

CONTROLE DE QUALIDADE DE PROCESSO: UMA COMBINAÇÃO HÍBRIDA DE REDES NEURAIS E LÓGICA FUZZY PARA A CONSTRUÇÃO DE CARTAS DE CONTROLE

PROCESS QUALITY CONTROL: A HYBRID COMBINATION OF NEURAL NETWORKS AND FUZZY LOGIC FOR THE CONSTRUCTION OF CONTROL CHARTS

Maria Emilia Camargo¹; Ivonne Maria Gassen²; Marcia Adriana de Oliveira Cerezer³; Suzana Leitão Russo⁴

¹Universidade de Santa Cruz do Sul, RS – Brasil

kamargo@terra.com

²Universidade de Santa Cruz do Sul, RS – Brasil

ivonne@unisc.com

³Universidade de Santa Cruz do Sul, RS – Brasil

marciac@unisc.br

⁴Universidade Federal de Sergipe – UFS – São Cristóvão/SE – Brasil

suzana.ufs@hotmail.com

Resumo

A nova ordem mundial vem se caracterizando cada vez mais por grandes mudanças tecnológicas e sociais e com o conseqüente aumento da competitividade na maioria dos setores da economia. Na disputa por novos mercados e na tentativa de manutenção das atuais posições, se faz necessário uma gestão eficiente e eficaz que garanta a continuidade do empreendimento no longo prazo, além do cumprimento de sua missão. Para que possam cumprir sua missão, as empresas necessitam cada vez mais de ferramentas robustas para monitorar e avaliar os seus processos produtivos, sendo assim, o Controle Estatístico do Processo (CEP) em uma empresa constitui um fator de extrema importância principalmente se considerarmos o alto grau de competitividade dos mais diversos ramos de atividade e as exigências do mercado atual. Neste contexto, este artigo teve como objetivo desenvolver uma metodologia para a construção de gráficos de controle baseadas nos resíduos pela rede neuro-fuzzy, ou seja, um modelo híbrido. Após o ajuste de um modelo AR com intervenção, construiu-se a carta de controle para a gramatura da fiação.

Palavras-chave: cartas de controle, redes neurais, lógica fuzzy.

Abstract

The new world order has been featuring increasingly by large technological and social changes and the consequent increased competitiveness in most sectors of the economy. In the race for new markets and in an attempt to maintain current positions, it is necessary a efficient and effective management to ensure the continuity of the enterprise in the long term, beyond the fulfilment of its mission. In order to fulfill its mission, companies increasingly need robust tools to monitor and evaluate their productive processes, thus, the statistical process control (CEP) in an enterprise is an important factor especially if we consider the high degree of competitiveness in the most varied fields of activity and current market requirements. In this context, this article was aimed at developing a methodology for constructing control charts based on neuro-fuzzy network waste, i.e. a hybrid model. After adjusting a model AR with intervention, was constructed the control chart. the the weight of spinning.

Key-words: control charts, neural networks, fuzzy logic.

1. Introdução

Para sobreviver à nova ordem econômica, as organizações precisam adaptar-se à realidade competitiva e tecnológica atual, bem como aprender a identificar, ganhar e preservar novos mercados.

O aumento da demanda por melhores serviços, qualidade e variedade de produtos, associado ao crescimento da concorrência, tem levado as organizações a repensar a maneira como gerenciam seus negócios.

Assim, na produção, a qualidade deve ser constantemente monitorada. Avaliações devem ser feitas nos pontos críticos do processo para estabelecer padrões e, depois, verificar se o processo mantém-se nos padrões estabelecidos.

Logo, a qualidade não pode estar separada das ferramentas estatísticas e lógicas usadas no controle, melhoria e planejamento da qualidade.

