

PROJETO DE APLICAÇÃO DE REDES NEURAS À MODELAGEM DE UM TORRADOR DE CAFÉ

Juliana Vieira Almeida¹

RESUMO

O projeto de modelagem de um torrador de café será feito utilizando técnicas de redes neurais artificiais com estudo do desempenho do torrador baseado nos modelos do tipo caixa-preta. Com isso, não é necessário o conhecimento fenomenológico do sistema. Os dados para o treinamento da rede neural será coletado no torrador de café da Indústria Alimentícia Maratá, situada no município de Itaporanga D'Ajuda em Sergipe. As variáveis de entrada são aquelas que armazenam informações fornecidas, como por exemplo, a temperatura da fornalha, temperatura de corte entre outras. Já as variáveis de saída, armazenam dados processados como a massa de saída, cor, umidade e temperatura de saída. Com base nos dados obtidos do processo serão realizadas várias simulações para verificar a aplicabilidade da técnica de redes neurais à descrição do comportamento do sistema. Vários parâmetros e arquiteturas de redes serão testados até que se encontre o modelo que melhor represente o sistema de torrador de café.

Palavras-chaves: Modelagem matemática; Redes neurais artificiais; Torrador de café.

1. INTRODUÇÃO

O café, que se propagou do Oriente para o Ocidente, prestando-se às demandas mercantilistas que alimentaram o capitalismo, acompanhando as revoluções científicas e financeiras que presidiram a sociedade moderna, tem grande importância na história e na economia mundial. No Brasil, muitas fortunas foram construídas com base nesse produto, muitas cidades foram fundadas ao longo de fazendas ou centros de produção cafeeira, como também relações sociais foram edificadas ao seu redor (MARTINS, 2008).

1

Desde o século XVIII até aos dias de hoje muitas mudanças ocorreram e vêm ocorrendo, associadas a essa cultura que chegou a ser o único financiador da economia do país e até os dias de hoje tem nela uma participação muito expressiva.

Apesar de o país ter se transformado muito, o café continua sendo um grande participante para a balança comercial do Brasil. Muitas localidades no Brasil são extremamente dependentes desse produto para o desenvolvimento da região, e o bom resultado do valor do café no mercado internacional possui uma relação direta com o nível de renda da população dependente dessa cultura.

O Brasil possui particularidades diferentes em relação a outros países produtores de café, pois além de ser grande produtor é também grande consumidor e a produção nacional tanto vai para o exterior como fica em nosso território para consumo interno.

A produção industrial de café se resume nas seguintes operações: análise do grão cru, armazenamento, torra, moagem, empacotamento e distribuição. Dessas operações, uma das mais importantes é a torra, pois a mesma é responsável pelo seu sabor.

O estudo do comportamento de um torrador de café constitui um enorme desafio devido ao grande número de variáveis que devem ser consideradas. Levando-se isso em conta, a utilização de modelos matemáticos tem se tornado um importante e útil instrumento para a descrição do processo.

Em função do grande número de variáveis determinantes do processo de torra do café, e o modo complexo como estas interagem, torna-se conveniente a aplicação de metodologias de modelagem que não consideram a fenomenologia do processo por meio de equações que expressam os princípios físico-químicos. Neste contexto, podem ser úteis as técnicas de redes neurais, uma modalidade da chamada Inteligência Artificial, as quais têm sido aplicadas desde a década de 80 para a modelagem de processos.

Em termos gerais, um modelo é definido como sendo qualquer objeto, concreto ou abstrato, que pode ser utilizado para explicar o comportamento de um dado sistema. Um modelo permite compreender como um sistema se comporta na presença de algumas perturbações e a relação existente entre as diversas variáveis envolvidas (PINTO e LAGE, 1997).

Uma das ferramentas utilizadas para a modelagem baseada em dados são as redes neurais, que consistem em elementos de cálculo simples, operando em

paralelo, cuja idéia básica é tentar reproduzir o comportamento do cérebro humano. O desempenho de uma rede neural é determinado em grande parte pelas conexões entre seus elementos, chamadas de pesos, os quais são ajustados a partir de um procedimento de treinamento a partir de dados.

O objetivo principal deste trabalho será o entendimento da técnica de redes neurais e a tentativa de aplicá-la na modelagem de um torrador de café industrial em operação na Indústria Alimentícia Maratá.

Como objetivos específicos podem ser destacados:

- Estudar a teoria básica de redes neurais;
- Fazer o levantamento empírico de dados operacionais em um torrador de café industrial;
- Analisar as variáveis de processo, definindo a melhor relação *input-output* para a descrição do comportamento do torrador de café;
- Implementar um programa computacional para treinar/simular uma rede neural direta de camadas múltiplas de modo a descrever a relação *input-output* do torrador de café.

2. ELEMENTOS HISTÓRICOS

O café foi descoberto em 1440 na Etiópia, por um pastor árabe, e seu fruto cafeeiro era chamado QUAHWAH, cujo significado quer dizer força e vigor. Posteriormente, os turcos e outros orientais passaram a pronunciar CABEUH, cuja palavra adaptou-se ao francês e vindo essa palavra a dar origem à palavra CAFÉ no português, francês, italiano e espanhol; COFFEE em inglês; KAFFE em alemão; KAVE no húngaro; KOHI no japonês e KIAFEY no chinês (Em: <http://www.revistacafeicultura.com.br/index.php?_mat=3278&tipo=ler>. Acesso em: 16 de agosto de 2011.)

