

Capítulo 18

MODELOS DE PADRÕES DE QUALIDADE DE FIOS DE ALGODÃO BASEADO EM REDES NEURAIAS ARTIFICIAIS QUE RELACIONAM A MATÉRIA-PRIMA AO PROCESSO DE PRODUÇÃO E AO PRODUTO FINAL

Gilberto Clóvis Antonelli

Patrícia Lopes da Silva de Araújo

Rosa Maria de Castro Fernandes Vasconcelos

Resumo: A técnica de Redes Neurais Artificiais (RNAs) é utilizada para a resolução de diversos tipos de problemas característicos da Inteligência Computacional (IC) com a utilização de dados/variáveis relacionadas entre si, cada uma com sua maior ou menor influência na solução de um determinado problema. Neste trabalho utilizam-se dados de uma indústria de produção do fio de algodão que tem como matéria prima a fibra de algodão e seus ajustes no processo. Os dados foram organizados cronologicamente e após a adequação, pode-se determinar as variáveis a serem utilizadas na definição das redes como solução para determinar modelos padrões para a previsão da qualidade do fio. Foram criadas redes neurais do tipo MultiLayer Perceptron e dois tipos de treinamento, o Backpropagation e o Levenberg-Marquardt. Como resultado, obteve-se modelos de padrões de qualidade que a partir dos dados das características das fibras e ajustes das máquinas, resultam na previsão da qualidade do fio a ser produzido.

Palavras chave: Fiação, Redes Neurais Artificiais, Engenharia de Produção.

1 INTRODUÇÃO

Devido à grande quantidade de informações em base de dados, ferramentas computacionais, especialmente os modelos quantitativos de análise de dados, foram requeridas para identificar elementos importantes e necessários para tomada de decisão (PRAHALAD e KRISHNAN, 2008).

A análise das características físicas das fibras constitui um dos pontos fundamentais para o alcance de melhores índices de produção e de qualidade a baixo custo. As características físicas das fibras são ferramentas importantes para o técnico, pois, através delas, ele decide quanto à aprovação ou não da compra da matéria-prima, à sua forma de consumo (misturas programadas), às ajustagens das máquinas e uma série de outras providências correlatas. Para tanto, é necessário medir e avaliar os valores das principais características das fibras, relacionando-os com o sistema de fiar com o produto a elaborar (MARSAL et. al., 1994).

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 modelos de padrões de qualidades do fio produzido. Por meio desta solução, o engenheiro da indústria pode simular a produção de um fio, melhorar a qualidade do fio e obter uma constante no processo produtivo com menores índices de quebra e de rupturas.

2 INDÚSTRIAS DE FIOS

O Brasil, de acordo com IEMI (2011, apud Souza, 2012), tem 432 empresas de fiação das quais aproximadamente 50% tem em sua matéria-prima principal o algodão e estão concentradas nas regiões sul, sudeste e nordeste do país. O consumo de matéria-prima pelas fiações brasileiras no ano de 2017, segundo ABIT (2017), foi de 1.486.100 toneladas de fibras e filamentos e o consumo de algodão representou aproximadamente 47% das fibras utilizadas.

Na Figura 1 pode-se observar que o consumo de algodão pelas fiações vem decrescendo ao longo dos últimos cinco anos, entretanto, o algodão é ainda a principal matéria-prima da maioria das fiações brasileiras.

Figura 1 – Consumo de fibras e filamentos em milhares de toneladas



Fonte: ABIT, 2017

2.1 PRINCIPAIS CARACTERÍSTICAS DA FIBRA DO ALGODÃO

De acordo com Souza et al. (2012), a fibra de algodão é a mais utilizada pelas empresas de fiação brasileira, este predicado se consolida porque o tecido de algodão apresenta característica de conforto e absorção de calor próprio para países de clima tropical.

As características físicas das fibras de algodão são ferramentas importantes e seu conhecimento permite decidir quanto à sua forma de consumo, os ajustes das variáveis do processo e uma série de outras providências correlatas. 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 (ANTONELLI & NEITZEL, 2015).

Para Rodgers et al. (2012 apud Souza et al., 2012), a fibra de algodão para ser determinada como uma matéria-prima de qualidade deve apresentar características como: Pureza, Maturidade, Comprimento, Umidade, Resistência, Finura e Uniformidade.

As propriedades das fibras de algodão determinam a sua utilização e são da maior importância para os produtores, fiandeiros,

acabadores e utilizadores. Esta importância torna-se ainda mais notória quando se leva em conta o processo de produção e o tipo de matéria prima utilizada, que poderão condicionar a produtividade, bem como a qualidade (VASCONCELOS, 1993).

