

Aplicação de redes neurais artificiais na indústria de fios de algodão

Artificial neural nets application in the cotton yarn industry

Gilberto Clóvis Antoneli¹ – Universidade Estadual de Maringá – Departamento de Engenharia de Produção
Ivo Neitzel² – Faculdade de Telêmaco Borba – Curso de Engenharia Química

RESUMO A competitividade no setor de produção de fios fez as empresas buscarem soluções para a obtenção de um fio com qualidade e baixo custo. Hoje, o diferencial entre elas e, desta forma, o do setor, está na matéria-prima, ou seja, o algodão processado e suas características. Existem diversos tipos de algodão, com características diferenciadas, fato que se deve à região de produção, à safra, ao armazenamento e ao transporte. As indústrias de fios trabalham com misturas de fibras de algodão, o que dificulta a determinação da qualidade do fio produzido a partir das características das fibras processadas. Neste trabalho, utilizam-se dados de um processo de fiação convencional, sendo alimentado com matéria-prima de composição 100% de algodão, e apresenta-se uma solução com redes neurais artificiais que determina as informações da qualidade do fio, utilizando os valores das características das fibras e definições de alguns ajustes do processo. Nessa solução utiliza-se uma rede neural artificial do tipo *MultiLayer Perceptron* com 11 neurônios na entrada (8 características da fibra e 3 ajustes do processo), 7 neurônios na saída (qualidades do fio) e dois tipos de treinamento, o *Back propagation* e o *Conjugate gradiente descent*. Descreve-se a seleção e organização dos dados de produção da indústria de fios da empresa cocamar[®] indústria de fios, para aplicar as redes neurais artificiais desenvolvidas. Na aplicação de redes neurais para determinar a qualidade do fio, conclui-se que, apesar de não possuir precisão ideal quanto aos valores absolutos, a solução apresentada representa uma excelente ferramenta para definir as variações das qualidades do fio quando se altera a composição da matéria-prima. O sistema desenvolvido permite realizar simulações para definir o percentual de mistura na matéria-prima a ser processada na fábrica com a utilização de informações dos fardos de algodão em estoque, desta forma pode-se obter uma mistura que mantenha a estabilidade de todo o processo produtivo.

Palavras-chave Fiação. Algodão. Redes neurais artificiais.

ABSTRACT *The competitiveness in the yarn production sector has led companies to search for solutions to attain quality yarn at a low cost. Today, the difference between them, and thus the sector, is in the raw material, meaning processed cotton and its characteristics. There are many types of cotton with different characteristics due to its production region, harvest, storage and transportation. Yarn industries work with cotton mixtures, which makes it difficult to determine the quality of the yarn produced from the characteristics of the processed fibers. This study uses data from a conventional spinning, from a raw material made of 100% cotton, and presents a solution with artificial neural nets that determine the thread quality information, using the fibers' characteristics values and settings of some process adjustments. In this solution a neural net of the type MultiLayer Perceptron with 11 entry neurons (8 characteristics of the fiber and 3 process adjustments), 7 output neurons (yarn quality) and two types of training, Back propagation and Conjugate gradient descent. The selection and organization of the production data of the yarn industry of the cocamar[®] indústria de fios company are described, to apply the artificial neural nets developed. In the application of neural nets to determine yarn quality, one concludes that, although the ideal precision of absolute values is lacking, the presented solution represents an excellent tool to define yarn quality variations when modifying the raw material composition. The developed system enables a simulation to define the raw material percentage mixture to be processed in the plant using the information from the stocked cotton packs, thus obtaining a mixture that maintains the stability of the entire productive process.*

Keywords Yarn industries. Cotton. Artificial neural nets.

1. Avenida Colombo, 5.790, Jardim Universitário, Maringá, Paraná, CEP 87020-900, gcantonelli@uem.br
2. ivo.neitzel@fateb.br

ANTONELI, G. C.; NEITZEL, I. Aplicação de redes neurais artificiais na indústria de fios de algodão. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, Ano 11, nº 2, abr-jun/2016, p. 1-20.

DOI: 10.15675/gepros.v11i2.1355

1. INTRODUÇÃO

A política de abertura comercial instalada no país a partir de 1990, com a redução acelerada das alíquotas de importação, submeteu as empresas da cadeia têxtil a um processo vital de reestruturação. Criou-se um ambiente de competição - nacional pela ampliação ou manutenção de mercados e internacional pela busca de novas oportunidades.

Desta forma, nesse novo ambiente, o processo de reestruturação se desenvolveu no sentido da capacitação tecnológica, da adequação do modelo empresarial, da melhoria da qualidade e do aumento da produtividade.

A fiação, um dos segmentos da cadeia têxtil, também teve que se adequar à essa nova realidade de mercado. “A importância das fiações na cadeia têxtil e em todas as partes do mundo é verificada pelo processamento mundial de fibras, que está acima de 80 milhões de toneladas/ano” (ABIT, 2013).

As fibras utilizadas nas fiações são de origem natural ou artificial e entre as fibras naturais está o algodão, uma das mais importantes fibras têxteis.

No Brasil, durante a safra de 2013, o algodão representou aproximadamente 54% da matéria-prima das fiações (ABIT, 2014). O custo da matéria-prima, no caso do fio de algodão, representa 95% do custo final do fio produzido (LIMA, 2000). Portanto, o conhecimento das características físicas das fibras de algodão e a sua influência no processo, constituem pontos fundamentais para o alcance de melhores índices de produção e de qualidade a baixo custo.

A influência das características da fibra na qualidade final do fio produzido não é simples de ser analisada, porque existem outros fatores externos que determinam essa qualidade, como, por exemplo, a safra, o acondicionamento da matéria-prima (temperatura e umidade), os ajustes das variáveis do processo, a porcentagem de misturas de fibras utilizadas no processo, dentre outros.

Portanto, é essencial o desenvolvimento de ferramentas aplicadas ao processo produtivo das indústrias de fio de algodão que auxiliem na decisão da determinação das condições de operação da fábrica, a fim de que esta produza o fio desejado com o algodão disponível.

Neste trabalho, é apresentada uma solução com redes neurais artificiais para determinar as qualidades do fio produzido por uma mistura de fibras de algodão. A metodologia desenvolvida disponibiliza as informações de qualidade do fio produzido, utilizando os valores das características das fibras e a definição de alguns ajustes do processo. Por meio desta metodologia, o engenheiro da indústria pode simular a produção de um fio, definir os ajustes das variáveis do processo, otimizar o uso da matéria-prima, melhorar a qualidade do fio e obter uma constante no processo produtivo com menores índices de quebra e de ruptura.