No Brasil, historicamente, o ciclo do café sucede ao da cana-de-açúcar. Em 1727 os portugueses compreenderam que a terra do Brasil apresentava boas possibilidades para a cafeicultura em razão de condições climáticas muito favoráveis. Uma limitação para a difusão da cultura cafeeira, entretanto, era o fato de que os portugueses não possuíam nem plantas nem grãos. Então, o governo do Pará decidiu enviar um jovem oficial, chamado Palheta, à Guiana Francesa com a missão de pedir ao governador M. d'Orvilliers algumas mudas. Segundo a história,

M. d'Orvilliers, seguindo ordens expressas do rei da França, deixou de atender ao pedido de Palheta, mas Mme. d'Orvilliers, esposa do governador da Guiana Francesa, não resistindo aos encantos do jovem tenente, enviou um ramo de flores a Palheta, quando ele já regressava ao Brasil. Dissimuladas pela folhagem, no ramo de flores se encontravam escondidas as sementes a partir das quais surgiu o poderoso império brasileiro do café (Em: <<http://www.planetaorganico.com.br/cafebrev1.htm>>. Acesso em: 06 de abril de 2011).

Do Pará, a cultura passou para o Maranhão, Bahia, Paraná, Minas Gerais e, por volta de 1760, foi trazida para o Rio de Janeiro por João Alberto Castelo Branco, onde se espalhou pela Baixada Fluminense e posteriormente pelo Vale do Paraíba. Com a chegada do café ao Brasil, muitas cidades foram construídas e muitas fortunas foram geradas, ou seja, o Brasil cresceu muito e isso fez com que o café tivesse uma grande importância na história e na economia do Brasil. Em 1840, o Brasil se tornou o maior produtor mundial de café.

3. O CAFÉ

O café é produzido a partir dos grãos torrados do fruto do [cafeeiro](#) (*Coffea arabica* ou *Coffea robusta*). É servido tradicionalmente quente, mas também pode ser consumido gelado. É bastante aromático e [estimulante](#), devido à presença de elevado teor de [cafeína](#). A propriedade estimulante do café ajuda à diminuição de cansaço ou fadiga e permite aumentar o estado de alerta.

Segundo Martins (2008), o café vem despertando interesse há longo tempo e originando grandes trabalhos de pesquisa. O mesmo, por ser uma bebida estimulante e não alcoólica, torna-se adequado aos ambientes que exigem sobriedade, como é o caso, por exemplo, dos encontros espirituais islâmicos, e isso fez com que o hábito de tomar café se tornasse um ritual de sociabilidade.

O café é uma bebida rica em diversas substâncias, como por exemplo, minerais, aminoácidos, lipídeos, ácidos graxos livres, açúcares e vitaminas do complexo B, apesar de a maioria das pessoas acharem que o café contém apenas ou principalmente cafeína. O mesmo possui de 1 a 2,5% de cafeína, mas apenas a cafeína é termoestável até uma dada temperatura (técnica de análise térmica via TG para determinar a estabilidade da cafeína), isto é, não é destruída com a torrefação

excessiva. As demais substâncias são preservadas, formadas ou mesmo destruídas durante o processo de torra (Em: <http://www.abic.com.br/publicue/cgi/cgilua.exe/sys/start.htm?infoid=161&sid=81>).

Acesso em: 16 agosto de 2011).

4. PROCESSAMENTO DO CAFÉ

O processo de fabricação do café começa na escolha dos grãos, iniciando-se nesta fase o processo que termina na distribuição ao mercado consumidor.

A primeira fase ocorre em laboratórios, onde o controle de qualidade se preocupa com o constante aprimoramento de seus produtos e com um rigoroso controle no padrão de qualidade. A indústria analisa, em laboratórios, todas as amostras de grãos antes do início do processo industrial.

O controle de umidade, granulometria adequada, teste de prova e coloração, dentre outras, são análises feitas periodicamente por profissionais, de modo a garantir o padrão do café a cada novo lote que se envia aos supermercados.

Em seguida, os grãos aprovados são acondicionados em armazém. As sacas serão dispostas de acordo com os diferentes tipos de grãos em *Big Bags*. Fabricados em fibra de polipropileno, os *Bags* são contentores ideais para o transporte e armazenamento dos grãos, facilitando seu manuseio e proporcionando maior proteção e higiene no manuseio.

A fase seguinte, que é a torra do café, é uma das fases mais importante, pois é ela que proporcionará o aroma aos grãos crus do café.

A Indústria Alimentícia Maratá, situada no município de Itaporanga, em Sergipe, na qual será realizados os experimentos do presente trabalho, torra seus grãos em um dos mais avançados sistemas do mundo, o moderno *Turbo Leogap*. O equipamento *Turbo Leogap* é construído em aço inoxidável, o que exclui a possibilidade de qualquer contato do grão torrado com superfícies que possam favorecer o processo de oxidação e contaminação do produto. Isto representa um controle eficiente na qualidade do produto que os consumidores saboreiam, pois desta maneira pode-se extrair da matéria-prima o que de melhor ela possui.

O processo de torra é totalmente computadorizado, o que garante máxima segurança na preservação do sabor e aroma do café, além de uma maior uniformidade na torra. Também, o processo adotado não agride o meio ambiente,

pois, o mesmo, utiliza gás natural e reduz o percentual de contaminação do produto e do ambiente de quase 0%, diferentemente de outros combustíveis, que promovem o desprendimento de substâncias que alteram o sabor e o aroma do produto final, além de poluir o meio ambiente.

Após torrado, o grão segue para um sistema de moagem que funciona através do avançado *Cold System Leogap*, processo realizado pelo sistema chamado de *Cold System Leogap* constituído por moinhos de rolos refrigerados a água. Esse sistema impede o superaquecimento dos rolos moedores, evitando alterações no ponto exato da torra, impedindo a oxidação, e mantendo, assim, o aroma e o sabor ideais do café.