Assim, dentre as várias ferramentas que podem ser utilizadas para a melhoria e aperfeiçoamento dos processos produtivos, pode-se destacar o Controle Estatístico de processo (CEP) que é empregado por muitas organizações não simplesmente como um conjunto de técnicas estatísticas, mas como uma forma de pensar que é determinante para que sejam atingidos os objetivos propostos. Esta ferramenta possibilita a monitoração e a melhoria dos processos produtivos, promovendo a redução dos custos associados `a falhas, a redução de desperdícios e conseqüentemente o aumento da qualidade dos produtos.

O controle estatístico de processo é uma técnica cientificamente comprovada e que permite estudar o comportamento de medidas de um processo, e controle multivariado nos permite através de um único gráfico monitorar simultaneamente duas ou mais variáveis com características de qualidade relacionáveis.

O objetivo deste trabalho, foi desenvolver um modelo com base na aplicação da metodologia híbrida neuro-fuzzy (redes neurais e lógica fuzzy) em conjunto com as cartas de controle para identificar padrões de processos produtivos cujas observações sejam autocorrelacionados.

Os dados foram coletados diariamente no período de março a abril de 2010 na Indústria Têxtil Oeste Ltda., no município de Mondai – SC. referentes a gramatura da fiação do tecido.

2. Fundamentação Teórica

O controle estatístico de processo pode ter diferentes objetivos e conseqüentemente pode ser feito de diferentes formas. Considerações estatísticas associadas com processos de controle de qualidade, têm sido discutidas, Hunter (1986); Montgomery & Friedman (1989) e Shewhart (1931).

Camargo et al. (1998), desenvolveram estudos utilizando técnicas alternativas no controle estatístico de qualidade, apresentando aplicações a casos reais e simulados para analisar as variações ocorridas em processos produtivos.

A análise das variações ocorridas durante o processo de produção através das cartas de controle também sido bastante analisadas como pode-se encontrar em Montgomery & Mastrangelo, 1991; Notohardjono & Ermes, 1986.

A interpretação das cartas de controle é baseada freqüentemente na suposição de que os dados observados são não correlatados. A presença de autocorrelação nos dados do processo tem efeitos adversos no desempenho das cartas do controle (Ermer, 1980).

West, Dellana, & Jarrett (2002), apresentam um estudo com a finalidade de verificar a habilidade de um modelo da função de transferência (variáveis de intervenção) para identificar causas assinaláveis de variação e de modelar relacionamentos dinâmicos entre entradas e saídas de processos, os autores apresentaram análises para dados reais e simulados.

Balestrassi (2000), desenvolveu uma metodologia para identificação de padrões utilizando series temporais e redes neurais para um processo produtivo univariado, ou seja, quando somente uma característica de qualidade é monitorada.

2.1 Redes Neurais Artificiais

Segundo Dayhoff (1990), uma rede neural artificial é um sistema massivamente paralelo composto de elementos ou unidades altamente interconectados (também chamados de neurônios) e processamento interativo que são baseados em modelos neurobiológicos.

A maior tarefa de uma rede neural é aprender e manter um determinado modelo suficientemente consistente para alcançar os objetivos de uma aplicação de interesse (Haykin,1994).

Conforme Balestrassi (2000), desde que as redes neurais tentam simular certos aspectos do sistema nervoso humano, elas exibem muitas propriedades para resolver problemas complexos. As seguintes características das redes neurais enfatizam o seu poder em termos de reconhecimento de padrões, fazendo-as particularmente atrativas para o problema de classificação de padrões não aleatórios de um gráfico de controle estatístico de processo:

- Podem aprender com exemplos e adaptar-se a novas situações;
- São robustas (podem abstrair informações de dados com ruído, incompletos ou não precisos);
- Podem generalizar a partir de exemplos (podem prover soluções corretas para dados similares, não vistos no treinamento)
- Podem construir soluções rapidamente sem muito domínio do conhecimento do processo;
- Podem aproximar qualquer função multivariada complexa (mal definida ou desconhecida) e formar uma decisão de classificação a partir do reconhecimento de padrões discriminantes;
- São computacionalmente eficientes (tem a velocidade para operar em tempo real).

