

# INTELIGÊNCIA ARTIFICIAL APLICADA AO CONTROLE ESTATÍSTICO DE PROCESSOS EM SISTEMAS AUTOMATIZADOS DE MANUFATURA

**Pedro Paulo Balestrassi**

EFEI –Escola Federal de Engenharia de Itajubá - e-mail: [pedro@eps.ufsc.br](mailto:pedro@eps.ufsc.br)

**Robert Wayne Samohyl**

UFSC - Departamento de Engenharia de Produção e Sistemas - e-mail: [samohyl@eps.ufsc.br](mailto:samohyl@eps.ufsc.br)

**Fernando Ostuni Gauthier**

UFSC – Departamento de Engenharia de Produção e Sistemas - e-mail: [gauthier@eps.ufsc.br](mailto:gauthier@eps.ufsc.br)

**Abstract:** *This study aims to present a focus on Statistical Process Control (SPC) by using Applied Intelligence techniques as Neural Networks and Fuzzy Logic. The SPC is a powerful tool extensively used in Industrial Engineering (Manufacturing Systems) and the adoption of Automated Manufacturing Systems has been increasing in recent years due to a greater demand for products diversification, with a higher quality and in a shorter delivery time. The quality control of the process in such situations demands flexible and intelligent quality control systems. So, it is proposed the presentation of SPC through the use of Applied Intelligence techniques according to the following steps:*

- *To simulate of an Automated Production Process;*
- *To envelope pre-processing techniques and Neural Networks;*

**Area:** *Controle Estatístico de Qualidade*

**Keywords:** *SPC, Applied Intelligence, Neural Networks*

## 1. Introdução

Esse trabalho descreve um exercício em Controle Estatístico de Processos (CEP) em um sistema automatizado de manufatura onde são utilizadas técnicas de Inteligência Artificial (IA). Esse tipo de sistema tem apresentado um enorme crescimento e a adoção de agentes inteligentes no desempenho de algumas funções como reconhecimento de padrões e diagnóstico de problemas, tarefas até então feitas pelo ser humano, certamente será a tônica dos próximos anos.

Na próxima seção serão vistos alguns conceitos fundamentais de IA. Na seção 3 o CEP será resumidamente apresentado, abordando principalmente o reconhecimento de padrões não aleatórios das cartas de controle. A seção 4 se ocupará com a contextualização do CEP em sistemas automatizados de manufatura em termos de IA. A construção de uma base de dados para treinamento e teste de um agente será descrito na seção 5. A seção 6 apresentará a rede neural fuzzy-Artmap, um algoritmo, além de algumas técnicas de pré-processamento. Na seção 7 a medida de desempenho abordando *ARL (Average Run Length)* é descrita e na seção 8 alguns resultados são apresentados.

Para esta aplicação foram geradas 3200 cartas de controle usando simulação (cada carta com 60 pontos) e os resultados em termos de reconhecimento de padrões mostraram ser satisfatórios.

## 2. Inteligência Artificial (IA)

A IA tem sido definida como “um campo de estudo que procura explicar e simular o comportamento inteligente em termos de processos computacionais” (Schalkoff, 1990) ou ainda como “um ramo da ciência da computação que se preocupa com a automação do comportamento inteligente”(Luger&Stubbefield, 1993). Nesse sentido, a IA é categorizada

como um sistema que atua racionalmente e é vista como o estudo e construção de agentes racionais.

Um agente é algo que pode perceber seu meio ambiente através de sensores e atuar sobre esse ambiente através de alguns mecanismos. Um agente racional é um agente que toma a ação correta (Russel&Norvig, 1995). Uma medida de desempenho é o critério que determina o quão bom é o agente racional e a tarefa da IA é projetar um programa agente que implemente um mapeamento entre a percepção do meio ambiente e uma referida ação. Esse programa irá rodar em algum tipo de arquitetura e o relacionamento entre agente, arquitetura e programa pode ser sintetizado pela expressão:


Agente = Arquitetura+Programa.