Em seguida, o café é conduzido para as máquinas de empacotamento, as quais operam com um sistema de controle digital de volume. Os pacotes podem ser de forma almofada ou a vácuo. Após o empacotamento, os mesmos são acondicionados em caixas, chegando aos pontos de vendas com suas embalagens preservadas com total controle de qualidade.

5. REDES NEURAIS ARTIFICIAIS

O neurônio, também conhecido como célula nervosa, é um dos principais componentes do sistema nervoso, que tem como função a coordenação das funções dos diferentes órgãos, através da propriedade de receber e transmitir estímulos. Ele apresenta um corpo celular chamado soma do qual partem dois tipos de prolongamentos: os axônios e os dendritos.

Os dendritos têm a função de conduzir sinais das extremidades para o corpo celular, ou seja, eles dão a informação do estímulo e o axônio, que geralmente é uma única ramificação, transmite um sinal do corpo celular para suas extremidades, ou seja, fornece a resposta para o estímulo. As extremidades do axônio são conectadas com dendritos de outros neurônios pelas sinapses, que é um tipo especial de junção. Geralmente, um axônio é diretamente conectado com outros axônios ou com o corpo de outro neurônio (BARRETO, 2002).

Segundo Barreto (2002), as sinapses são responsáveis pela conexão entre os neurônios e transmissão química de impulsos nervosos. Os impulsos nervosos proporcionam, na região das sinapses, liberação de neurotransmissores, que excitam a membrana do dendrito e dá origem à atividade elétrica do outro neurônio.

Sempre que uma sinapse é ativada ou consegue ativar outro neurônio o número de neurotransmissores liberados aumenta na próxima vez que o neurônio for ativado, o que indica uma conexão muito maior entre os neurônios interligados através de suas sinapses. Para este processo foi dado o nome de facilitação e inspirou a conhecida lei de Hebb, segundo a qual a intensidade de uma conexão sináptica entre dois neurônios aumenta quando os dois neurônios estão excitados simultaneamente (BARRETO, 2002).

Do que foi descrito acerca da fisiologia do neurônio, ele pode ser comparado a uma unidade de processamento, pois para os diferentes estímulos é gerada uma resposta que permite ao organismo responder a alterações do meio, ou seja, solucionar problemas.

Na tentativa da construção de máquinas inteligentes, um grande número de pesquisadores buscou simular o comportamento do cérebro humano utilizando os chamados neurônios artificiais. Nos anos 40 do século passado, McCulloch e Pitts obtiveram um dos primeiros resultados de pesquisa na área (MCCULLOCH; PITTS, 1943 apud HAGAN, 1996). Graças à criação dos *perceptrons* e à respectiva regra de aprendizagem proposta por Rosenblatt, foi demonstrado que as redes neurais poderiam ser aplicadas em problemas práticos, como no reconhecimento de padrões (ROSENBLATT, 1958 apud HAGAN, 1996).

De acordo com Barreto (2002), as redes neurais artificiais (RNAs) têm inspiração nos neurônios biológicos e nos sistemas nervosos devido a sua estrutura, topologia de suas conexões e comportamento conjunto desses elementos. Entretanto, atualmente as redes neurais artificiais (RNAs) estão muito distantes das redes neurais naturais (RNNs) e frequentemente essas semelhanças são mínimas.

Matematicamente, as entradas (u_i) são multiplicadas pelos pesos (w_i), resultando em um somatório (ϕ) ao qual se soma um valor chamado de limiar (θ), ou *bias*, resultando no valor que representa o estado de ativação do neurônio (η), o qual pela aplicação de uma função de ativação produz a saída do neurônio. Portanto, a matemática do neurônio artificial básico é algo muito simples.

As RNAs podem ser classificadas de diferentes formas, como por exemplo, de acordo com a sua forma de aprendizado, que pode ser supervisionada e não supervisionada. Pode ainda ser contínua, discreta, determinística, estocástica, redes de múltiplas camadas (*multilayer feedforward network*) e redes recursivas (*recurrent network*).

No aprendizado supervisionado, como o próprio nome já diz, tem que ter a presença de uma pessoa para supervisionar e fazer os devidos ajustes nos dados de saída de acordo com os dados de entrada, até que esses valores tenham uma variação mínima possível com os valores desejados. Isso corresponde operar um procedimento de ajuste dos pesos que são os parâmetros que determinam a resposta da rede.

No aprendizado não-supervisionado, ao contrário do anterior, não se necessita de um supervisor, pois neste caso não ocorre a etapa de ajuste dos dados de saída com os dados desejados, ou seja, para fazer modificações nos valores das conexões sinápticas não se usa informações sobre se a resposta da rede.

Há diferentes etapas para o desenvolvimento de um modelo ou projeto baseado em redes neurais artificiais. Essas etapas estão representadas no fluxograma abaixo e estão descritas em conformidade com Caudill (1991). Têm-se as seguintes etapas: definição do problema, coleta dos dados para o treinamento e teste, pré e pós-processamento dos dados, projeto da estrutura da rede, treinamento, teste e validação.




Figura 1: Fluxograma para o desenvolvimento de um modelo.

Com base em inúmeros estudos disponíveis na literatura, para a grande parte das aplicações em engenharia química, as redes neurais mais adequadas são as redes de camadas múltiplas do tipo direto (*feedforward*) com método de aprendizagem supervisionado e com aplicação utilizando o algoritmo de retropropagação (*backpropagation*). Este tipo de rede neural será considerado no presente trabalho para tentar descrever o comportamento do torrador de café acima descrito em termos de suas variáveis determinantes.