Hwang (1992) desenvolveu uma metodologia para o reconhecimento de padrões em cartas X-bar usando *backpropagation e Boltzman Machine*.

Lucy-Bouler (1991) apresenta um sistema especialista para reconhecimento de padrões em controle estatístico de processo para dados autocorrelacionados, bem como as cartas CUSUM e as regras de corridas (*runs rules*).

2.2 Sistemas Fuzzy

Os sistemas *fuzzy* são baseados na teoria da lógica *fuzzy* e dos conjuntos *fuzzy*, propostos por Zadeh em 1965 (Zadeh, 1965, 1987). A lógica booleana define as variáveis como sendo verdadeiras ou falsas, 1 ou 0, enquanto na lógica *fuzzy*, as variáveis são mapeadas em graus de pertinência que

variam de 0 a 1. As variáveis com grau de pertinência 0 denotam a não-pertinência absoluta, as variáveis com grau de pertinência 1 denotam a pertinência absoluta, e as variáveis com grau de pertinência entre 0 e 1 denotam a pertinência intermediária.

“Quando a complexidade do sistema cresce, nossa habilidade para tornar as proposições precisas diminui até um limiar que está fora do nosso alcance. Isto torna a precisão e a relevância duas características excelentes” (Cox, 1994).

Zadeh representa o mundo em termos de conjuntos *fuzzy* (Cox, 1994) e sobre estes conjuntos, foi definida a teoria dos conjuntos *fuzzy*, para tornar possível as operações de união, interseção e negação sobre variáveis com valores lógicos entre 0 e 1. A teoria dos conjuntos *fuzzy* é uma extensão da teoria clássica dos conjuntos e da lógica booleana (Cox, 1994).

Sistemas baseados em lógica *fuzzy* se caracterizam pela inferência de regras (IF-THEN) *fuzzy*, que são uma forma clara e eficiente de representar o conhecimento. As regras *fuzzy* manipulam termos lingüísticos.

Através dos sistemas *fuzzy* pode-se modelar problemas não-lineares complexos, onde as decisões são tomadas em um ambiente incerto e impreciso.

2.3 Redes neuro-fuzzy

As diferenças básicas das redes neurais e sistemas *fuzzy* não são obstáculos ao processo de manipulação de problemas imprecisos e não-lineares. A integração destes dois sistemas é baseada na combinação das virtudes de cada um deles a fim de diminuir suas deficiências, e desenvolver um sistema mais eficiente, robusto e compreensível.

Uma rede *neuro-fuzzy* pode ser definida como sendo um sistema *fuzzy* que é treinado por algum algoritmo derivado da teoria das redes neurais (ZADEH, 1987). Este tipo de rede é o resultado da união destes dois modelos. Com isto, tem-se a capacidade das redes neurais em reconhecimento e classificação.

Zadeh (1987) percebeu que o conhecimento humano é incerto, incompleto e impreciso, além de observar que a complexidade do sistema depende da forma como as variáveis são representadas e manipuladas.

2.4 Cartas de Controle (X_{ind})

Quando somente medidas individuais estiverem disponíveis, torna-se necessário o emprego das cartas de controle X_{ind} . A carta X_{ind} tem como objetivo controlar as medidas individuais do processo (Buchaim et al, 1994; Montgomery, 2000).

Segundo Montgomery (2000), supondo-se um processo onde a característica de qualidade de interesse (X_i) a ser controlada tenha distribuição normal com média μ e desvio padrão σ .