2.2 PROCESSO DE PRODUÇÃO DO FIO DE ALGODÃO

O processo de produção do fio de algodão, segundo Vasconcelos (1993), é onde de uma massa desordenada de fibras que se encontram emaranhadas, devido às fortes pressões a que foram sujeitas para que o seu transporte fosse facilitado, consegue-se, através de operações de estiragem e de paralelização, isto é, colocando as fibras paralelas umas em relação às outras com uma determinada secção transversal, obter-se um fio com a secção desejada (título), ao qual é inserida uma certa torção, com o objetivo de lhe conferir um determinado número de propriedades.

Existem três sistemas diferentes de processos para a produção do fios, fiação penteada, fiação cardada ou convencional e fiação open end. Na Figura 2 estão apresentadas as etapas envolvidas em cada sistema de fiação.

Figura 2 – Etapas dos processos de produção de fios



Fonte: Autoria Própria, 2018

De acordo com Araujo & Castro (1986), os passadores têm como finalidade regularizar o material em massa por unidade de comprimento, corrigindo as irregularidades

que as fitas, vindas das cardas ou penteadeira, apresentam, conforme a linha de produção seja cardada ou penteada. Isto é, melhorar a uniformidade deste material

através dos processos de dublagem e estiragem, minimizando as irregularidades remanescentes do processo anterior.

Na sequência da linha de produção cardada, tem-se a maçarqueira onde, segundo Araujo & Castro (1986), a alimentação se faz pelas fitas armazenadas em potes provenientes dos laminadores e que ao passar pelo sistema de torção, a matéria sai em forma de uma mecha enrolada numa bobina. A última etapa do processo cardado ocorre no filatório, onde após a estiragem e torção o fio é enrolado ao pavil.

É importante observar que as características físicas das fibras são fatores determinantes do tipo de tecnologia a utilizar (ARAUJO & CASTRO, 1986).

2.3 QUALIDADE DO FIO DE ALGODÃO

O termo qualidade é utilizado frequentemente como sinónimo de produto bom, embora a definição clássica seja a capacidade de satisfazer as necessidades de aplicabilidade ou o grau de conformidade com os requisitos do cliente. Também nas indústrias têxteis, a qualidade desempenha um papel vital devido a uma variedade de produtos intermediários e finais com especificações e padrões para aplicações diversificadas. Diante deste fato, o processo empregado e a matéria-prima utilizada têm um papel fundamental, pois sabe-se que a qualidade final do fio é afetada

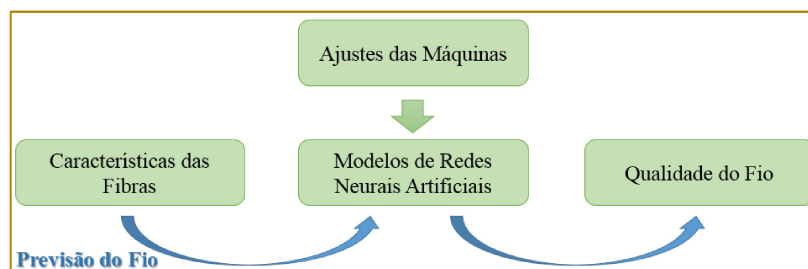
diretamente por eles (CHATTERJEE & CHAKRABORTY, 2017).

A resistência e alongamento do fio são duas das suas características fundamentais, sendo normalmente utilizadas como índices de qualidade, isto devido ao fato de a suas grandezas serem influenciadas por uma combinação de fatores, tais como as propriedades das fibras, a estrutura dos fios e parâmetros inerentes ao processo. Uma das explicações tradicionais do fenómeno de variações da resistência em relação à torção dada ao fio é baseada na combinação de fatores como o deslizamento das fibras e a própria resistência da fibra. Além destas características, outro dos fatores a levar em consideração é o efeito das próprias fibras ao serem enroladas ao longo do seu eixo, isto é, com a inserção da torção, a qual influencia a resistência e o alongamento do fio (VASCONCELOS, 1993).

2.4 MODELOS DE PADRÕES DE QUALIDADE DO FIO

Os modelos de padrões de qualidade do fio, são originados a partir do relacionamento de dados das fibras de algodão e da linha de produção do fio com a técnica das Redes Neurais Artificiais, resultando em algoritmos lógicos computacionais. A representação gráfica deste procedimento pode ser observado na Figura 3.