Nas redes de camadas múltiplas, a técnica de aprendizado supervisionado se dá de maneira diferente daquela aplicada a uma rede de camada única, pois as camadas intermediárias não apresentam dados de saída desejados, ou seja, o

cálculo do erro só poderá ser realizado para os neurônios da última camada. Sendo assim, o erro das camadas intermediárias é feito por meio do algoritmo de retropropagação dos erros, que é feito pela estimativa do efeito do erro das camadas intermediárias no erro da camada de saída.

De acordo com a teoria estabelecida, uma RNA pode ser especificada de maneira única se apresentar os seguintes elementos:

- a) Topologia da rede: Conjunto de interligações dos neurônios;
- b) Algoritmo de aprendizagem: Define como os pesos da rede neural, e eventualmente suas conexões, são alterados durante o treinamento;
- c) Codificação dos dados de entrada: Em muitos casos os dados de entrada devem ser convertidos para uma representação diferente daquela original;
- d) Decodificação dos valores de saída: As saídas correspondem a valores numéricos contínuos. Se esta não for a representação desejada, ela deve ser convertida para o formato adequado.

6. VANTAGENS E DESVANTAGENS DE REDES NEURAIS

De acordo com Santos (2010), as principais vantagens em se utilizar uma rede neural se relacionam a um menor tempo de implementação, à boa capacidade de generalização, à possibilidade de adaptação a novas situações e ao auto-aprendizado.

Como desvantagens devem ser destacadas a necessidade de um grande volume de dados de treinamento, a falta de regras gerais para estabelecer a paramétrica da rede, tais como: número de camadas ocultas, número de neurônios em cada uma das camadas, percentagem de dados que deve ser destinada ao treinamento e ao teste da rede.

Deve-se destacar ainda que na aplicação de redes neurais não se chega ao motivo pelo qual a rede conduz a uma dada conclusão depois de treinada, ou seja, a mesma funciona como uma espécie de caixa-preta, e não permite, portanto, extrair explicações para os resultados apresentados.

7. REDES DIRETAS (*FEEDFORWARD*)

Uma rede neural direta (*feedforward*) é formada por uma ou mais camadas de unidades de processamento não-lineares. As conexões entre unidades de camadas adjacentes são definidas por um conjunto de pesos sinápticos. No entanto, para ser uma rede neural direta é necessário que suas saídas se conectem somente com as unidades da próxima camada (NEVES, 2006).

Em uma rede neural direta (*feedforward*), a organização dos neurônios é feita em camadas sucessivas. Os sinais de entrada percorrem a rede da camada de entrada, passando pela(s) camada(s) oculta(s) até a camada de saída, por meio de conexões que percorrem uma única direção entre os neurônios de camadas subsequentes. Redes desse tipo são frequentemente chamadas de redes de retropropagação ou redes multicamadas e são as mais aplicadas em problemas de engenharia química (BULSARI, 1995, *apud* SANTOS, 2010).

De acordo com Haykin (1999), o número de neurônios na camada oculta deve mudar com o número de exemplos para o treinamento da rede, sendo poucas unidades de processamento necessárias se a quantidade de exemplos é pequena. Se um ajuste altamente não-linear é necessário, mais neurônios na camada oculta devem ser utilizados.

Faz-se necessário, de acordo com Santos (2010), conhecer o número de neurônios de processamento, pois se o mesmo for muito grande, o modelo pode se sobreajustar aos dados, situação conhecida como *overfitting*. De modo inverso, se o número de neurônios na camada oculta for insuficiente, o mapeamento da função não será adequado, o que caracteriza uma situação de subajuste ou *underfitting*.

A escolha do número de camadas ocultas e de neurônios é geralmente feita empiricamente, por um procedimento de tentativas, já que não existe um procedimento geral teoricamente fundamentado para fazer esta determinação (OSTAFE, 2005).

8. RETROPROPAGAÇÃO

A retropropagação consiste em um método de aprendizado supervisionado em que o erro calculado na camada de saída é utilizado para encontrar aquele das camadas intermediárias através da propagação do mesmo para trás – isto explica a origem do nome do método. Esse processo é feito de forma repetitiva até que o erro

de predição da rede neural atinja um valor menor do que uma dada tolerância estipulada.

No algoritmo de retropropagação a entrada é apresentada e propagada para frente (etapa avante do algoritmo) através da rede, calculando as ativações para cada unidade de saída. Cada unidade de saída é comparada com o valor desejado, resultando em um valor de erro. Na sequência, calculam-se os erros em cada unidade e são realizadas alterações nos pesos (etapa de retorno do algoritmo).

9. APRENDIZADO

De acordo com Neves (2006): “A caracterização de um sistema como rede neural geralmente implica na capacidade de o mesmo aprender. Aprendizado é o processo pelo qual uma rede neural adquire a habilidade de responder corretamente a estímulos, através do ajuste de parâmetros internos de acordo com algum esquema de aprendizado. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.”

Em redes neurais artificiais, o aprendizado não procura obter regras como na abordagem simbólica clássica da Inteligência Artificial, mas proporciona um procedimento para determinar a intensidade de conexões (pesos) entre os neurônios (BARRETO, 2002).

O aprendizado em uma RNAs se faz através da apresentação de exemplos. Para um determinado conjunto de dados, o algoritmo de aprendizado deve ser responsável pela adaptação dos parâmetros da rede, de maneira que, em um número finito de iterações do algoritmo, haja convergência para uma solução. O critério de convergência varia de acordo com o algoritmo e com o paradigma de aprendizado, mas pode envolver, por exemplo, a minimização de uma função-objetivo, a variação do erro de saída ou mesmo a variação das magnitudes dos vetores de peso da rede (KARRER *et al.*, 2005).