Se $X_1, X_2, X_3, \dots, X_n$ são amostras resultantes das observações individuais, ou seja, amostras de tamanho $n=1$ de distribuição com média μ e desvio padrão $\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}} = \sigma$ pois $n=1$, ou seja

$\bar{X} \sim N\left(\mu, \sigma_{\bar{X}}\right) = N(\mu, \sigma)$. Assim, com as propriedades da distribuição normal, pode-se concluir que existe uma probabilidade igual a $(1-\alpha)$ de que a média do processo esteja entre $\mu - Z_{\frac{\alpha}{2}}\sigma$ e $\mu + Z_{\frac{\alpha}{2}}\sigma$,

ou seja, no intervalo de confiança $P\left(\mu - Z_{\frac{\alpha}{2}}\sigma < \bar{X} < \mu + Z_{\frac{\alpha}{2}}\sigma\right) = (1-\alpha)$.

Utilizando-se o sistema 3σ , que consiste em fazer $Z_{\frac{\alpha}{2}} = 3$. Neste caso, quando $k=3$, indica que 99,73% das observações da carta de controle estão no intervalo $\mu \pm 3\sigma$, ou seja,

$P\left(\mu - 3\sigma < \bar{X} < \mu + 3\sigma\right) = 0,9973$ que é a probabilidade de ocorrência das observações dentro desse

intervalo. Através do sistema 3σ , podemos concluir que a probabilidade do gráfico emitir um falso alarme é igual a $(1-\alpha) = (1-0,9973) = 0,0027$, ou seja, 0,027% que é a probabilidade de ocorrência de valores fora do intervalo de $(\mu \pm 3\sigma)$ considerado.

Usando $\hat{\mu} = \bar{X}$ e $\hat{\sigma} = \frac{\bar{R}_m}{d_2}$ como estimadores de μ e σ respectivamente, a carta de

controle para medidas individuais X_i fica definida com os seguintes parâmetros:

Limite Superior de Controle

$$LSC_x = \bar{X} + \frac{3}{d_2} \bar{R}_m \quad (1)$$

d_2 : é uma constante tabelada em função da amplitude móvel utilizada.

Linha Média

$$LM_x = \bar{X} \quad (2)$$

que representa o valor médio da característica de qualidade em estudo correspondente ao estado sob controle.

Limite Inferior de Controle

$$LIC_x = \bar{X} - \frac{3}{d_2} \bar{R}_m \quad (3)$$

onde:

$$\text{A média do processo: } \bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

Conforme Montgomery (2000), para avaliar o desempenho de uma carta de controle e comparar vários procedimentos, podemos levar em conta os valores dos erros Tipo I (risco de um ponto cair fora dos limites de controle, indicando uma condição fora de controle quando nenhuma causa assinalável está presente) e Tipo II (é o risco de um ponto cair entre os limites, quando o processo está realmente fora de controle) associados às tomadas de decisão e as conseqüências econômicas deles resultante, isto é, custo associado à procura do problema inexistente e o custo associado a fraca qualidade que se obtém no produto final desde que a mudança ocorre até que seja detectada.

3. Aspectos Metodológicos

O método de pesquisa científica do ponto de vista da natureza e da forma de abordagem do problema proposto para este projeto pesquisa enquadra-se, de acordo com Silva & Menezes (2001), na categoria de pesquisa aplicada quantitativa. A pesquisa aplicada quantitativa tem como objetivo gerar conhecimentos para aplicação prática dirigida à solução de problemas específicos com o uso de recursos e técnicas estatísticas, que no caso é de desenvolver um modelo com base na aplicação da metodologia híbrida neuro-fuzzy (redes neurais e lógica fuzzy) em conjunto com as cartas de controle para identificar padrões de processos produtivos cujas observações sejam autocorrelacionados.

Os dados foram coletados diariamente no período de março a abril de 2010 na Indústria Têxtil Oeste Ltda., no município de Mondai – SC. referentes a gramatura da fiação do tecido.

4. ANÁLISE DOS DADOS

Os dados analisados representam medidas individuais da gramatura da fiação do tecido inerentes ao processo de tecelagem na produção de sacos da Indústria Têxtil Oeste Ltda. de Mondai, Santa Catarina, no período de março a abril de 2010 do tear 27, representado na Figura 1.