Figura 3 – Etapas para a determinação dos modelos de padrões de qualidade do fio



Fonte: Autoria Própria, 2018

Esses algoritmos computacionais podem ser utilizados para a previsão da qualidade do fio utilizando informações das fibras em estoque da empresa e os ajustes das máquinas em operação, auxiliando os engenheiros na Programação e Controle da Produção.

3 REDES NEURAS ARTIFICIAIS

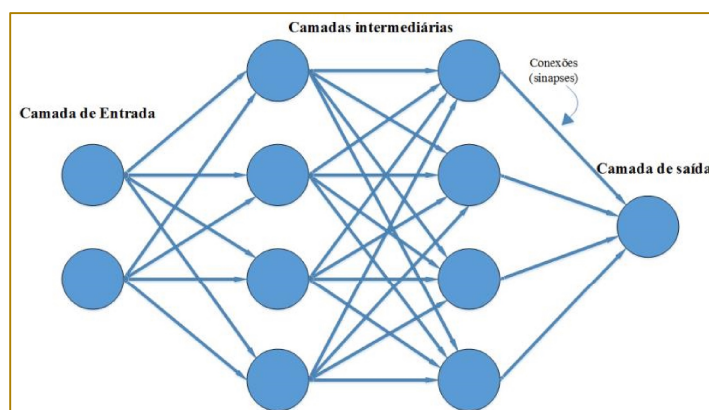
Computação por Redes Neurais Artificiais (RNA) emergiu na última década como um poderoso paradigma que tem encontrado aplicações em quase todos os ramos da engenharia. O desenvolvimento de RNA foi inspirado pelos mecanismos pelos quais neurônios biológicos reais trabalham no cérebro humano. O processo decisório do

cérebro é emulado por uma rede artificial de elementos de processamento (PE) ou neurônios. Uma rede devidamente treinada pode prever a resposta de saída para um maior grau de precisão do que os modelos matemáticos ou estatísticos convencionais (MAJUMBAR, MAJUMBAR & SARKAR, 2004).

Antonelli & Neitzel (2015), afirmam que, basicamente uma rede neural se assemelha ao cérebro em dois pontos: o conhecimento é obtido através de etapas de aprendizagem, e

pesos sinápticos são usados para armazenar o conhecimento. Sinapse é o nome dado à conexão existente entre neurônios. 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, conforme mostrado na Figura 4.

Figura 4 – Exemplo de uma Rede Neural Multi Layer Perceptron (MLP)



Fonte: ANTONELLI & NEITZEL, 2015

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 (ANTONELLI & NEITZEL, 2015).

3.1 TREINAMENTO BACK-PROPAGATION

Conforme descrito por Majumbar, Majumbar & Sarkar (2004), o algoritmo back-propagation (também conhecido como regra delta generalizada) é o método de treinamento mais comumente usado para os modelos de RNA. A regra delta generalizada basicamente realiza uma descida de gradiente na superfície de erro. O treinamento ocorre em duas fases, a saber, a forward e a backward. Na fase forward, um conjunto de dados é apresentado à rede como entrada e seu efeito é propagado, em estágios, através de diferentes camadas da rede. Finalmente, um conjunto de saídas é produzido. O cálculo do vetor de erro é feito a partir da diferença entre a saída real e a prevista de acordo com a Equação 1:

$$E = \frac{1}{2} \sum (T_r - O_r)^2 \quad (1)$$

onde E é o vetor de erro, T_r e O_r denotam a saída desejada e a saída prevista respectivamente, no nó de saída r .

Na fase *backward*, este sinal de erro é propagado para trás na rede neural, e os pesos sinápticos são ajustados para que o sinal de erro diminua a cada processo de iteração, e o modelo de rede neural se

aproxime cada vez mais da saída desejada. As correções necessárias nos pesos

$$\Delta w_{pq(n)} = -\eta \left[\frac{\partial E}{\partial w_{pq(n)}} \right] \quad (2)$$

onde $w_{pq(n)}$ é o peso que conecta os neurônios p e q na enésima iteração; $\Delta w_{pq(n)}$ é a correção aplicada ao $w_{pq(n)}$ na enésima iteração e η é uma constante conhecida como taxa de aprendizado.

sinápticos são realizadas pela regra delta, que é expressa na Equação 2.