2. REFERENCIAL TEÓRICO

2.1. A indústria de fios

Na fiação, a tecnologia está voltada ao estudo da produção de fios. Neste contexto a palavra fiação “refere-se à conversão de grande quantidade de fibras individuais não ordenadas, de comprimento relativamente curto, em um produto linear, ordenado e de comprimento muito grande, utilizando dispositivos e máquinas apropriadas” (RIBEIRO, 1984).

Na indústria têxtil brasileira a fibra que mais se destaca é o algodão e segundo ABIT (2014), na safra 2013 seu consumo foi de aproximadamente 54% do total de fibras consumidas e 98% do total de fibras naturais consumidas.

No processo de fiação do algodão a matéria-prima representa em torno de 95% do custo de produção do fio (LIMA, 2000). Este fato isolado é suficiente para indicar a importância da matéria-prima no processo de produção de fio.

O processo de produção de fio possui duas tecnologias consagradas, *open end* e convencional. Na tecnologia *open end* se utiliza filatórios a rotor e na tecnologia convencional filatórios a anel. Devido a esse fato, essas tecnologias também são conhecidas como rotor e anel, respectivamente. “A tecnologia a ser adotada depende de vários fatores relacionados com o fio que se deseja produzir e a qualidade desejada desse fio” (MAURO, 2002).

2.2. Características das fibras de algodão

As características físicas das fibras de algodão são ferramentas importantes e seu conhecimento permite decidir quanto à sua forma de consumo e os ajustes das variáveis do processo de fiação. Para tanto, é necessário medir e avaliar os valores das principais características das fibras, relacionando-os com o sistema de fiar e com o produto a elaborar.

As principais características da fibra de algodão são: o comprimento, a uniformidade do comprimento, a espessura (*micronaire*), a maturidade, a resistência, o tipo, a umidade e o de *honeydew* ou caramelização, que representa a quantidade aceitável de açúcar presente no algodão para o sistema de fiação em uso (LEWIN PEARCE, 1985).

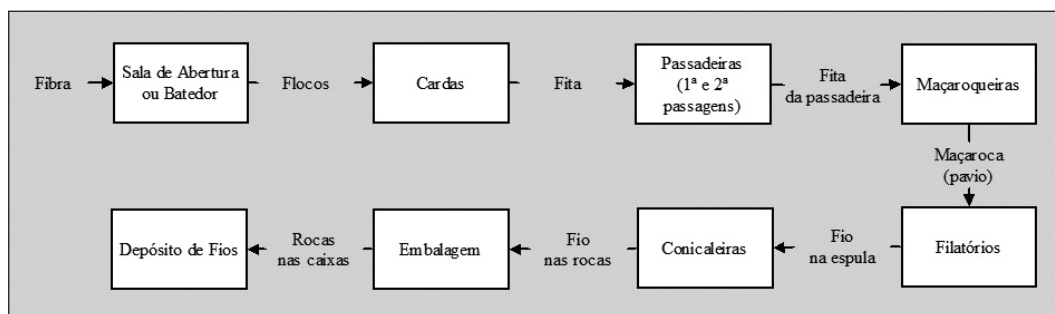
Existe forte correlação entre as próprias características da fibra e também forte correlação entre a qualidade do fio e as características da fibra (LIMA, 1992).

2.3. O processo fabril das fiações convencionais

O sistema de fiação convencional, desde a sua criação, descrito por Crespim e Neves (2000), segue basicamente os mesmos princípios: abertura, limpeza, cardagem, paralelização das fibras e fiação (com estiragem, torção e enrolamento). Na Figura 1 tem-se o fluxograma simplificado do processo de fabricação de fios com a denominação dada à fibra após cada etapa.

Após cada etapa do processo, o material produzido fica armazenado em áreas destinadas a esse fim, deste modo, tem-se dentro da indústria estoques reguladores do processo.

Figura 1 – Fluxograma simplificado do processo convencional de produção de fios.



Fonte: Elaborado pelos autores (2014).

2.4. Qualidades do fio produzido

A qualidade do fio produzido é medida de acordo com suas características físicas e mecânicas. As principais são: o Título, a variação de massa ao longo do fio (USTER), o Coeficiente de variação do USTER (CV (%) USTER), o número de NEPS, o número de pontos finos, o número de pontos grossos, a tenacidade e o número de rupturas (GORDEEV; VOLKOV, et al., 1987).

2.5. Misturas programadas de matéria-prima

As indústrias de fio trabalham com misturas programadas de matéria-prima objetivando diminuir os custos; entretanto, a economia excessiva em relação à matéria-prima geralmente não reduz custo, levando às vezes a deterioração da processabilidade da fábrica (KLEIN, 1985).

Existem diversos tipos de algodão que possuem características diferenciadas, relacionadas à região de produção, à safra, ao armazenamento e ao transporte, o que torna impossível, após um processo de mistura, determinar com precisão a qualidade do fio que será produzido, ou ainda, definir o ponto economicamente ideal de mistura (produção de um determinado fio com propriedades definidas com o menor custo possível).

Geralmente, as fiações ajustam o processo produtivo por meio de métodos de tentativas e erros baseados no conhecimento e/ou experiência adquirida, pelos seus técnicos, ao longo do tempo. Esta situação leva as indústrias a atravessar, durante o ano, períodos de instabilidade no seu processo produtivo, gerando produtos com baixa qualidade e pouco valor agregado.

2.6. Redes neurais artificiais

Redes neurais artificiais é um conceito da computação que visa trabalhar o processamento de dados de maneira semelhante ao cérebro humano. Nas redes neurais artificiais, a ideia é realizar o processamento de informações tendo como princípio a organização de neurônios do cérebro. Assim, uma rede neural pode ser interpretada como um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem (experiência) e disponibilizar este conhecimento para a aplicação em questão.

2.6.1. Funcionamento das redes neurais artificiais

As redes neurais artificiais são criadas a partir de algoritmos projetados para determinada finalidade e basicamente se assemelha ao cérebro humano em dois pontos: o conhecimento é obtido através de etapas de aprendizagem, e os pesos sinápticos são usados para armazenar o conhecimento. Sinapse é o nome dado à conexão existente entre neurônios e às conexões são atribuídos valores, que são chamados de pesos sinápticos. Isso deixa claro que as redes neurais artificiais têm em sua constituição uma série de neurônios artificiais (ou virtuais) que serão conectados entre si, formando uma rede de elementos de processamento.