### 3. Aplicação

Uma aplicação que está perfeitamente inserida nesse contexto se refere ao Controle Estatístico de Processos (CEP) em Sistemas Automatizados de Manufatura. As Cartas de Controle são aqui as mais importantes e também as mais conhecidas ferramentas. Elas são úteis em determinar se um processo está se comportando como desejado ou se existem algumas causas não naturais de variação interagindo no processo. Um processo está fora de controle se um ponto (por exemplo, uma medida obtida de um sensor em um processo de manufatura automatizado) situa-se fora dos chamados limites de controle ou uma série de pontos exibem um comportamento não natural (também conhecido como padrão não aleatório).

A análise dos padrões não aleatórios é um dos mais relevantes aspectos do CEP. Esses padrões fornecem valiosas informações relacionadas com a melhoria de um processo. Existe uma vasta literatura técnica sobre tais padrões que associam frequentemente um conjunto específico de causas assinaláveis a um determinado padrão não natural em uma carta de controle. A identificação desses padrões pode fortemente estreitar o conjunto de causas que devem ser investigadas em possíveis problemas e assim o tempo de diagnóstico pode ser substancialmente reduzido.

Desde a sua formal concepção em 1924 por Walter Shewhart, numerosas regras suplementares conhecidas como *Runs Tests* ou *Zone Tests* (Western Electric 1958, Nelson 1984) tem sido propostas para analisar os padrões não aleatórios das cartas de controle. A figura 1 mostra um desses conjuntos de regras clássicas. Essas regras foram desenvolvidas para assistir os operadores na detecção de padrões não naturais. Contudo, a interpretação dos dados de um processo qualquer ainda permanece difícil pois isso envolve aspectos de reconhecimento de padrões que frequentemente leva em consideração a experiência do analista em determinar se um padrão não natural existe ou não.



- 1) 1 ponto acima do limite de controle
- 2) 2 pontos em 3 consecutivos acima de 2 desvios
- 3) 4 pontos em 5 consecutivos acima de 1 desvio
- 4) 7 pontos consecutivos além da linha média
- 5) 6 pontos consecutivos crescentes ou decrescentes
- 6) 8 pontos crescentes ou decrescentes em 10
- 7) 2 pontos consecutivos com diferença de 4 desvios

Figura 1: *Runs Tests* clássico

### 4. A Aplicação em Termos de IA

Para a aplicação anteriormente sugerida um agente racional pode ser descrito em termos de IA de acordo com a tabela 1.

Tipo de Agente	Sistema de reconhecimento de padrões não aleatórios em gráficos de CEP.
Percepção	Medidas de um item de controle obtidas em tempo real por meio de sensores.
Ação	Sugerir causas de possíveis problemas de produção a um operador, atuar no processo interrompendo a produção, acionar controladores, sinalizar, etc...
Objetivo	Reconhecer determinados tipos de padrões em séries temporais e suas possíveis causas.
Ambiente	Sistemas de manufatura automatizados

Tabela 1: Um Agente e sua descrição em termos de IA.

O ambiente no qual este agente está definido possui as propriedades descritas pela tabela 2.

Acessível	Os sensores detectam todos os aspectos que são relevantes para a escolha da ação a ser tomada.
Determinístico	O próximo estágio do ambiente é completamente determinado pelo estado atual e ações selecionadas pelo agente
Episódico	Cada episódio consiste da percepção e ação de um agente
Semi-Dinâmico	O ambiente não muda com o passar do tempo mas o desempenho do agente sofre alterações
Discreto	Existe um número limitado de percepções e ações a ser tomadas pelo agente

Tabela 2: As Propriedades do Ambiente do Agente

O programa agente a ser implementado é do tipo *reflexo simples* que usa conexões do tipo *regra if-then* ou *regra condição-ação* e está representado na figura 2. Uma das mais importantes técnicas para a percepção do ambiente consiste hoje nas Redes Neurais e a ação a ser tomada pode ser efetuada a partir de um Sistema Especialista avaliando a *regra condição-ação*. Temos assim nesse caso um agente usando um programa híbrido.