O processo de aprendizado ocorre através de estímulo da rede pelo meio externo com a apresentação do conjunto de dados. Com isso, o algoritmo de aprendizado provoca mudança nos parâmetros da rede e, finalmente, a mudança nos parâmetros implica em mudança no comportamento da RNA. Espera-se que a mudança gradual no comportamento da rede resulte em melhoria gradativa do seu desempenho.

10.RESULTADOS E DISCUSSÃO

Para estudar o desempenho do torrador de café aplicando redes neurais, será coletado os dados de um dos torradores da Indústria Alimentícia Maratá. Esses dados serão usados para treinamento de redes neurais diretas de camadas múltiplas (*feedforward*), visando obter uma arquitetura que representasse o comportamento do torrador de café considerado.

As variáveis de entrada consideradas serão: tempo de torra (T_t), temperatura de corte (T_c), temperatura de aromatização (T_a), volume de água (V_a), temperatura da fornalha (T_f), temperatura da câmara no instante de entrada do grão (T_e), consumo de gás (C_g), temperatura do ar entrando na câmara durante o corte (T_{ar}) e massa de entrada do grão (M_e). Em um primeiro olhar sobre o sistema, estas variáveis serão consideradas como definidoras do desempenho do sistema.

As variáveis de saída consideradas serão: massa de saída (M_s), temperatura do grão na saída do torrador (T_s), cor (C) e umidade (U_m). Estas variáveis são definidoras do desempenho do processo, devendo-se destacar que em termos de qualidade do produto têm-se a cor e a umidade como parâmetros mais relevantes.

Através do monitor de vídeo do painel pode-se acompanhar o processo e saber o estado de cada parte da máquina, instantaneamente. Em uma rápida observação, pode-se verificar: em que temperatura se encontra o café nas câmaras de torra ou a temperatura da fornalha; a quantidade de água injetada durante a aromatização; quanto tempo o café está no processo de torra na câmara de torra e outras informações.

No painel de controle, o operador define as programações de temperaturas necessárias para o ponto (cor) correto do café e apenas acompanha o resultado da torra para possíveis correções.

A cor, a umidade e as massas de entrada e de saída não são registradas no monitor do equipamento. Entretanto, estas variáveis são necessárias, pois o sabor do café está relacionado com a cor, o rendimento da torra com as massas de entrada e de saída e a questão da segurança com a umidade. Estas variáveis são disponíveis a partir de informações de laboratório para cada torra feita.

Para testar a aplicação de redes neurais os dados coletados do processo serão utilizados para gerar duas matrizes associadas ao treinamento e teste da rede: uma com o conjunto das variáveis de entrada e outra com o conjunto das variáveis de saída. Estas matrizes geradas são apresentadas no Anexo A deste trabalho.

Então, para aplicar redes neurais à modelagem do torrador de café, será implementado um programa específico, utilizando-se o ambiente de programação *MatLab*. Com isso, será possível testar vários parâmetros associados a diferentes arquiteturas de rede formadas a partir das variáveis operacionais.

O programa, cuja listagem é apresentada no Anexo B deste trabalho, foi estruturado para permitir considerar diversas arquiteturas de rede em termos de variáveis de entrada e de saída. Assim, por exemplo, pode-se considerar uma rede com a arquitetura entrada-saída, envolvendo todas as variáveis descritas, mas também arquiteturas mais simples onde as entradas e as saídas são tomadas como subconjuntos das variáveis.

Várias simulações foram realizadas, testando-se os diferentes parâmetros associados a uma rede direta de camadas múltiplas. Notadamente, verificou-se a influência da arquitetura da rede (camadas e número de neurônios em cada camada), o algoritmo de treinamento, a função de ativação, a sistemática de treinamento (com ou sem validação) e o número de épocas. As simulações visaram chegar a uma estrutura de rede que melhor representasse o comportamento do sistema.

Primeiramente foi testada uma arquitetura de rede envolvendo todas as variáveis, na forma do modelo entrada-saída. Os resultados estão representados nas Figuras 2 e 3. Na Figura 2, está a representação do treinamento das variáveis de entrada sobre a variável de saída massa, ou seja, foi colocada todas as variáveis de entrada coletadas para o presente trabalho, juntamente a todas as variáveis de massa de saída, pois assim, teremos a influência dessas variáveis de entrada sobre a variável massa de saída. Já na Figura 3, está o teste, ou seja, foi colocada alguns dados das variáveis de entrada de forma aleatória(algumas linhas da matriz com as variáveis de entrada) juntamente a suas variáveis massa de saída(correspondente as de entrada utilizadas). Verifica-se que se consegue um treinamento razoável, mas sem uma predição adequada. Este mesmo comportamento ocorre para as demais

variáveis de saída (umidade, cor e temperatura de saída do grão), mas as mesmas não tiveram um bom resultado.




Figura 2: Gráfico de treinamento (massa de saída).




Figura 3: Gráfico de teste (massa de saída).

Outras simulações foram feitas, como por exemplo, foram correlacionadas as variáveis de entrada, individualmente, com as variáveis de saída, para assim, verificar quais variáveis de entrada tem uma maior influência sobre as variáveis de saída e qual variável de saída tem uma maior influência no processo como um todo.

Após várias simulações, foi notado que havia uma relação entre a variável tempo de residência e as variáveis massa de saída e cor. Os gráficos de teste para a massa de saída e a cor em função do tempo de residência, são mostrados nas Figuras 4 e 5.

Como pode ser notado, eles apresentaram um bom resultado, tendo apenas a presença de um pico que pode ser devido a alguma falha de processo.




