%
%     net.divideParam.testInd = [105:130 235:260 365:390]; % Camarão
net.divideParam.testInd = [73:90 163:180 253:270]; % Espumante
camarão

%=====Train and Apply
Network=====
%-----Performance function-----
%
net.performFcn = 'mae';
%-----Train function-----
%
net.trainFcn = 'trainlm';
% 'trainbr' Bayesian regularization
% 'trailm' Levenberg-Marquardt backpropagation

```



```

% 'trainbfg
%-----Transfer function for new type newfit-----
-----%

net.layers{1}.transferFcn = nTrFcn{TF};
net.trainParam.min_grad=1e-8;
net.trainParam.epochs=1000;
% 'softmax' Softmax transfer function
% 'logsig' Log-sigmoid transfer function
% 'netinv' Inverse transfer function
% 'radbas' Radial basis transfer function
% 'tansig' Hyperbolic tangpnt sigmoid transfer function
[net,tr,outputs,E,Pf,Af] = train(net,Xinput,Ytarget);
[outputs,Pf,Af,E,perf] = sim(net,Xinput);
% Weight and bias values
nparam=length(getx(net));
w1=net.iw{1,1}; %Weight values Layer 1
b1=net.b{1}; %Bias values Layer 1
w2=net.lw{2,1}; %Weight values Layer 2
b2=net.b{2}; %Bias values Layer 2

% Desnormalizar las variables
% Yexp=reshape(Ytarget,1,size(Ytarget,1)*size(Ytarget,1));
% Ycal=reshape(outputs,1,size(Ytarget,1)*size(Ytarget,1));
Yexp=Ytarget;
Ycal=outputs;
R2=min(min(corrcoef(Yexp,Ycal).^2));
ndata=length(Yexp);
R2adj=1-(1-R2)*(ndata-1)/(ndata-nparam);
MRE=100*sum(abs(Yexp-Ycal)./Yexp)/ndata;
MSE=sum(abs(Yexp-Ycal))/ndata;
RESnetTemp(rep,:)=[nHN(HN) nparam R2 R2adj MRE MSE];
DataXYTemp{rep}=[Ytarget outputs];
NETSTemp{rep}=net;
bestrep=RESnetTemp(:,4)==max(RESnetTemp(:,4));
end;
fprintf(['Test' num2str(HN) ': ' num2str(RESnetTemp(bestrep,:)) '
(rep:' num2str(find(bestrep)) '\n']);
RESnet(HN,:)=RESnetTemp(bestrep,:);
DataXY{TF,HN}=DataXYTemp{bestrep};
NETS{TF,HN}=NETSTemp{bestrep};
end;
RES{1,TF}=nTrFcn{TF};
RES{2,TF}=RESnet;
bestf=RESnet(:,4)==max(RESnet(:,4));
BESTF(TF,:)=RESnet(bestf,:);
fprintf(['*Best: ' num2str(BESTF(TF,:)) '\n']);
end;
thebest=BESTF(:,4)==max(BESTF(:,4));
BESTN{1,1}=nTrFcn{thebest};
BESTN{1,2}=BESTF(thebest,:);
BESTN{1,3}=DataXY{thebest,nHN==BESTF(thebest,1)};
BESTN{1,4}=NETS{thebest,nHN==BESTF(thebest,1)};
filenet=['RES_' nNType{ntype} '.mat'];
fprintf(['\n Saving ' filenet ' ... \n']);
eval(['save ( ' filenet ' '
' ','DataXY','NETS','RES','BESTF','BESTN' )']);
end;
% view(net);
%====Plot propeties network=====%
% plotperf(tr)

```

```
% plotfit(net,Xinput,Ytarget)  
% plotregression(Ytarget,outputs)
```