Figura 1– Gráfico da série original da gramatura

Observando-se o comportamento dos dados originais, pode-se afirmar que a série é estacionária, com uma mudança na média do processo na observação (7).

Nas Figuras 2 e 3, apresenta-se as funções de autocorrelação e autocorrelação parcial da série obtida pela rede neuro-fuzzy. As figuras 2 e 3 representam as funções de autocorrelação e autocorrelação parcial. As funções de autocorrelação e autocorrelação parcial indicam que os dados podem ser ajustados através de um modelo AR(1), pois a função de autocorrelação apresenta somente o lag(1) estatisticamente significativo ao nível de significância de 5%. Para verificar-se a normalidade dos dados foi aplicado o teste de normalidade de Kolmogorov-Smirnov (Conover, 1971), o qual apresentou um valor de ($p\text{-value} = 0,23 > 0,05$), podendo-se assim garantir que os dados se ajustam a uma distribuição normal, ao nível de significância de 5%.




Figura 2 – Gráfico dos coeficientes da Função de Autocorrelação




Figura 3 – Gráfico dos coeficientes da Função de Autocorrelação Parcial

4.1 Ajustamento dos dados da gramatura através do modelo AR(1) sem intervenção

$$X_t = 63,78604 + 0,7274 X_{t-1} + a_t$$

As estatísticas de ajuste forão: $R^2 = 78\%$; AIC = -3, 1430; BIC = -3,0784

Ao se analisar a série residual, encontrou-se um ponto no lag(5) = -0,274 fora dos limites de controle, indicando que o modelo não gerou uma série de erros aleatórios, logo deve-se investigar o efeito da mudança da média do processo.

4.2. Ajustamento dos dados da gramatura através do modelo AR(1) com intervenção

Foram encontradas cinco intervenções significativas, sendo uma mudança na média do processo na observação 7, e quatro outliers significativos nas observações (2; 17; 21 e 28). O modelo representativo está apresentado na equação a seguir:

4.3. Carta de controle X_{ind}

A seguir apresenta-se na Figura 4, a carta X_{ind} de Shewhart para os dados obtidos pela rede nuro-fuzzy, a qual apresenta 10 pontos fora dos limites de controle, indicando que o processo está fora de controle, podendo ser o efeito da autocorrelação nas observações do processo e na Figura 5, apresenta-se a carta de controle X_{ind} para os resíduos obtidos pelo modelo ARMA(1) sem intervenção, o qual apresentou somente um ponto fora dos limites de controle, indicando que houve uma mudança média do processo, pois nesta semana houve problema no tear 27, em função de um ajuste na máquina .




Figura 4 - Carta X_{ind} para os dados originais




Figura 5 - Gráfico para os resíduos da rede neuro-fuzzy

Na Figura 6, apresenta-se gráfico de controle X_{ind} para os resíduos obtidos pela rede neuro-fuzzy, o qual não apresentou nenhum ponto fora dos limites de controle, indicando que o modelo incorporou os outliers, bem como a mudança na média do processo. Assim, pode-se afirmar que o modelo ajustado para os resíduos da rede neuro-fuzzy, ARMA(1) com intervenção tem condições de eliminar os alarmes falsos produzidos pela autocorrelação nos dados referentes a um processo produtivo.




Figura 6 - Gráfico X_{ind} para os resíduos do ARMA(1) com intervenção

5. CONSIDERAÇÕES FINAIS

O presente trabalho encontrou base nos procedimentos da rede neuro-fuzzy, das cartas de controle para medidas individuais de Shewhart (X_{ind}), utilizadas para dados independentes e normalmente distribuídos, as quais tem como objetivo, detectar mudanças no processo na média.

Concluindo pode-se afirmar que realmente as cartas de controle são ferramentas que podem servir para acompanhar o comportamento das características de qualidade, auxiliando os profissionais da área monitorarem os seus processos com o objetivo de manterem serviços de qualidade para os seus clientes.