3.2 TREINAMENTO LEVENBERG-MARQUART

Em uma RNA de Múltiplas Camadas, o algoritmo de Levenberg-Marquardt (LM) utiliza uma aproximação pelo método de Newton, de forma a minimizar a função erro no decorrer do processo de aprendizagem; esta aproximação é obtida a partir do método de Gauss-Newton modificado. A atualização dos pesos através do método de Gauss-Newton é realizada utilizando a Equação 3 (HAYKIN, 2009):

$$w_{(n+1)} = w_{(n)} - (J_{(n)}^T J_{(n)} + \delta I)^{-1} J_{(n)}^T e_{(n)} \quad (3)$$

onde n é o número da iteração; $w_{(n)}$ é o peso na enésima iteração; $J_{(n)}$ é a matriz jacobiana do vetor do erro em relação ao vetor peso na enésima iteração; δ é uma constante positiva pequena escolhida para assegurar que $(J_{(n)}^T J_{(n)} + \delta I)$ seja definida positivamente para todo n e $e_{(n)}$ é o erro na enésima iteração.

4 METODOLOGIA E DESENVOLVIMENTO

A Metodologia é a aplicação de procedimentos e técnicas que devem ser observados para construção do conhecimento, com o propósito de comprovar sua validade e utilidade nos diversos âmbitos da sociedade (PRODANOV & FREITAS, 2013).

Segundo Silva e Menezes (2005), pesquisar significa “procurar respostas para indagações propostas”, e que para Gil (2002), é um “processo formal e sistemático de desenvolvimento do método científico”, ou seja, a pesquisa promove o descobrimento de respostas para problemas com o auxílio de procedimentos científicos.

Este trabalho é classificado como uma pesquisa de natureza aplicada, que tem por objetivo a geração de conhecimento para a aplicação prática e dirigido à solução de problemas específicos, levando em consideração as verdades e os interesses locais. Em relação à forma de abordagem do

problema, foi utilizada a metodologia de pesquisa quantitativa pois, trata-se de uma pesquisa que traduz em números as opiniões e informações coletadas, com o intuito de classificá-las e analisá-las. Já em relação aos seus objetivos, a pesquisa pode ser classificada como exploratória, pois têm como objetivo principal o aprimoramento de ideias ou a descoberta de intuições.

O presente trabalho se dividiu em sete etapas distintas: coleta dos dados, adequação dos dados, análise dos dados, definição das redes neurais, treinamento das redes, testes e validação.

4.1 COLETA, ADEQUAÇÃO E ANÁLISE DOS DADOS

Para o desenvolvimento desta pesquisa, se utilizou os dados de produção por processo cardado, conforme descrito no item 2.2, de uma fiação brasileira que disponibilizou todo o material desde a matéria-prima, ajustes de máquinas e do fio produzido nas safras de 2014/2015, 2015/2016 e 2016/2017. Após a coleta e importação para o ambiente computacional, se exportou os mesmos para um banco de dados para serem relacionados. Após esse relacionamento cronologicamente, a análise se baseou em determinar as variações dos valores das propriedades, e os resultados obtidos estão representados na Tabela 1 para as características das fibras, na

Tabela 2 para os ajustes do processo e na Tabela 3 para as qualidades do fio produzido.

Com os valores médios, o desvio padrão e o coeficiente de variação, pode se determinar

as variáveis mais influentes na construção dos padrões de qualidade, e com os valores mínimos e máximos se determinou os limites de aplicabilidade destes padrões.

Tabela 1 - Valores apurados dos dados das características das fibras

Propriedade	COM (mm)	UNI (%)	MIC ($\mu\text{g/pol}2$)	RES (gf/tex)	ALO (%)	TRC	TRA (%)	LFG (%)	MR (%)	SFI (%)	MOI (%)
Média	29,1	81,6	4,0	30,7	6,6	12,3	0,2	2,5	0,9	9,1	7,1
Desvio Padrão	0,31	0,49	0,13	0,88	0,06	4,66	0,06	0,47	0,01	0,44	0,60
CV	1,07	0,60	3,25	2,87	0,91	37,89	30,00	18,80	1,11	4,84	8,45
Mínimo	28,8	81,1	3,9	29,8	6,5	7,6	0,2	2,0	0,9	8,6	6,5
Máximo	29,4	82,1	4,1	31,6	6,7	17,0	0,3	3,0	0,9	9,5	7,7

Legenda:
COM = Comprimento, UNI=Uniformidade, MIC = Micronaire, RES = Resistência, ALO = Alongamento, TRC = Número de partículas de impurezas, TRA = Percentual de area ocupada pelas impurezas, LFG = Grau de folhas, MR = Maturidade, SFI = Índice de fibras curtas, MOI = Umidade.