Figura 4: Gráfico da massa de saída (teste).




Figura 5: Gráfico da cor (teste).

11. CONCLUSÃO

Em relação à temática tratada, deve-se destacar, a partir das múltiplas simulações realizadas e dos resultados obtidos, que a modelagem do torrador de café mostrou-se difícil de ser realizada. Isso deve ser atribuído, de fato, à baixa representatividade do conjunto de dados de treinamento que foi possível de ser coletado a partir da operação do torrador de café objeto deste estudo. De fato, uma análise dos dados mostra que as variáveis de desempenho do sistema (cor, umidade, temperatura de saída do grão e massa de saída) não apresentam uma gama de variação capaz de permitir a extração de conhecimento no processo de treinamento da rede neural. Isso ocorre porque industrialmente as variáveis encontram-se estabelecidas para que o equipamento funcione em regime permanente, sob condições de produção tais que garantam a qualidade do produto.

Portanto, para avançar no estudo da modelagem do torrador de café aplicando-se redes neurais seria necessário dispor de um conjunto de dados mais representativos, envolvendo uma gama maior de variação das variáveis definidoras do desempenho do sistema.

12. ABSTRACT

The project of modeling of a roasting machine for coffee will be done using techniques of artificial neural networks with study of the performance of a roasting machine based on the models of the type black box. With this, it is not necessary the phenomenological knowledge system. The data for the training of the neural network will be collected in a roasting machine for coffee from the Food Industry Marata, located in the municipality of Itaporanga d'Ajuda in Sergipe. The input variables are those that store information provided, such as for example, the temperature of the furnace, temperature cut among others. Already the output variables, store processed data as the mass of output, color, moisture and temperature output. Based on data obtained from the process will be carried out several simulations to check the applicability of the technique of neural networks the description of system behavior. Various parameters and network architectures will be tested until you find the model that best represents the system of a roasting machine for coffee.

Keywords: mathematical Modeling; artificial neural Networks; a Roasting Machine for coffee.

13. REFERÊNCIAS

BARRETO, J. M. **Introdução às Redes Neurais Artificiais**. Laboratório de Conexão e Ciências Cognitivas – UFSC, Florianópolis – SC, 2002.

BULSARI, A. B. (Ed.). **Neural Networks for Chemical Engineers**. Amsterdam, The Netherlands: Elsevier Science, 1995. 680 p.

CAUDILL, M. **Expert Network**. Byte. October. 1991. pp 108-116.

DAWSON, C. W.; WILBY, R. L.; HARPHAM, C.; BROWN, M. R.; CRANSTON, E.; and DARBY, E. J.(2000). **Modelling Ranunculus Presence in the Rivers Test and Itchen Using Artificial Neural Networks**. *GeoComputation*, 2000.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. **Neural network Design**. Boston: PWS, 1996.

HAYKIN, S. **Neural Networks: a comprehensive foundation**. 2. Ed. New Jersey: Prentice Hall. 1999. 842 p.

KARRER, D.; CAMEIRA, R. F.; VASQUES, A. S.; BENZECRY, M. A. **Redes neurais artificiais: conceitos e aplicações**. Profundão – IX Encontro de Engenharia de Produção da UFRJ, 2005.

MARTINS, A. L. **História do café**. São Paulo: Contexto, 2008. 316 páginas, ilustrado.

NEVES, M. V. **Uma (Breve) Introdução as Redes Neurais Artificiais**. Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre – RS, 2006.

OSTAFE, D. **Neural Network Hidden Layer Number Determination Using Pattern Recognition Techniques**. In: ROMANIAN-HUNGARIAN JOINT SYMPOSIUM ON APPLIED COMPUTATIONAL INTELLIGENCE, 2, 2005, Timisoara, Romania. *Paper...*Suceava: Universitatii Stefan cel Mare, 2005.

PINTO, J. C.; LAGE, P. L. C. **Métodos numéricos em problemas de Engenharia Química**. Programa de Engenharia Química/ COPPE - Universidade Federal do Rio de Janeiro, 1997.

SANTOS, R. M. **Aplicação de redes neurais à modelagem de reator de leito fixo para reação de oxidação do Etanol a Acetaldeído**. Trabalho de Conclusão de Curso – Universidade Federal de Sergipe (UFS), São Cristóvão – SE, 2010.

<http://www.revistacafeicultura.com.br/index.php?mat=3278&tipo=ler>. Acesso em: 16 de agosto de 2011.

<http://www.abic.com.br/publique/cgi/cgilua.exe/sys/start.htm?inoid=161&sid=81>. Acesso em: 16 de agosto de 2011.

<http://www.planetaorganico.com.br/cafebrev1.htm>. Acesso em: 06 de abril de 2011.

ANEXO A: DADOS OPERACIONAIS DO TORRADOR DE CAFÉ

Tabela A1: Matriz de variáveis de entrada.