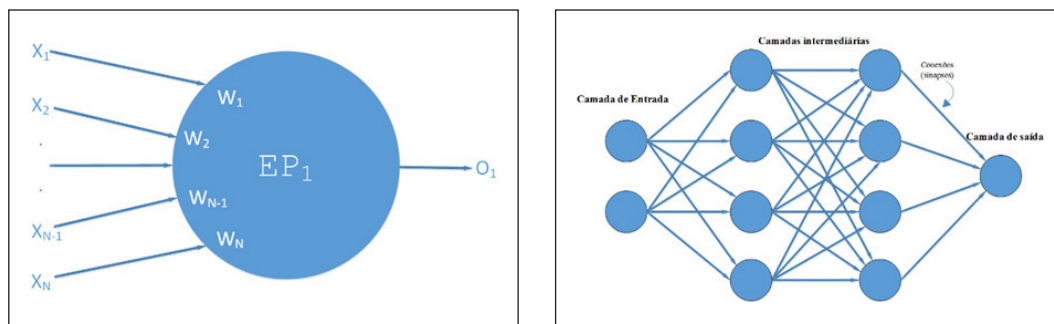
Na representação esquemática de um EP (elemento de processamento, ou neurônio) da Figura 2, cada elemento recebe várias entradas (x_j) e possui uma única saída (o_i). Cada conexão de entrada é associada a um peso ou força da conexão (w_{ij}) (FREEMAN; SKAPURA, 1991).

O valor líquido de entrada do elemento é uma somatória do produto das conexões e seus respectivos pesos e pode ser escrito como:

$$\alpha_i = \sum_j^N w_{ij} x_j \quad (1)$$

Neste caso, N representa o total de conexões de entrada do elemento de processamento. Esse valor líquido (α_i) recebe o nome de valor de ativação, ou simplesmente ativação.

Figura 2 – Estrutura de um elemento de processamento e sua interligação na rede.



Fonte: Elaborado pelos autores (2014).

A saída do elemento de processamento é determinada a partir da ativação através da aplicação de funções lineares ou não-lineares, as chamadas funções de ativação, as mais utilizadas são a linear, a sigmoïdal e a hiperbólica.

O potencial e a flexibilidade do cálculo baseado em redes neurais artificiais vêm da criação de conjuntos de neurônios que estão interligados entre si conforme mostra a Figura 2, que pode ter a notação definida como MLP:2:2-4-4-1:1, uma rede Multi Layer Perceptron, com 2 neurônios na entrada, 1 neurônio de saída e duas camadas intermediárias com 4 neurônios. Esse paralelismo de elementos com processamento local cria a “inteligência” global da rede. Um elemento da rede recebe um estímulo nas suas entradas, processa esse sinal e emite um novo sinal de saída que por sua vez é recebido pelos outros elementos.

2.6.2. O aprendizado

O processo de aprendizagem das redes neurais, definido como treinamento, é realizado quando ocorrem várias modificações significantes nas sinapses dos neurônios.

O melhor algoritmo de treinamento de fácil compreensão é o *Back propagation*, que foi desenvolvido independentemente por Rumelhart, Hinton e Williams (1986), Werbos (1974), e Parker (1985). Outros algoritmos modernos de segunda ordem, como *Conjugate gradient descent* (BISHOP, 1985; SHEPHERD, 1997) e o algoritmo *Levenberg-Marquardt* (PRESS, et al., 1992; BISHOP, 1995; SHEPHERD, 1997) são substancialmente rápidos para a maioria dos problemas.

2.6.2.1. Treinamento *back propagation*

O algoritmo de treinamento *back propagation* é baseado no cálculo do gradiente de uma função erro (E). Como o gradiente informa a direção em que a função é crescente, esse método caminha em direção oposta ao gradiente, ou seja, para um ponto de menor valor da função erro definida. Assim, uma vez atingido o ponto de mínimo da função, têm-se os valores dos pesos que produzem os menores erros de saída (ANTONELLI, 1998).

No aprendizado supervisionado a direção é baseada no gradiente (∇E) de todo o conjunto de dados. A representação matemática do algoritmo é:

$$\Delta w_{ij}(t) = -\eta * \frac{\partial E}{\partial w_{ij}} + \alpha * \Delta w_{ij}(t-1) \quad (2)$$

Sendo que, Δw é o valor da correção do peso w_{ij} , t é o instante atual, $t-1$ é o instante anterior, η é o passo de aprendizado, α é o coeficiente de momento, e $\frac{\partial E}{\partial w_{ij}}$ é a derivada parcial da função erro em relação ao peso w_{ij} .

O coeficiente de momento pode acelerar o treinamento em regiões lisas da superfície do erro e suprimir as oscilações dos pesos em vales ou ravinas íngremes.

Uma boa escolha do passo de aprendizado (η) e do coeficiente de momento (α) é essencial para o sucesso e a velocidade do treinamento. Ajustar esses parâmetros manualmente pode ser muito difícil e pode-se levar um longo tempo para problemas mais complexos.

Durante o processo de treinamento, a correção dos pesos é realizada no sentido inverso da rede, ou seja, da saída para a entrada. Diz-se que o erro se propaga para trás (*back propagation*).

2.6.2.2. Treinamento *conjugate gradient descent*

O algoritmo de treinamento *Conjugate gradient descent* é um avançado método de treinamento para redes *multilayer perceptron*. Possui *performance* geralmente melhor do que o treinamento *Back propagation*, e pode ser aplicado em todos os casos que se usa o treinamento *Back propagation*. Esta é uma técnica recomendada para qualquer rede com um número grande de pesos (mais de uma centena) e/ou múltiplas unidades de saídas.

O *Conjugate gradiente descent* é um algoritmo do grupo de atualização em lote: enquanto o algoritmo *Back propagation* ajusta os pesos da rede um de cada vez, o algoritmo *Conjugate gradiente descent* trabalha com a saída média do gradiente da superfície do erro sobre todos os casos, e atualiza todos os pesos de uma vez no fim da iteração. Por esta razão, não há necessidade de selecionar parâmetros como passos de aprendizagem ou razão de momento para o algoritmo, assim, a sua utilização se torna mais fácil em relação ao treinamento *Back propagation* (STATSOFT, 2010).

A representação matemática do algoritmo é:

$$W(t) = W(t-1) + \alpha(t-1)d(t-1) \quad (3)$$

$$\alpha(t) = \arg \min E(W(t) - \alpha d(t)) \quad (4)$$

$$d(t) = -\nabla E(W(t)) + \beta(t-1)d(t-1) \quad (5)$$

$$\beta(t-1) = \frac{-\nabla E(W(t)) \cdot [\nabla E(W(t)) - \nabla E(W(t-1))]}{\nabla E(W(t-1)) \cdot \nabla E(W(t-1))} \quad (6)$$

Sendo que, W é a matriz dos pesos da rede, t é o instante atual, $t-1$ é o instante anterior, E é a função erro a ser minimizada, ∇E é o gradiente da função erro, d é a direção de otimização do algoritmo, α é a amplitude do passo na direção d e β é a relação de correção de Polak-Ribier. A determinação da amplitude do passo (α) garante que a função erro seja minimizada na direção do seu gradiente descendente. As direções de otimização $d(t)$ e $d(t-1)$ são ditas mutuamente conjugadas. Assim, define-se o método como gradiente descendente conjugado (*Conjugate gradiente descent*).