Fonte: Autoria Própria, 2018

Conforme apresentado na Tabela 1, utilizou-se onze propriedades que caracterizam as

fibras utilizadas no processamento do fio produzido.

Tabela 2 - Valores apurados dos dados dos ajustes das máquinas.

	Passador 1			Passador 2			MAÇAROQUEIRA			FILATÓRIO				
	P1_MPM	P1_ESC_T	P1_ESC_D	P2_MPM	P2_ESC_T	P2_ESC_D	M_ESC_F	M_ESC_I	M_ESC_T	T/P	M_RPM	F_RPM	EST%	TORC%
Média	381,4	52,4	42	716,2	7,3	4,3	37,5	49,5	52,5	1,1	1139,5	16545,5	105,7	100
Desvio Padrão	17,34	0,91	0	47,6	0,45	0,45	0	0	0	0,02	22,84	97,06	0,45	0
CV	4,55	1,74	0	6,65	6,16	10,47	0	0	0	1,82	2	0,59	0,43	0
Mínimo	364,1	51,5	42	668,6	6,8	3,8	37,5	49,5	52,5	1,1	1116,7	16448,4	105,3	100
Máximo	398,8	53,3	42	763,8	7,7	4,7	37,5	49,5	52,5	1,1	1162,4	16642,5	106,2	100

Legenda:
P?_MPM = Velocidade, P?_ESC_T = Escartamento Trazeiro, P?_ESC_D = Escartamento Dianteiro, ?=Número do passador
M_ESC_F = Escartamento frontal, M_ESC_I = Escartamento Intermediário, M_ESC_T = Escartamento Trazeiro, T/P = Tensão por polegada,
M_RPM = Rotação do fuso, F_RPM = Rotação do fuso no filatório, EST%=Percentual de estiragem, TORC%=Volts por polegada.

Fonte: Autoria Própria, 2018

Na Tabela 2 se observa os quatorze parâmetros dos ajustes das máquinas

existentes no processo que foram utilizados para a produção dos fios em estudo.

Tabela 3 - Valores apurados dos dados da qualidade do fio.

Propriedade	NE	UM (%)	CVM(%)	PLHI	PLSH	TENAC	ALONG
Média	28,4	13,23	16,8	6,7	1,6	14,5	5,6
Desvio Padrão	1,96	0,66	0,85	0,63	0,09	0,55	0,33
CV(Coef.Variação)	6,9	4,99	5,06	9,4	5,63	3,79	5,27
Mínimo	26,5	13,89	16	6,1	1,5	14	5,6
Máximo	30,4	13,23	17,7	7,4	1,7	15,1	5,94

Legenda:
NE=Massa Linear, UM=Índice uster, CVM=Coefficiente de variação de massa, PLHI=Pilosidade, PLSH=Variação de pilosidade, TENAC=Tenacidade, ALONG=Alongamento

Fonte: Autoria Própria, 2018

Os sete parâmetros apresentados na Tabela 3 correspondem aos padrões de qualidade determinados por meio de modelos computacionais baseados em redes neurais artificiais.

4.2 DEFINIÇÃO, TREINAMENTO E TESTES DAS REDES NEURAS ARTIFICIAIS

Para a definição das redes neurais artificiais utilizou-se o software SNN - STATISTICA: NEURAL NETWORKS®, o qual oferece grande flexibilidade para definição de arquiteturas e treinamento de redes. Com o recurso IPS (Intelligent Problem Solve), existente no SNN, definiram-se as estruturas de redes a serem treinadas. O IPS é uma ferramenta sofisticada que ajuda a criar e testar redes neurais para problemas de análise e predição de dados. 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. A performance de uma rede, no sistema SNN, é realizada por meio de índices (erros) obtidos com os subconjuntos de treinamento, de seleção e de teste. Esses índices são determinados pela relação entre os desvios-padrão do residual (diferença entre o valor desejado e o determinado pela rede) e os desvios-padrão dos dados observados de saída. Na Tabela 4 tem-se os modelos determinados para cada qualidade do fio, bem como os erros calculados durante as etapas de seleção e treinamento, e os tipos de treinamentos utilizados.