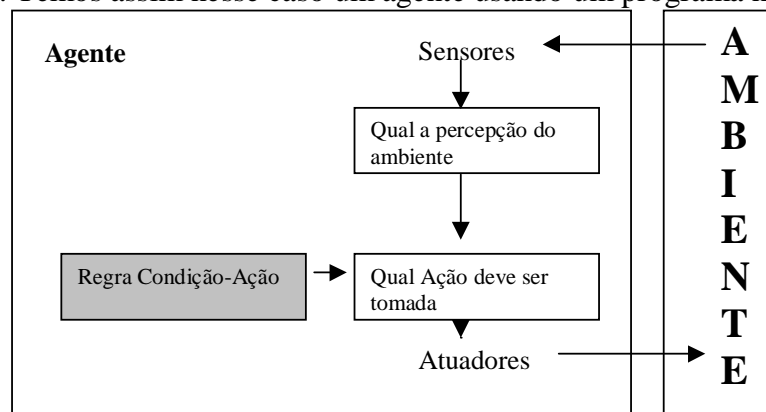


Figura 2 – Agente do tipo Reflexo Simples

No contexto da aplicação os seguintes passos exemplificam a atuação do agente descrito:

1. 60 medições são obtidas a partir de um sensor em um processo de manufatura qualquer;
2. Uma rede neural anteriormente treinada identifica um padrão aleatório do tipo *tendência*
3. Um Sistema Especialista identifica a partir de um conhecimento prévio que a tendência detectada anteriormente está relacionada com a deterioração da matéria-prima;
4. Um sistema de alarme indica que a matéria prima deve ser averiguada.

Guo&Dooley (1992) descreve que o CEP pode ser pensado como consistindo de vários estágios (*observação, avaliação diagnóstico, decisão e implementação*) os quais ele define como *Janelas de Qualidade*. Assim, o processo é *observado* através dos dados do produto e então a estabilidade do processo é *avaliada* por meio dos padrões não aleatórios das cartas de controle. Um padrão não aleatório implica em um *diagnóstico* de uma possível causa para o comportamento não aleatório e uma vez identificada a causa, uma *decisão* deve ser tomada no sentido de uma ação corretiva que é então *implementada*.

Devido ao caráter didático, o restante desse trabalho se ocupará somente com o estudo da fase de *avaliação* deixando as outras fases para posteriores estudos.

## 5. Construção do Banco de Dados

Na geração dos padrões aleatórios e não-aleatórios de CEP, para o treinamento e teste das redes neurais, os principais cuidados a serem tomados estão relacionados com a sua boa representatividade das situações reais dos padrões de um processo. Deve-se ter assim um bom balanceamento de padrões para a entrada das redes neurais durante o treinamento e teste e sobretudo os padrões não devem mostrar ambigüidade no sentido de fornecer uma boa indicação de causas assinaláveis de variação, auxiliando assim o operador ou possibilitando a inserção de Sistemas Especialistas numa posterior etapa de tomada de decisão. A figura 3 mostra um processo de geração do banco de dados de treinamento onde foi usada a orientação dos trabalhos de Hwang&Hubele (1993), Guo&Dooley (1992) e Tontini(1995).




Figura 3: Geração do conjunto de treinamento

Nesse esquema são geradas 60 amostras de uma distribuição normal  $N(0,1)$  constituindo um gráfico de CEP. Em seguida é feito um teste de normalidade sobre esse gráfico usando as cartas de Shewhart para pontos individuais, a Soma dos Quadrados dos Desvios e também Carta CUSUM. Caso o processo não seja normal devido a um desses 3 testes uma nova carta deve ser gerada. Em caso de normalidade um padrão não natural é gerado por meio de algumas equações clássicas e há uma consecutiva inserção de pontos não naturais no gráfico de controle normal até que o padrão não natural seja identificado pelo mesmo teste de normalidade. Esse deslocamento tem o intuito de simular um processo real onde os padrões não naturais vão surgindo com o tempo. O deslocamento da janela de pontos é um mecanismo de inserção de um padrão não natural em um padrão natural. Por meio desse mecanismo, pode ser obtido o ARL (*Average Run Length*) e o número de amostras necessárias para a determinação do reconhecimento de padrões não naturais (Mittag 1993). Caso o padrão tenha sido identificado, ele é armazenado em um arquivo e o processo todo é reiniciado. Caso o padrão não seja identificado pelos testes, um novo padrão não natural é gerado até a sua identificação.