REFERÊNCIAS

- ALWAN, L. C. & ROBERTS, H. V. (1988). Time Series Modeling for Statistical Process Control. **Journal of Business and Economic Statistics**, v. 6, p. 87-95.
- ALWAN, L. C. (1992). Effects of Autocorrelations on Control Chart Performance. **Communications in Statistics – Theory and Methods**, v. 21, p. 1025-1049.
- BALESTRASSI, P. P. (2000) . **Identificação de padrões em gráficos de controle estatístico de processos, em tempo real, utilizando séries temporais e redes neurais artificiais**. Florianópolis, Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.
- BOX, G. E. P. & JENKINS, G. M. (1976). **Time series analysis: forecasting and control**, revised edition. San Francisco: Holden-day.
- BOX, G. E. P., JENKINS, G. M. & REINSEL, G. C. (1994). **Time Series Analysis, Forecasting and Control**. 3rd ed. Prentice Hall, Englewood Cliffs, N.J.
- BOX, G.E.P. & Kramer, T. (1992). **Statistical Process Monitoring and Feedback Adjustment - A Discussion**. **Technometrics**, v. 34, n. 3, 251-285.

- CAMARGO, M.E.; TEIXEIRA, J.M.G.; ANSUJ, A.P.; FRIEDRICH, H.R. (1998). The Use of Some Techniques in Statistical Process Control. **Anais do Congresso Optimization 98**. Lisboa.
- COX, E. (1994). *The Fuzzy Systems Handbook*. Academy Press Inc.. Estados Unidos.
- DAYHOFF, J. E. (1990). **Neural Network Architectures: An Introduction**. New York, Van Nostrand Reinhold.
- DRIANKOV, D.; HELLENDORF, H.; REINFRANK, M. (1996). **An Introduction to Fuzzy Control**, Springer-Verlag, 1996.
- ERMER, D.S. (1980). A control chart for dependent data. **ASQC 34th Annual Technical Conference Transactions**, Atlanta, Georgia.
- FULLER, R. (1995). **Neural Fuzzy Systems**. Abo Akademi University.
- GU LBAY, M.; KAHRAMAN, C.. (2006). Development of fuzzy process control charts and fuzzy unnatural pattern analyses. **Computational Statistics & Data Analysis**, vol. 51, 434–451.
- GU LBAY, M.; KAHRAMAN, C.. (2007). An alternative approach to fuzzy control charts: direct fuzzy approach. **Information Sciences** , vol. 177 (2007) 1463–1480.
- GULBAY , M. ; KAHRAMAN, C.. (2007). An alternative approach to fuzzy control charts: Direct fuzzy approach. **Information Sciences**, vol. 177, 1463–1480.
- HAYKIN, S. (1994). **Neural Networks: A Comprehensive Foundation**. New York: MacMillan Publishing Company.
- HARRIS, T.J. & ROSS, W.H. (1991). Statistical process control procedures for correlated observations. **The Canadian Journal of Chemical Engineering**, v.69, p.48-57.
- HUNTER, J.S.. The exponentially weighted moving average. **Journal of Quality Technology**, 1986, 18.12. Jones, R. H., Change detection model for serially correlated multivariate data, **Biometrics**, 1970 (26), 269-279.
- HSIEH, K.L., Tong, L.I., Wang, M.C. (2007). The application of control chart for defects and defect clustering in ic manufacturing based on fuzzy theory. **Expert Systems with Applications**, vol. 32 , 765–776.
16. HWRANG H.B.; HUBELE N.F., (1993). X-Bar Control Chart Pattern Identification Through Efficient Off-line Neural Network Training. **IIE Transactions**, vol.25, 3, May.
17. KARTALOPOULOS, S. V. *Understanding Neural Networks and Fuzzy Logic*. IEEE PRESS, 1996.