2.7. O software *Statistica Neural Networks*

O software *STATISTICA NEURAL NETWORKS* (SNN) oferece grande flexibilidade para definição de arquiteturas e treinamento de redes.

Segundo Statsoft (2010), o *Intelligent Problem Solve* (IPS) existente no SNN, é uma ferramenta sofisticada que ajuda a criar e testar redes neurais para problemas de análise e predição de dados, ele projeta um número de redes para resolver o problema e seleciona aquelas com melhores resultados, baseando-se em análises de desempenho da rede.

O SNN divide o conjunto de dados em três subconjuntos: os casos para treinamento, os casos para seleção e os casos para teste. Essa divisão é feita de forma randômica, na proporção-padrão de 2:1:1, ou seja, para cada dois casos de treinamento temos um caso para a seleção e um caso para o teste. Entretanto, o usuário pode alterar essa proporção como lhe convier.

No SNN as redes neurais são treinadas usando-se somente o subconjunto de treinamento. O subconjunto de seleção é usado para manter uma checagem independente sobre o desempenho da rede durante o treinamento, porque um aumento excessivo do erro no subconjunto de seleção indica um *over-learning*.

A *performance* de uma rede, no sistema SNN, é realizada por meio de índices obtidos com os subconjuntos de treinamento, de seleção e de teste. Esses índices são determinados pela relação entre os desvios-padrão do residual e os desvios-padrão dos dados observados de saída. Uma relação de 1.0 implica que, ou não há nenhuma informação útil nas variáveis da entrada, ou a rede não está usando a informação com sucesso. À medida que o desempenho da rede melhora, a relação torna-se mais perto de zero.

Outro fator disponível para análise de desempenho, é o valor da função erro determinada para cada subconjunto analisado. A função erro geralmente utilizada é a erro-quadrático, que soma as diferenças quadradas entre os valores previstos e os observados na saída da rede.

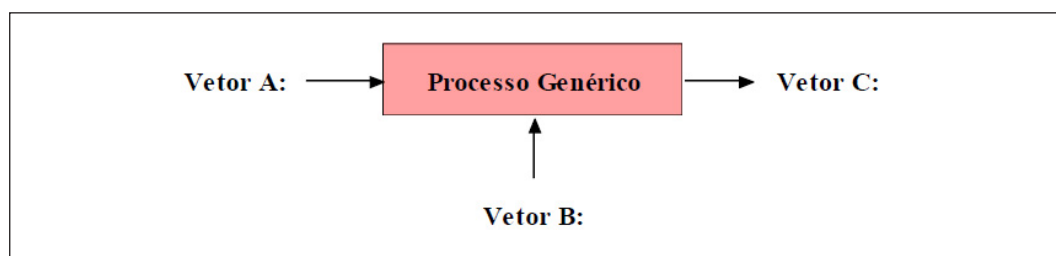
3. PROCEDIMENTOS METODOLÓGICOS

A principal finalidade da aplicação das redes neurais artificiais no processo de produção de fios é possibilitar a previsão da qualidade do fio a produzir na indústria, durante a programação e montagem das misturas de matéria-prima. Devido à complexidade do sistema produtivo e das características intrínsecas das fibras de algodão, simplificações foram estabelecidas para construção do modelo proposto neste trabalho.

3.1. Estrutura genérica de implantação de RNAs na indústria de fios

O processo de produção de fios pode ser considerado um processo genérico, como mostrado na Figura 3. Neste caso, define-se o Vetor A como as características das fibras, o Vetor B, como os ajustes das máquinas, e o Vetor C como a qualidade do fio produzido.

Figura 3 – Estrutura básica de um processo genérico.



Fonte: Elaborado pelos autores (2014).

Uma rede neural artificial pode receber os vetores A e B e prever o vetor C. Entretanto, o modelo simples apresentado esbarra na escolha dos dados que devem alimentar o sistema neural, porque uma grande faixa de características das fibras e variedade dos ajustes das máquinas pode ser usada para produzir um fio com uma determinada qualidade; ou seja, a solução ótima não é única e uma solução ótima global é praticamente impossível de ser alcançada (VAN LANGENHOVE; SETTE, 2002).

Procurando minimizar os efeitos das misturas programadas de matéria-prima, Van Lange-nhove e Sette (2002), utilizaram coeficientes de misturas, nos quais as propriedades da mistura foram determinadas por meio de modelos lineares simples. Neste caso o valor de cada característica da fibra a ser processada pela rede neural é determinado através das Equações 7 e 8 apresentadas a seguir.

$$C_m = \sum_{i=1}^N m_i \cdot C_i \quad (7)$$

$$m_i = \frac{p_i}{\sum_{i=1}^N p_i} \quad (8)$$

De modo que C_m é o valor da característica da mistura a ser determinado, C_i é o valor da característica de cada componente da mistura, m_i é o coeficiente mássico de cada componente da mistura, p_i é o peso de cada componente da mistura e N é o número de componentes da mistura.

3.2. Objeto de estudo

3.2.1. A fiação de algodão Cocamar

A fiação Cocamar nasceu em 1982, inaugurada em 22 de outubro, com o principal objetivo de agregar valor ao algodão entregue pelos seus associados. Inicialmente foi implantada para produzir 270 toneladas/mês de fios cardados 100% algodão (COCAMAR INDÚSTRIA DE FIOS, 2002).

Em 2011, a indústria de fios da Cocamar deu início à modernização do seu processo e atualmente possui a capacidade de produção de 8.300 toneladas/ano de fios de algodão, poliéster e mistos, pelo processo convencional e open-end (COCAMAR, 2013).

3.2.1.1. Armazenamento e preparo da matéria-prima

O algodão é armazenado em fardos que são identificados (código de barras), pesados e classificados. Nessa etapa se determinam as propriedades das fibras: comprimento, alongamento, *m micronaire*, índice de fibras curtas, uniformidade, resistência, umidade e maturidade. Após a classificação, os fardos de algodão são enviados ao armazém de fibras, onde se determina o número da pilha de armazenamento segundo as suas características.

Vários estudos foram desenvolvidos pela empresa na busca de uma sistemática de composição de mistura programada de matéria-prima. Souza, Mizoguchi e Antonelli (2004), realizaram análises comparativas da evolução das propriedades das fibras e da qualidade do fio durante o procedimento denominado corte de mistura, onde ocorre ajuste no processo para a mudança da procedência da matéria-prima.