Tt	Tc	Ta	Va	Tf	Te	Cg	Tar	Me
262	256,2	266,2	49,1	669	163,9	2	476	270,8
282	253,3	263,4	49,1	659	161,4	2,222	454	269,9
252	256,2	266,2	49,1	666	165,6	2	474	270,3
275	253,3	263,4	49,1	659	167,7	2,222	470	269,7
263	256,2	266,2	49,1	660	164,6	2	473	270,6
269	253,4	263,3	49,1	665	158,8	2	468	269
276	255,6	265,7	49,1	667	165,7	2,222	469	270,2
264	252,9	262,9	49,1	653	173,9	2	470	270,8
273	255,6	265,6	49,1	656	211,6	2	467	270,4
266	252,9	262,9	49,1	667	160	2	467	270,4
268	255,6	265,7	49,1	667	161,2	2,222	473	268,7
269	252,9	262,9	49,1	652	166	2	461	270,5
269	255,7	265,7	49,1	663	157,2	2,222	474	269,4
269	252,9	262,9	49,1	656	166,5	2	471	270,2
267	255,7	265,7	49,1	661	160,3	2,222	469	270,5
285	252,9	262,9	49,1	656	170,3	2,222	465	271
264	255,6	265,7	49,1	663	160	2	472	270,1

268	252,9	262,9	49,1	656	225,7	2	469	268,8
264	255,7	265,7	49,1	657	162	2	472	271,1
268	252,9	262,9	49,1	655	164,3	2	468	270,4
271	255,7	265,7	49,1	668	165,4	2,222	470	268,6
268	252,9	262,9	49,1	660	166,6	2	466	270,2
270	255,6	265,7	49,1	662	160,4	2,222	473	270,2
268	252,9	262,8	49,1	656	163,5	2	471	270,4
268	255,7	265,6	49,1	659	155,3	2	470	269,9
268	252,9	262,9	49,1	656	160,1	2	467	271
267	255,7	265,7	49,1	668	154,4	2	471	269,2
283	252,9	262,9	49,1	654	165,9	2,222	444	270,9
258	255,7	265,7	49,1	667	146,6	2	471	269,6
293	252,9	262,8	49,1	652	159,8	2,222	463	269,3
265	253,6	263,6	48,1	657	169,6	2	470	270,5
267	256,3	266,3	48,1	663	160,7	2	472	269,4
267	253,5	263,5	48,1	659	180,4	2	470	270,9
264	256,3	266,3	48,1	661	163,6	2	470	269,9
283	253,7	263,6	49,1	655	167	2,222	469	270,7
250	256,2	266,8	49,1	656	168,5	2	471	269,6
271	253,6	263,6	49,1	661	174,5	2	472	269,4
257	256,3	266,4	49,1	665	161	2	481	269,6
263	253,4	263,4	49,1	670	173,2	2	472	270,1
266	256,1	266,1	49,1	661	162,1	2	477	269,4
263	253,4	263,4	49,1	654	169,8	2	467	269,4
267	256,2	266,2	49,1	671	151,8	2,222	474	270,5
258	256,1	266,2	49,1	662	158,1	2	476	269,3
273	253,4	263,4	49,1	662	171,1	2,222	468	269,7
258	256,2	266,2	49,1	694	150,3	2	476	270,3
277	253,4	263,4	49,1	655	163,2	2,222	472	270,8

264	256,2	266,2	49,1	660	153,8	2	474	271,2
270	253,3	263,3	49,1	652	165,2	2	471	264,6
267	256,2	266,2	49,1	665	163,1	2	472	271,2
271	253,3	263,4	49,1	658	163,8	2,222	467	264,2
267	256,2	266,2	49,1	660	156,2	2	476	272
267	253,4	263,3	49,1	654	167,4	2	469	269,1
270	256,2	266,2	49,1	669	159,1	2,222	471	270,1
307	253,4	263,4	49,1	656	170,7	2,444	460	270,9
262	257,1	267,1	49,1	678	155,4	2	480	269,5
286	254,1	264,1	49,1	659	161,2	2,222	451	270,3
259	257,1	267,1	49,1	678	155,3	2	473	269,9
291	254,1	264,1	49,1	656	167,4	2,222	450	270,2
254	257,1	267	49,1	673	159,3	2	478	270,5
280	254	264	49,1	653	160,4	2	468	269,5
249	241,4	251,4	45,1	643	130,2	2,444	390	270,2
299	243,3	253,1	44,1	656	199,1	2,889	432	270,1
253	244,6	254,6	45,1	650	178,8	2,444	433	270,1
283	244,5	254,6	44,1	654	205,4	2,667	438	270,3
258	244,6	254,6	45,1	648	211,5	2,444	427	269,6
243	244,6	254,6	44,1	651	211	2,667	437	270,2
260	244,6	254,6	45,1	650	185,7	2,444	438	269,5
267	244,6	254,6	45,1	654	237,8	2,444	443	270,2
266	244,6	254,6	46,1	651	187,5	2,444	440	270
276	244,6	254,5	45,1	651	208,8	2,444	443	270,6
265	244,6	254,6	46,1	651	185,1	2,444	443	269,5
267	244,6	254,5	45,1	646	240,1	2,222	438	270,2
265	244,6	254,6	46,1	650	178,1	2,444	442	269,9
267	245,1	255,1	45,1	650	209,9	2,222	440	267
276	244,6	254,6	46,1	651	184,3	2,444	444	270,4
278	245,1	255,1	45,1	650	211,7	2,444	442	269,5

266	244,6	254,6	46,1	648	219,5	2,444	442	270,6
284	245	255,1	45,1	652	245,7	2,444	444	268
287	244,6	254,6	46,1	651	191,9	2,444	438	271,4
499	245,1	255,1	45,1	648	229,1	5,333	392	269,8
294	245,1	255,1	45,1	649	206	2,667	431	270
260	244,5	254,6	46,1	650	142,3	2,222	435	270,4
282	245,1	255,1	45,1	646	178	2,444	434	270,2
262	244,6	254,6	46,1	649	190,3	2,222	437	269,4
274	245,1	255,1	45,1	648	214,4	2,444	436	270,4
266	244,5	254,6	46,1	651	193,7	2,222	442	270,2
270	245,1	255,1	45,1	647	209	2,222	436	270,5
299	244,5	254,6	46,1	653	194,4	2,667	436	269,5
182	230,1	253	25,1	657	167,3	1,556	414	172,1

Tt: Tempo de torra (s)

Tc: Temperatura de corte (°C)

Ta: Temperatura de aromatização (°C)

Va: Volume de água (L)

Tf: Temperatura da fornalha (°C)

Te: Temperatura da câmara na entrada do grão (°C)

Cg: Consumo de gás (m³/saca de 60Kg)

Tar: Temperatura do ar que ta entrando na câmara durante o corte (°C)

Me: Massa de entrada (Kg)

Tabela A2: Matriz de variáveis de saída.