Dessa forma todo o conjunto de treinamento é gerado automaticamente abrangendo um grande escopo de padrões não naturais. Sendo gerado *off line*, tal banco de dados representa também um abrangente escopo de possibilidades de causas assinaláveis existentes em um processo automatizado de manufatura. Para treinamento não supervisionado, a obtenção desse banco de dados provavelmente poderia ser obtido por uma implementação em *hardware* usando placas de DSP (*Digital Signal Processing*), que conjuntamente com um conversor analógico/digital, permite a implementação de inúmeras ferramentas matemáticas como FFT, Ondaletas, etc.

Como resultado desse processo de geração, foram obtidos então 1400 padrões, divididos nas seguintes categorias:

Desvios da média: com amplitude de $\pm 1\sigma$ e $\pm 1.5\sigma$	(400)
Mistura: com amplitude de $1\sigma$ e $1.5\sigma$	(200)
Ciclos: com amplitude de $1\sigma$ e $1.5\sigma$ e período 20	(200)
Sistemáticos: com amplitude de $1\sigma$ e $1.5\sigma$	(200)
Diminuição da variabilidade: com amplitude de $0.5\sigma$ e $0.7\sigma$	(200)
Normais: $\sim N(0,1)$	(200)
	1400

A equação que define a geração dos números aleatórios pode ser sintetizada pela expressão:  $y(t) = \mu + a(t)$  com  $\mu=0$  e ruído  $a(t)$  com média zero e variância  $\sigma^2=1$ . As equações geradoras dos padrões não aleatórios estão bem representadas em Tontini (1995). Para que se consiga uma boa representatividade dos padrões gerados, não basta que eles sejam gerados por suas respectivas equações. É preciso garantir que algumas condições iniciais sejam satisfeitas. Não raro ocorre que uma carta de controle gerada aleatoriamente segundo uma distribuição normal apresenta padrões não naturais. Os testes a seguir tem a função de monitorar esse problema.

- a) *Teste de Shewhart para Pontos Individuais*
- b) *SSQ<sub>t</sub> (Soma dos Quadrados dos Resíduos)*
- c) *CUSUM (Gráfico de Somas Acumuladas - Cumulative Sums)*

O conjunto de treinamento e de testes dos padrões de CEP diferem ligeiramente no sentido de ampliar a sensibilidade de reconhecimento dos padrões. No conjunto de testes não foram incluídos os padrões de normalidade deixando para o sistema a identificação do padrão normal quando todos os outros testes falharem.

Como resultado desse processo de geração, foram obtidos 1800 padrões, divididos nas seguintes categorias:

Desvios da média: com amplitude de $\pm 1\sigma$ , $\pm 1.5\sigma$ e $\pm 2\sigma$	(600)
Mistura: com amplitude de $1\sigma$ , $1.5\sigma$ e $2\sigma$	(300)
Ciclos: com amplitude de $1\sigma$ , $1.5\sigma$ e $2\sigma$ e período 20	(300)
Sistemáticos: com amplitude de $1\sigma$ , $1.5\sigma$ e $2\sigma$	(300)
Diminuição da variabilidade: com ampl. de $0.5\sigma$ , $0.6\sigma$ e $0.7\sigma$	(300)
	1800

Foi considerado na geração dos padrões de teste, no deslocamento da janela de pontos, o valor da função *ARL*. A função *ARL* é um poderoso instrumento que descreve a *performance* das cartas de controle (a CCO- Curva Característica de Operação também pode fazer isso). Tal função representa a expectativa da variável aleatória *Run Length* que é o número de amostras que ocorrem entre duas intervenções consecutivas em um processo. A função *ARL* de uma carta de controle mostra como os valores de *ARL* dependem do estado do processo. Quando um processo está sob controle, esta função deveria possuir altos valores e para processos fora de controle, a função deveria apresentar baixos valores.

## 6. Redes Neurais

O banco de dados gerado nos moldes do capítulo anterior é agora experimentalmente testado com respeito ao reconhecimento dos padrões das cartas de controle de CEP. Em sua primeira parte experimental foi utilizada a rede neural Fuzzy ARTMAP. Os valores dos parâmetros da rede, foram selecionados a partir da literatura existente (Tontini,1995), onde a técnica de *Projetos de Experimentos* foi extensivamente utilizada.