3.2.1.2. O processo produtivo

A indústria de fios Cocamar separa seu processo em três linhas de produção, denominadas de linha convencional, linha *Open-End* (OE) e linha de sintéticos. A linha convencional e a linha OE processam fibras 100% algodão e a linha de sintéticos processa fibras 100% sintéticas (poliéster) ou mistas (poliéster/viscose ou poliéster/algodão). A linha convencional segue o fluxograma de processo de produção de fios mostrado na Figura 1.

3.3. Procedimentos de coleta de dados

Apesar de a empresa Cocamar possuir os dois tipos de processos, desenvolveu-se este trabalho utilizando a linha convencional.

A forma e o sistema de armazenamento dos dados da empresa não seguem um padrão, ou seja, cada um dos conjuntos possui sua própria forma de armazenamento, utilizando *software* específico ou planilhas no *Microsoft Excel*. A seguir estão descritas as etapas que foram executadas para a seleção e organização desses dados, que após a aquisição das informações necessárias, as mesmas foram armazenadas em base de dados no formato *Microsoft Access*.

3.3.1. Dados da qualidade da fibra

As características das fibras de algodão disponíveis digitalmente são armazenadas através de um sistema próprio, dele foram exportados 100.551 registros, que correspondem à quantidade de fardos processada no período de 01 de dezembro de 2001 a 20 de julho de 2005.

3.3.2. Dados da qualidade do fio

A qualidade do fio produzido pela empresa Cocamar é avaliada pelo laboratório de controle de qualidade da fiação, e os resultados das análises são armazenados em planilhas utilizando o *Microsoft Excel*. O problema encontrado é que, nessas planilhas não existe um padrão de preenchimento, cada dia pode conter uma quantidade diferente de informações, o que dificultou a extração somente dos dados de produção do fio da linha de produção convencional. Para contornar esse problema, desenvolveu-se uma aplicação dentro da planilha do *Microsoft Excel*, em linguagem de programação *Visual Basic Application* (VBA), com a qual foram selecionados 44.097 registros, correspondentes à qualidade de fios produzidos pela empresa Cocamar no período de 02 de maio de 2000 a 11 de maio de 2004.

3.3.3. Dados do processo

Por meio de uma rotina de exportação disponibilizada no sistema de controle da manutenção das máquinas da indústria de fios, foram selecionados 779 registros referentes aos ajustes do processo no período de 01 de janeiro de 2001 a 30 de dezembro de 2004, referentes aos ajustes na linha de produção convencional para a fabricação de fios com título Ne 24/1.

3.4. Procedimentos de Análise de Dados

Para a utilização dos dados na RNA é necessário que estes estejam dispostos de forma organizada e distribuídos uniformemente ao longo de todo um período; ou seja, os dados da fibra, do processo e do fio devem estar compatibilizados em relação ao espaço de tempo.

Os dados da qualidade da fibra, apesar de serem distribuídos de acordo com a data de saída do armazém, não são contínuos nesta variável, pois não existe carregamento aos domingos e feriados e a matéria-prima é enviada para a fábrica e fica aguardando para ser processada no dia seguinte. Também há um tempo morto no processo, devido à presença de estoques reguladores na indústria, pois, segundo Souza, Mizoguchi e Antonelli, (2004), a mudança na qualidade do fio provocada pelo procedimento de alteração da matéria-prima só é observada aproximadamente 48 horas depois de iniciar-se o processamento da nova mistura.

Durante a seleção dos dados da qualidade da fibra algumas providências foram tomadas para eliminar os problemas citados anteriormente:

Para contornar o problema do tempo morto do processo criou-se uma variável denominada data processo, que recebeu a data da remessa mais dois dias (48 horas).

Determinou-se a média das propriedades das fibras processadas em cada remessa aplicando-se os coeficientes de misturas definidos no item 3.1.

Os dados do processo são espaçados de acordo com a intervenção no equipamento para seu ajuste e podem ocorrer várias ou nenhuma intervenção ao longo de um mês, dependendo das condições de operação desejada no processo. Após a intervenção, o equipamento passa a operar com os ajustes implantados até a nova intervenção; deste modo o equipamento opera por um longo período com os valores dos ajustes inalterados.

Na união dos dados da fibra, do fio e do processo obteve-se um conjunto de 4.450 registros, correspondentes ao período de 10 de junho de 2001 a 11 de maio de 2004.

3.5. Sequência metodológica aplicada

Para a obtenção dos resultados apresentados a seguir, primeiramente se ajustou os dados das propriedades das fibras utilizando a estrutura genérica apresentada no item 3.1, depois foi realizado os procedimentos de análise de dados descritos no item 3.4, e posteriormente para a seleção e aplicação da rede utilizou-se o *software* SNN descrito no item 2.7.

Os parâmetros de ajustes necessários para utilizar o *software* SNN estão descritos juntamente com os resultados, uma vez que os mesmos devem ser aplicados a cada etapa dos processos de escolha da estrutura, do treinamento e da aplicação da rede. As decisões tomadas durante esses processos também estão descritas a medida que se constrói os resultados, e o fator para análise de desempenho da rede, foi o valor da função erro-quadrático, que soma as diferenças quadradas entre os valores previstos e os observados na saída da rede.

4. RESULTADOS

Na determinação da qualidade do fio produzido, inicialmente utilizou-se o conjunto de 4.450 registros definido no item 3.4. Com o recurso do IPS distribuíram-se os dados nos subconjuntos de treinamento, de seleção e de testes na proporção 2:1:1 respectivamente (2.225 casos para treinamento, 1.113 casos para seleção e 1.112 casos para teste). Definiu-se a pesquisa do IPS em 200 tipos diferentes de redes utilizando-se a seguinte distribuição das variáveis:

- Variáveis de entrada da rede:
- Características da fibra: *micronaire*, maturidade, comprimento, uniformidade, SFI, resistência, alongamento e umidade;
- Ajustes do processo: rotação, peão de estiragem auxiliar, peão de estiragem, pré-estiragem, viajante, apoio do manchão, coeficiente de torção e braço pendular;
- Variáveis de saída da rede:
- Qualidade do fio: Uster, CV Uster, pontos finos, pontos grossos, NEPS, tenacidade e alongamento.

Apesar da quantidade elevada dos tipos de redes testadas e do conjunto de dados, o IPS não apresentou um bom desempenho; as redes por ele selecionadas possuíam um valor muito elevado do índice de *performance* de seleção, próximo da unidade, como também elevado valor da função erro no conjunto de seleção, na ordem de 10^2 , que representa um *over-learning*. Entretanto, o desempenho do treinamento de uma rede está relacionado diretamente à qualidade, e não à quantidade de dados apresentados à rede. Assim, realizou-se uma análise nos dados apresentados na rede e verificou-se que as variáveis de ajustes do processo oscilam pouco ao longo do conjunto de dados selecionados. Essa característica inviabiliza o processo de treinamento de uma rede, uma vez que as redes neurais “aprendem” a função do problema apresentado, por meio das oscilações existentes nos dados. Dados repetitivos tendem a desestabilizar o treinamento.