Ms	C	Um	Ts
225	84	3,46	72,6

227	84	3,39	73,9
226	85	3,3	72,5
226	86	3,59	72,7
225	86	3,73	72,2
225	86	3,24	74,6
226	86	3,38	71,1
224	86	3,73	71,9
225	86	3,32	72,1
226	86	3,38	72,5
224	86	3,41	72,4
224	86	3,16	74,1
226	86	3,41	72,7
224	86	3,4	73,2
225	86	3,54	72,3
226	86	3,45	70,7
225	86	3,33	72,4
225	86	3,11	74,6
224	86	3,29	71,9
224	87	3,11	74,8
225	86	3,46	72,2
226	86	2,89	72,4
226	86	3,54	72,3
226	86	3,48	72,1
225	86	3,54	72
226	86	3,48	73,7
226	86	3,54	72,2
226	86	3,37	71,6
225	86	3,34	72,8
226	86	3,04	74,5
224	84	2,91	75,8

224	84	2,8	74,6
222	86	3,08	75,7
224	88	3,19	73,7
222	84	3,31	72,6
226	88	3,16	72,2
223	84	3,24	73,8
224	84	3,13	71,2
225	85	3,3	72,9
225	87	3,01	71,6
225	85	3,2	73,4
224	87	3,1	71,6
226	88	3,58	72,1
225	86	3,23	74,5
224	85	3,19	71,9
224	86	2,94	74,3
224	87	3,21	72,3
224	86	3,11	72,4
226	89	3,5	72,2
224	89	3,64	71,9
223	86	3,21	72,1
224	87	3,69	74,4
225	86	3,25	70,4
225	87	3,65	71,9
224	86	3,49	72,6
225	86	3,39	74,6
226	85	3,62	72,5
224	86	3,23	73,8
225	88	3,4	72,9
224	88	3,42	74,4
239	107	3,2	67,3

237	107	3,3	64,4
238	102	3,1	73,2
238	104	3	55,5
238	98	2,9	74,8
238	100	3,1	69,3
237	101	3,1	75
237	100	3	72
238	101	3,3	74,2
238	102	2,4	70,9
239	101	3,4	74,4
238	104	3,3	53,3
237	99	3,2	75,4
238	101	3,2	53,2
237	100	3,4	73,4
237	100	3,2	61,4
236	98	3,1	77,4
237	99	3,3	54,8
235	100	3,2	78,3
238	101	2,9	54,4
237	99	3,3	50,6
237	97	3,3	74,2
237	102	3,3	51,2
237	99	3,4	75,3
237	101	3,4	52,7
236	100	3,3	75,1
238	101	3,3	50,3
237	101	3,4	68,8
153	99	3,1	49,2

Ms: Massa de saída (kg)


```

net = newff(trn,alvotr,[8]); % definição da rede (8 é o número de neurônios)

net.trainparam.goal=1e-10;

net.trainparam.epochs=1000;

net.divideFcn=''; % comando para desativar a função de divisão de treinamento, validação e teste.

%net.divideParam.trainRatio = 0.1; %dividerand

%net.divideParam.testRatio = 0.2;

%net.divideParam.valRatio = 0.2;

[net,ts] = train(net,trn,alvotr); % treinamento da rede

y = sim(net,trn); % simulação após a rede treinada

ytest = sim(net,test);

na = 1:60;
ns = 1:29;

% treinamento

figure(1)
plot(na,alvotr(1,:), 'k',na,y(1,:), 'b--');
xlabel('Número da amostra');
ylabel('Massa de saída (kg)');
legend('Real', 'Predito');
title('Treinamento')

figure(5)
plot(ns,alvotest(1,:), 'k',ns,ytest(1,:), 'b--');
xlabel('Número da amostra');
ylabel('Massa de saída (kg)');
legend('Real', 'Predito');
title('Teste')

figure(2)
plot(na,alvotr(2,:), 'k',na,y(2,:), 'b--');
xlabel('Número da amostra');
ylabel('Cor');
legend('Real', 'Predito');
title('Treinamento')

```

```
figure(6)
plot(ns,alvotest(2,:), 'k', ns,ytest(2,:), 'b--');
xlabel('Número da amostra');
ylabel('Cor');
legend('Real', 'Predito');
title('Teste')

figure(3)
plot(na,alvotrnr(3,:), 'k', na,y(3,:), 'b--');
xlabel('Número da amostra');
ylabel('Umidade(%)');
legend('Real', 'Predito');
title('Treinamento')

figure(7)
plot(ns,alvotest(3,:), 'k', ns,ytest(3,:), 'b--');
xlabel('Número da amostra');
ylabel('Umidade(%)');
legend('Real', 'Predito');
title('Teste')

figure(4)
plot(na,alvotrnr(4,:), 'k', na,y(4,:), 'b--');
xlabel('Número da amostra');
ylabel('Temperatura de saída do grão (°C)');
legend('Real', 'Predito');
title('Treinamento')

figure(8)
plot(ns,alvotest(4,:), 'k', ns,ytest(4,:), 'b--');
xlabel('Número da amostra');
ylabel('Temperatura de saída do grão (°C)');
legend('Real', 'Predito');
title('Teste')
```