Tabela 4 - Modelos de qualidade para o processamento de fios cardados

Qualidade	Modelo	Erro durante seleção	Erro após Treino	Treinamento/Membros
NE	MLP 8:8-7-1:1	0,59	0,23	BP1000,LM1000
UM	MLP 25:25-26-1:1	0,47	0,10	BP200,LM500,BP100
CVM	MLP 25:25-30-1:1	1,00	0,21	BP100,BP100,LM500,BP100
PLHI	MLP 25:25-28-1:1	0,54	0,09	BP100,LM500
PLSH	MLP 25:25-54-1:1	0,46	0,08	BP100,LM500,BP100,LM500,BP100
TENAC	MLP 25:25-131-1:1	0,41	0,07	BP100,LM500
ALONG	MLP 25:25-61-1:1	0,41	0,07	BP1000,LM500,BP100,LM2500

Legenda:
NE=Massa Linear, UM=Índice uster, CVM=Coefficiente de variação de massa, PLHI=Pilosidade, PLSH=Variação de pilosidade, TENAC=Tenacidade, ALONG=Alongamento
BP=BackPropagation, LM= Levenberg-Marquart, =Número de iterações

Fonte: Autoria Própria

Na Tabela 4 tem-se uma representação de cada modelo na forma MLP E:E-I-S:S, e exemplificando com o modelo MLP 8:8-7-1:1 do NE, trata-se de uma rede MultiLayer Perceptron, com 8 variáveis de entrada, 1 camada intermediária de 7 neurônios e 1 neurônio de saída.

No processo de treinamento das redes neurais utilizou-se como indicador de melhora nas iterações o coeficiente de correlação entre os valores Observados (corretos) e os valores Previstos (determinados pela rede). Assim, na Tabela 5 tem-se um comparativo desses valores antes e depois do treinamento da rede.

Tabela 5 – Coeficiente de Correlação entre os valores Observados e Previstos das qualidades do fio

Etapa	Qualidade do fio						
	NE	UM	CVM	PLHI	PLSH	TENAC	ALONG
ANTES DO TREINAMENTO	0,7935	0,6361	0,6935	0,6350	0,4851	0,6516	0,4951
APÓS O TREINAMENTO	0,8056	0,8806	0,8649	0,8448	0,8884	0,9121	0,9142

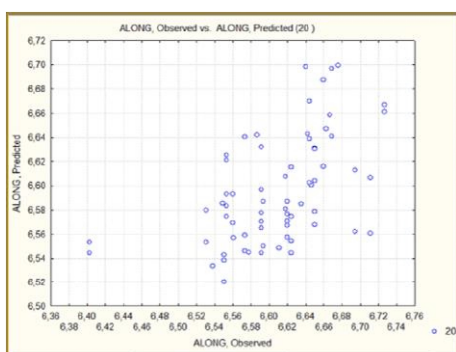
Fonte: Autoria Própria, 2018

Uma análise gráfica da correlação entre os valores Observados e os valores Previstos pela rede neural do modelo da qualidade

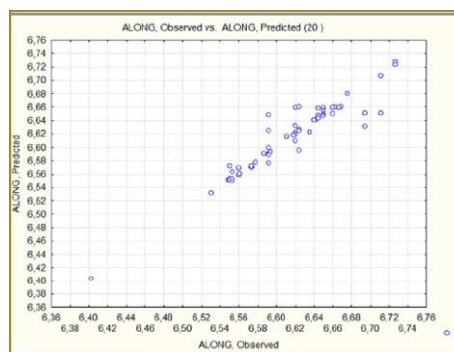
Alongamento (ALONG) está apresentada na Figura 5, as demais representações estão apresentadas no Apêndice deste trabalho.

Figura 5 – Correlação entre valores Observados e Previstos da qualidade Alongamento

Antes do treinamento



Após o treinamento



Fonte: Autoria Própria, 2018

4.3 TESTES E VALIDAÇÃO DOS MODELOS DE PADRÕES DE QUALIDADE

Após o treinamento da rede, passou-se então para a fase de testes utilizando cases que foram previamente excluídos na fase do treinamento. Esses cases diferem entre si para cada qualidade do fio determinada. Para avaliação dos resultados dos testes utilizou-se o erro percentual (E) entre os valores

observados e previstos. Na Tabela 6 tem-se os valores médios dos erros obtidos para cada qualidade do fio.

Após os testes das redes, realizou-se a etapa de validação, onde se determinou os intervalos de confiança dos erros percentuais de cada modelo de qualidade, aplicando-se a Equação 4.

$$h = t_{n-1, 1-\alpha/2} \frac{s}{\sqrt{n}} \quad (4)$$

onde temos que h representa o semi-intervalo de confiança a $1-\alpha$, S é o desvio padrão da amostra, n é o número de amostragens e $t_{n-1, 1-\alpha/2}$ é o valor tabelado de t-student para $n-1$ graus de liberdade e $1-\alpha$ o nível de confiança. Assim, tem-se que o intervalo de

confiança é dado por $[E-h, E+h]$ para o valor do erro percentual de cada modelo. Determinou-se com um nível de confiança de $\alpha = 95\%$ os intervalos de confiança apresentados na Tabela 6.