Em função disto, desenvolveu-se novos recursos para a seleção, dentre os dados selecionados, de registros com qualidade para serem utilizados na rede neural artificial. Outra providência tomada foi a redução da quantidade de variáveis na entrada da rede, onde optou-se por selecionar algumas das variáveis que caracterizam o processo de fiação. Com essas novas restrições ao conjunto de dados, obtiveram-se 1.207 registros para serem utilizados pela rede neural artificial. As faixas dos valores das variáveis utilizadas na determinação da qualidade do fio, contidas nos dados selecionados, estão apresentadas na Tabela 1. Observa-se que os valores possuem uma boa representatividade das condições reais do processo, uma vez que, algumas características apresentam uma larga faixa de trabalho.

Para uma nova seleção da estrutura de rede para determinar a qualidade do fio dividiram-se os dados nos subconjuntos de treinamento, seleção e testes na proporção 2:1:1 (604 casos para treinamento, 302 para seleção e 301 para teste). Na Tabela 1 têm-se as 5 (cinco) melhores estruturas selecionadas pelo IPS durante os testes.

Tabela 1 – Faixa de valores de entrada da rede para determinar a qualidade do fio.

Variável	Valor mínimo	Valor máximo
Micronaire ($\mu\text{g}/\text{in}^2$)	3,21	4,37
Uniformidade (%)	77,90	86,23
Comprimento (mm)	27,77	30,86
Resistência (gf/tex)	27,60	33,73
Maturidade	0,8390	0,9110
SFI (%)	6,47	11,33
Alongamento (%)	6,05	10,03
Umidade (%)	5,60	9,65
Rotação (rpm)	11.052	12.277
Peão de estiragem	27	40
Coefficiente de torção	3,63	3,99

Fonte: Elaborado pelos autores (2014).

Por meio da análise do índice de *performance* e do valor da função erro no subconjunto de seleção, apresentados na Tabela 2, optou-se por utilizar a quinta RNA apresentada, com a estrutura MLP 11:11-11-13-7:7. Na Figura 4 tem-se a representação gráfica dessa estrutura, com a descrição das variáveis de entrada e a variável de saída. Essa estrutura de rede utiliza função de ativação linear na camada de entrada, função de ativação hiperbólica nas camadas intermediárias e função de ativação sigmoideal na camada de saída.

O mesmo conjunto de dados utilizado na etapa de seleção da estrutura da rede foi utilizado na etapa de treinamento da RNA. Entretanto, com o objetivo de priorizar o treinamento, dividiram-se os dados em três subconjuntos; 807 casos no subconjunto de treinamento, 200 casos no subconjunto da seleção e 200 casos no subconjunto de teste.

Tabela 2 – Resultado da seleção da RNA para determinar a qualidade do fio.


Perfil da Rede	Performance Treino	Performance Seleção	Performance Teste	Erro Treino	Erro Seleção	Erro Teste
RBF 11:11-19-7:7	0,719286	0,842287	0,849925	0,66620	0,75590	40,5041
GRNN 11:11-270-8-7:7	0,502767	0,801764	0,875459	0,45304	0,71547	40,5023
Linear 10:10-7:7	0,778397	0,888545	0,850488	0,12350	0,13686	7,5609
MLP 11:11-14-7:7	0,738235	0,860302	0,851725	0,10321	0,11817	7,5583
MLP 11:11-11-13-7:7	0,679758	0,504876	0,658730	0,06638	0,10851	3,1230

RBF - *Radial Basis Function*; GRNN - *Generalized Regression Neural Networks*; Linear - *Linear Network*; MLP - *Multilayer Perceptron*.

Fonte: Elaborado pelos autores (2014).

O treinamento da rede para determinar as qualidades do fio foi dividido em duas fases: um treinamento inicial utilizando um algoritmo *Back propagation* (com 100 iterações, passo de aprendizagem $\eta=0.01$ e coeficiente de momento $\beta=0.3$) e um segundo treinamento utilizando um algoritmo *Conjugate gradient descent* com 200 iterações.

Figura 4 – Estrutura da RNA utilizada para determinar a qualidade do fio.



Fonte: Elaborado pelos autores (2014).

Obteve-se os índices de performance 0,057681, 0,125645 e 0,098655 para os conjuntos de treino, seleção e teste respectivamente. Na Tabela 3 têm-se, para cada propriedade da qualidade do fio determinada, o erro-quadrático médio e o coeficiente de correlação entre os valores observados e previstos. Observa-se que apesar de algumas qualidades do fio apresentarem erros elevados, como o caso dos Pontos Grossos, o coeficiente de correlação da rede foi bom. Esse fato ocorre para características que possuem valores elevados de desvio padrão nos dados amostrados, ou seja, nas propriedades NEPS, Pontos Finos e Pontos Grossos.

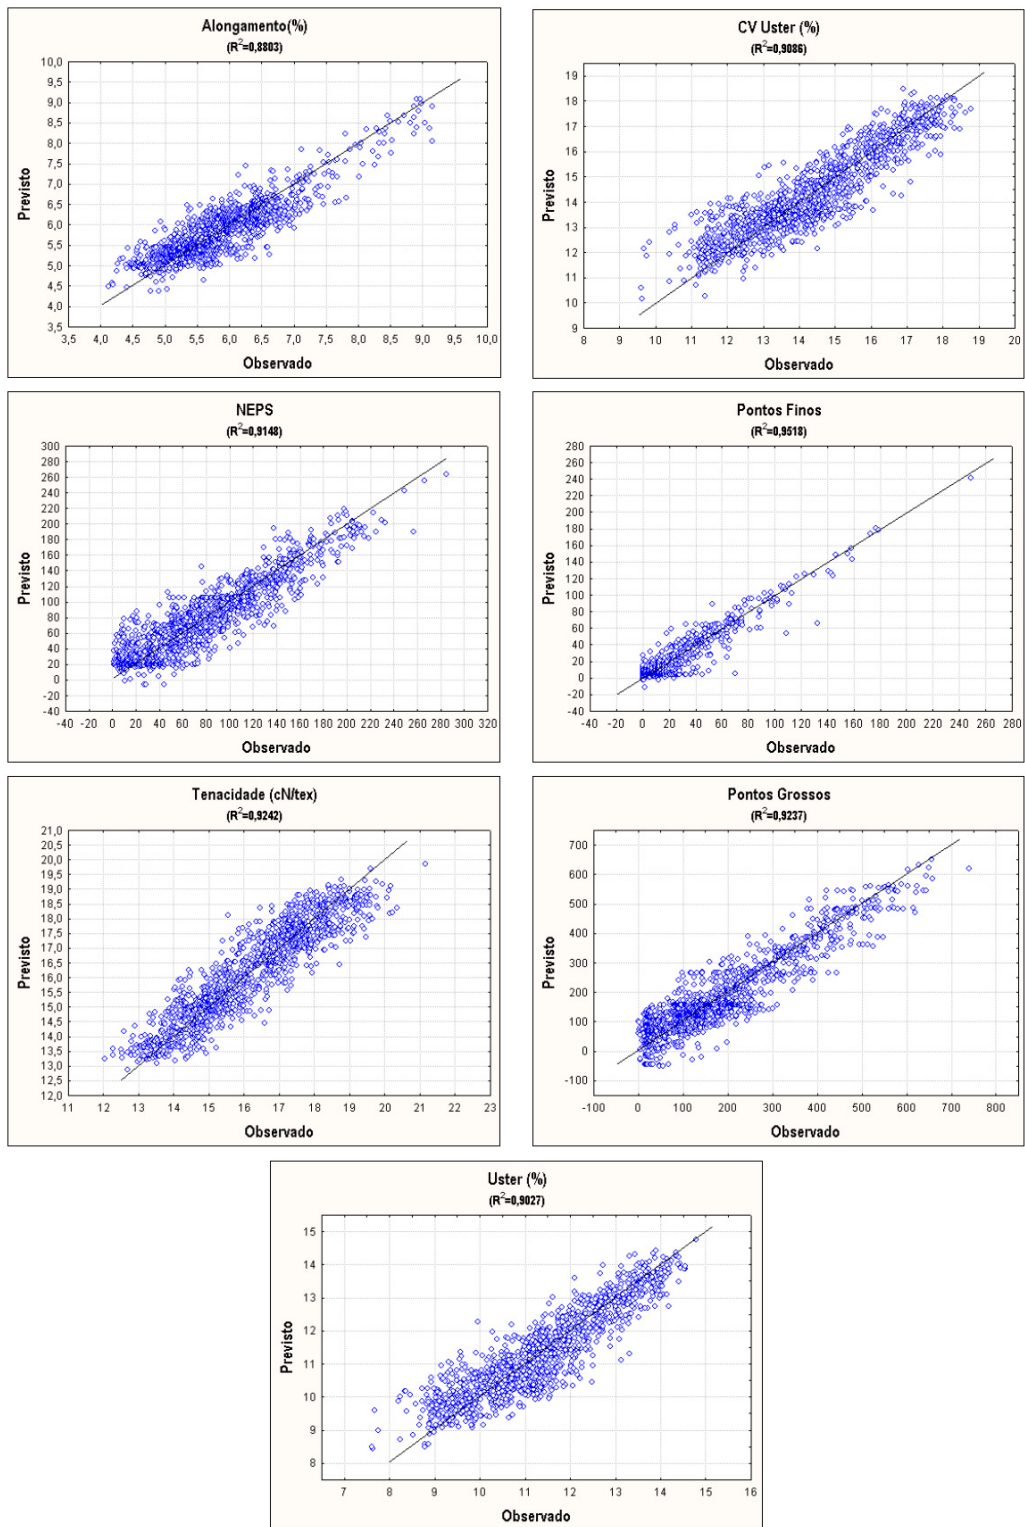
Tabela 3 – Resultados estatísticos do treinamento da RNA para determinar a qualidade do fio.

Qualidade Do fio	Valor Médio	Desvio Padrão	Erro Médio	Desvio padrão do Erro	Erro absoluto Médio	R ² Coeficiente de correlação
Alongamento	5,66	0,4991	-0,00246	0,33927	0,26482	0,8803
CV Uster	15,18	0,9590	-0,00128	0,22538	0,16710	0,9086
NEPS	98,41	28,7800	-0,19462	13,35490	10,34332	0,9148
Pontos Finos	13,15	12,4126	-0,29868	5,13431	3,44310	0,9518
Tenacidade	15,85	1,4816	-0,00288	0,54896	0,42709	0,9242
Pontos Grossos	237,20	87,2094	-0,48990	25,82952	19,39320	0,9237
Uster	11,95	0,7635	-0,00063	0,18510	0,13384	0,9027

Fonte: Elaborado pelos autores (2007).

Na Figura 5, para cada qualidade do fio estudada, está representado graficamente o coeficiente de correlação apresentado na Tabela 3. Esses coeficientes de correlação foram determinados entre as propriedades observadas (valores selecionados) e as propriedades previstas (valores determinados pela rede). Nesta figura pode-se visualizar o desempenho da rede sobre todo o conjunto de dados; foram incluídos os subconjuntos de treino, seleção e teste. Observa-se, nas figuras, uma linha que indica o valor ideal da correlação ($R^2=1$). Verifica-se, pela representação do coeficiente de correlação, que houve uma boa *performance* da rede durante o processo de treinamento.

Figura 5 – Performances da RNA no treinamento para determinar as propriedades do fio.



Fonte: Elaborado pelos autores (2014).

Observa-se que o menor coeficiente de correlação foi obtido para a qualidade alongamento. Para tentar melhorar o desempenho da RNA isolou-se essa qualidade, ou seja, excluiu-se essa propriedade da saída da rede. O objetivo era, posteriormente, construir uma rede que determinasse essa propriedade; entretanto, observou-se que a retirada da qualidade alongamento da saída da rede desestabilizou todas as outras saídas, demonstrando a grande interdependência entre as qualidades do fio.

5. DISCUSSÕES

Com a aplicação de redes neurais artificiais na determinação da qualidade do fio, provou-se que é possível determinar, por meio das redes neurais artificiais, a qualidade do fio que seria produzido por uma mistura de fibras de algodão, com determinadas características e com alguns ajustes do processo. Entretanto, um fato limitante no uso dos resultados obtidos, está na seleção dos dados utilizados no processo de treinamento da rede, porque foram coletados somente dados de produção da linha convencional, ou seja, a linha que produz fios com misturas 100% algodão e com título Ne 24/1.

Algumas variáveis de ajustes do processo foram eliminadas por falta de informação, ou seja, estavam vazias. Neste caso o problema está no usuário do sistema de manutenção, que não deu entrada com o devido valor da variável no sistema. Portanto, esse é um problema operacional, e deve ser solucionado para disponibilizar uma maior quantidade de variáveis do processo, para o treinamento das redes neurais artificiais.