Tabela 6 – Erro Médio Percentual do Modelos de Qualidade para o processamento de fios cardados

Qualidade	Número de cases	t-student	Erro Médio Percentual (%)	Desvio Padrão do Erro Médio (%)	Intervalo de confiança do Erro (%)	
					Limite Inferior	Limite Superior
NE	10	1,81246	2,28	3,92	0,03	4,52
UM	10	1,81246	2,46	1,65	1,50	3,41
CVM	10	1,81246	3,48	2,77	1,87	5,08
PLHI	10	1,81246	4,62	2,98	2,89	6,34
PLSH	9	1,83311	2,40	2,31	1,06	3,74
TENAC	10	1,81246	2,12	1,67	1,15	3,08
ALONG	8	1,85955	4,21	3,30	2,27	6,15

Fonte: Autoria Própria, 2018

Os intervalos de confiança representam os limites de erros obtidos pelos modelos de padrões de qualidade, por exemplo, tem-se 95% de confiança que o erro percentual do modelo de padrão de qualidade UM, está entre 1,5 e 3,41%, quando o mesmo é utilizado para prever sua propriedade.

5 DISCUSSÕES E CONCLUSÕES

Os resultados apresentados nos testes e validação demonstram que os modelos de padrão de qualidade obtidos podem ser utilizados para prever a qualidade de um fio de algodão por processo de produção cardado com erros percentuais inferiores a 10%. Entretanto, os modelos padrões de qualidade apresentados estão limitados ao uso pelos valores das variáveis apresentados no item 4.1, valores mínimos e máximos, e à

qualidades de fios obtidos por processamento cardado.

A grande dificuldade de obtenção dos padrões de qualidade por meio de redes neurais artificiais reside na definição de sua estrutura e seu treinamento, e seleção dos dados de entrada uma vez que os mesmos devem conter informações suficientes para que o sistema neural consiga detectar a correlação entre a entrada e a saída.

Finalmente, o grande benefício do desenvolvimento deste trabalho foi a inclusão da palavra simulação no cotidiano da indústria em estudo. 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.

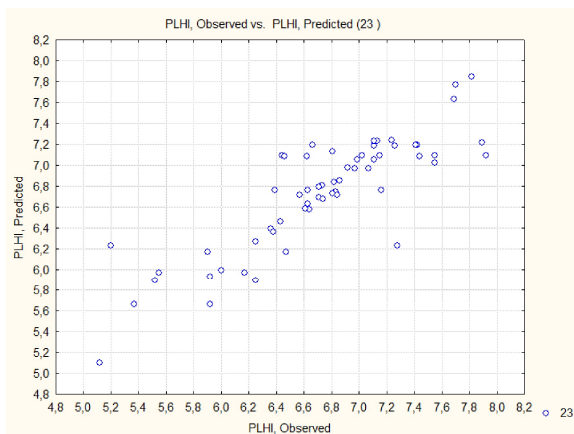
REFERÊNCIAS

[1] ABIT – ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA TÊXTIL. Consumo industrial de Fibras e Filamentos - (1970-2017). Disponível em: <<http://www.abit.org.br/cont/dados-comercio-exterior>>. Acesso em: 24/09/2018.

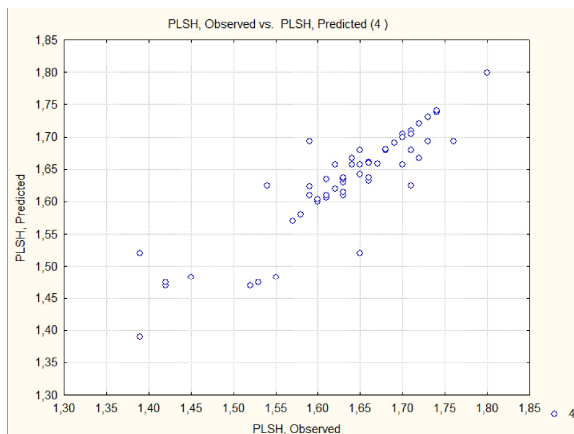
[2] ANTONELLI, G. C.; NEITZEL, I. Aplicação de redes neurais artificiais na indústria de fios de algodão – determinação do índice de fibras imaturas. Revista Gestão Industrial. ISSN 1808-0448. v. 011, n. 02: p. 87-105, 2015. D.O.I.:10.3895/gi.v11n2.2662