6. CONCLUSÕES

Apesar das limitações de uso que apresenta e de não determinar com precisão os valores absolutos de qualidade do fio, o método demonstrado representa uma excelente ferramenta para definir as variações das qualidades do fio quando se alteram a composição da matéria-prima ou ajustes do processo. Assim, o responsável pela composição da mistura pode realizar a simulação, em computador, da mistura a ser processada na fábrica com a utilização de informações dos fardos de algodão em estoque, procurando, deste modo, montar uma mistura que mantenha a estabilidade de todo o processo produtivo.

Como proposta de continuidade deste trabalho, deve-se desenvolver outras redes, para misturas de algodão com outras matérias-primas e outros títulos de fios; entretanto, não se devem esquecer as dificuldades apresentadas no item 3.4, para a seleção e organização dos dados utilizados no treinamento da rede. Neste caso, para o desenvolvimento de novas aplicações, deve-se estudar primeiramente uma maneira prática de armazenar os dados da qualidade do fio, de modo a facilitar a união com os dados da matéria-prima vindos do armazém e dados vindos do processo.

Outro fator limitante do uso do método desenvolvido está na quantidade de ajustes do processo utilizada (3 ajustes).

Finalmente, o grande benefício do desenvolvimento deste trabalho foi a inclusão da palavra simulação no cotidiano da indústria de fios Cocamar. Os engenheiros responsáveis pela produção possuem muito conhecimento prático, tomam decisões baseadas em conhecimentos anteriores, e este trabalho vem contribuir para um bom desenvolvimento do trabalho desses profissionais.

REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA TÊXTIL E DE CONFECÇÃO, ABIT. **Indústria Têxtil e de Confeção Brasileira** - Cenários, Desafios, Perspectivas e Demandas, 2013. Disponível em: <http://www.abit.org.br/conteudo/links/publicacoes/cartiha_rtcc.pdf>. Acesso em: 08 Agosto 2013.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA TÊXTIL E DE CONFECÇÃO, ABIT. **Apresentação de dados de produção e consumo de algodão**, 2014. Disponível em: <<http://www.abit.org.br/adm/Editor/Document/Consumo%20Industrial%20de%20Fibras%20e%20Filamentos%20-%201970%20a%202013%20-%20agosto.pdf>>. Acesso em: 18 fevereiro 2014.
- ANTONELLI, G. C. **Controle de Processos com Redes Neurais Inversas**. 1998.110p. Dissertação (Mestrado em Engenharia Química) – Programa de Pós-Graduação em Engenharia Química, Universidade Estadual de Maringá, Maringá, 1998.
- BISHOP, C. **Neural Networks for Pattern Recognition**. Oxford: University Press, 1985.
- COCAMAR. **Indústrias**, 2013. Disponível em: <<http://www.cocamar.com.br/industrias>>. Acesso em: 20 Agosto 2013.
- COCAMAR INDÚSTRIA DE FIOS. **Conhecendo a Empresa – Manual de Integração**. Maringá: Departamento Administrativo, v. maio, 12 p., 2002.
- CRESPIM, L.; NEVES, J. D. Consequências da Modernização na Fiação. *In*: CONGRESSO NACIONAL DE TÉCNICOS TÊXTEIS, XIX, 2000, Fortaleza, **Anais...** Fortaleza, CNTT, 2000.
- FREEMAN, J. A.; SKAPURA, D. M. **Neural Networks: Algorithms, Applications and Programming Techniques**. Boston: Addison-Wesley Publishing Company, 1991.
- GOLUB, G.; KAHAN, W. Calculating the Singular Values and Pseudo-Inverse of a Matrix. **Journal of the Society for Industrial and Applied Mathematics Series B Numerical Analysis**, v. 2, n. 2, p. 205-224, 1965.
- GORDEEV, Y.; VOLKOV, P.; BLINOV, I.; SVYATENKO, M. **Cotton Weaving**. Moscow: Mir Publishers, 1987.
- KLEIN, W. **The Technology of Short-staple Spinning**. Manchester: The Textile Institute, 1985.
- LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. **Quarterly Journal of Applied Mathematics II**, v. 2, p. 164-168, 1944.
- LEWIN, M.; PEARCE, E. M. **Handbook of Fiber Science and Technology: Fiber Chemistry**. New York: Marcel Dekker, v. IV, 1985.
- LIMA, F. M. P. D. Análise Econômica entre Tecnologias Diferentes na Indústria Têxtil de Fiação. *In*: CONGRESSO NACIONAL DE TÉCNICOS TÊXTEIS, XIX, 2000, Fortaleza, **Anais...** Fortaleza, CNTT, 2000.
- LIMA, J. J. **Controle do Processo de Fiação**. Rio de Janeiro: CETIQT/SENAI, 1992.

- MARQUARDT, D. W. An algorithm for least-squares estimation of non-linear parameters. **Journal of the Society of Industrial and Applied Mathematics II**, v. 2, p. 431-441, 1963.
- MAURO, J. A. E. Open end e Anel: conceitos e aplicações. **Revista Textilia**, São Paulo, n. 48, p. 24-34, 2002.
- PARKER, D. B. **Learning logic. Technical Report TR-47**. MA: MIT Center for Research in Computational Economics and Management Science. Cambridge, p. 32, 1985.
- PRESS, W. H.; TEUKOLSKY, S. A.; VETTERLING, W. T.; FLANNERY, B. P. **Numerical recipes: the art of scientific computing**. New York: Cambridge University Press, 1992.
- RIBEIRO, L. **Introdução a Tecnologia Têxtil**. Rio de Janeiro: CETIQT/ SENAI, v. 1, 1984.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. *In*: RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition I**. Cambridge MA: MIT Press. 1986. p. 318-362.
- SHEPHERD, A. J. **Second-Order Methods for Neural Networks**. New York: Springer, 1997.
- SOUZA, F. A. D.; MIZOGUCHI, E. T.; ANTONELLI, G. C. Estudo das Características da Fibra de Algodão e das Qualidades do Fio Durante o Processo de Mistura Programada de Matéria-prima. *In*: SIMPÓSIO INTERNACIONAL DE ENGENHARIA TÊXTIL, II, 2004, Natal, **Anais...** Natal, II SIENTEX, 2004.
- STATSOFT. Big Data, Data Mining, Predictive Analytics, Statistics, StatSoft Electronic Textbook. **Electronic Statistics Textbook**, 2010. Disponível em: <<http://www.statsoft.com/textbook/>>. Acesso em: 25 Outubro 2010.
- VAN LANGENHOVE, L.; SETTE, S. The Complex Relationships Between Fibres, Production Parameters and Spinning Results. *In*: EUROPEAN SIMULATION SIMPOSIUM, 14th, 2002, Dresden, **Proceeding**. Dresden, Alemanha, p. 469-473, 2002.
- WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioural sciences**. Tese (PHD) - Harvard University, Boston, 1974.