- [3] ARAUJO, M.; CASTRO, E. M. M. Manual de Engenharia Têxtil. Lisboa: Fundação Calouste Gulbenkian, 694 p, 1986.
- [4] CHATTERJEE, P.; CHAKRABORTY, S. Development of a meta-model for the determination of technological value of cotton fiber using design of experiments and the TOPSIS method. Journal of Natural Fibers. Series E. v. 98. 2017.
- [5] GIL, A. C. Como elaborar projetos de pesquisa. São Paulo: Atlas, 2002. 176p.
- [6] HAYKIN, S. Neural Networks: A Comprehensive Foundation. 3. ed. Mc Master University Hamilton Ontario, Canada: Prentice Hall, 2009. 906p.
- [7] MAJUMDAR, A.; MAJUMDAR, P. K.; SARKAR, B. Selecting cotton bales by spinning consistency index and micronaire using artificial neural networks. Autex Research Journal, v. 4, n.1, 2004.
- [8] MARSAL, F.; OKUDA, K.; TONEU, J. M.; YAMASAKI, S. S. Parametria de hilos. Barcelona: Terrassa, Editions UPC, 1994.
- [9] PRODANOV, C. C.; FREITAS, E. C. Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. Novo Hamburgo: Feevale, 2013.
- [10] PRAHALAD, C. K.; KRISHNAN, M. S. A nova era da inovação: a inovação focada no relacionamento com o cliente. Rio de Janeiro: Elsevier, 2008.
- [11] SILVA, E. L.; MENEZES, E. M. Metodologia da Pesquisa e Elaboração de Dissertação. 4ª Edição. Florianópolis: UFSC, 2005.
- [12] SOUZA, F. A. de; KACHBA, Y. R.; HATAKEYAMA, K.; DIAS, M. C. Rastreabilidade e identificação de matéria-prima: estudo de caso em uma indústria de fios. XXXII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Bento Gonçalves/RS. Brasil. 2012.
- [13] VASCONCELOS, R. M. de C. F. Contribuição à aplicação de técnicas de inteligência artificial na tecnologia da fiação. 231 f. Tese (Doutorado) - Programa Doutoral da Escola de Engenharia da Universidade do Minho, Universidade do Minho, Guimarães/Portugal, 1993.


APÊNDICE



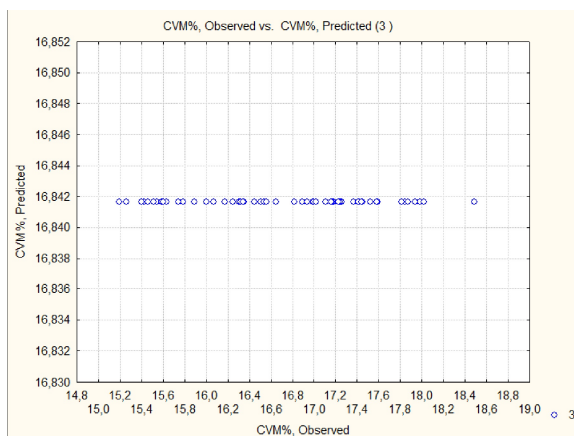
Correlação entre valores Observados e Previstos da qualidade do PLHI



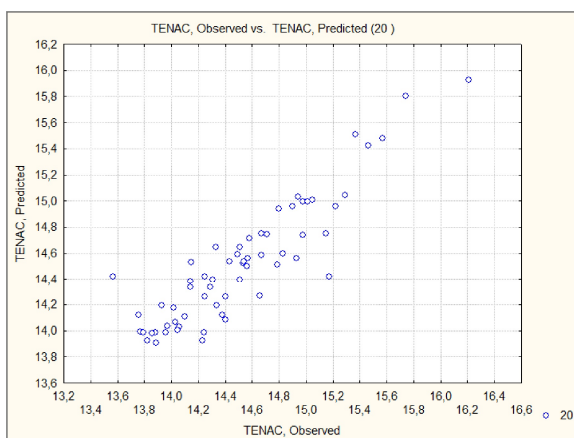
Correlação entre valores Observados e Previstos da qualidade do PLSH




Correlação entre valores Observados e Previstos da qualidade do NE



Correlação entre valores Observados e Previstos da qualidade do CVM%



Correlação entre valores Observados e Previstos da qualidade da TENAC



Correlação entre valores Observados e Previstos da qualidade do UM%