Aplicados como entrada das redes neurais sem nenhum tipo de pré-processamento, as cartas de controle do banco de dados não tiveram uma satisfatória taxa de acertos em termos de reconhecimento de padrões. Isto não é fato novo e foi satisfatoriamente relatado na literatura técnica (Guo&Dooley,1992). O pré-processamento aqui utilizado, valendo-se de métodos de fácil computação teve a tarefa de eliminar as observações espúrias das cartas de controle, diminuindo o número de entradas para as redes neurais e aumentando em muito a eficiência das redes.

A escolha feita pela rede Fuzzy ARTMAP como passo inicial de experimentação, em detrimento da escolha da rede *Multilayer Perceptron* treinada por *Backpropagation* procura dar continuidade aos trabalhos de Guo&Dooley (1992), Hwang&Hubele (1993) e Tontini (1995). A rede treinada por *Backpropagation* (em uma de suas versões) foi já testada nos trabalhos de Cheng (1989) e seus resultados apesar de promissores, foram

superados. A figura 4 mostra como os pontos das cartas de controle foram transformados e inicialmente utilizados nas redes neurais.

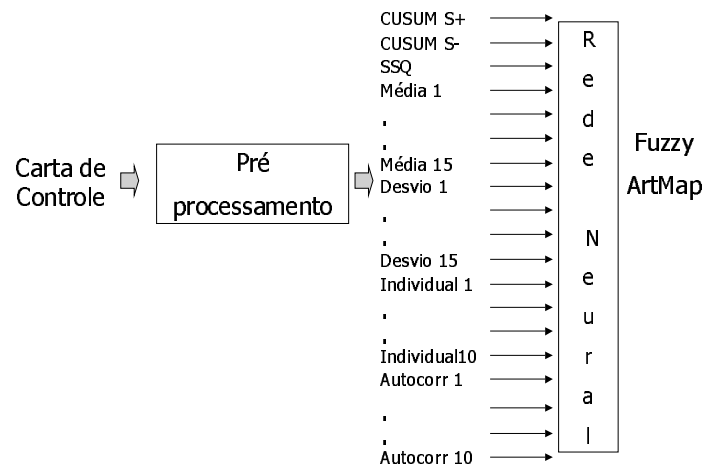


Figura 4: Processo experimental com as redes neurais evidenciando o pré-processamento

Os valores máximos das estatísticas da carta de somas acumuladas (CUSUM) tem a finalidade de auxiliar na monitorização do desvio da média. A Soma dos Quadrados dos Resíduos (SSQ) visa auxiliar na monitoração da variabilidade do processo e na discriminação entre os padrões de Mistura, Sistemático e Diminuição da Variabilidade. Os 60 pontos das cartas de controle são subdivididos em 15 faixas menores contendo 4 pontos por faixa onde são calculadas as Médias e Desvios Padrões com a finalidade de ajudar na identificação de padrões como mistura e sistemático. Os padrões aqui estudados tem uma grande amplitude e podem ocasionar um ponto fora de controle muito antes das estatísticas anteriores terem informação suficiente para sinalizar que tipo de padrão está ocorrendo. Os últimos 10 pontos individuais das cartas de controle estão, estreitamente relacionados com os padrões que se quer identificar e serão aqui utilizados. Tais pontos tem a finalidade de ajudar na identificação dos padrões de mistura e sistemático.

#### *Rede Fuzzy-ARTMAP*

A teoria de Ressonância Adaptativa, ou ART, foi introduzida como uma teoria sobre o processamento cognitivo de informações no cérebro humano. Essa teoria levou ao desenvolvimento de uma série de modelos de redes neurais capazes de um aprendizado não supervisionado para classificação de padrões em tempo real. Os modelos nessa família compreendem: a rede ART1, que pode aprender a categorizar padrões de entrada binários apresentados em ordem arbitrária; a rede ART2, que pode aprender a categorizar padrões de entrada analógicos ou binários; e a rede ART3, que pode fazer uma busca paralela, ou teste de hipóteses, em códigos com reconhecimento distribuído.

A rede ART1 foi usada no projeto de uma rede com arquitetura hierárquica chamada ARTMAP que tem aprendizado instantâneo, estabelecendo uma associação entre padrões binários de entrada com binários de saída. A rede Fuzzy-ART é uma generalização da rede ART1 para torná-la capaz de reconhecer padrões binários e analógicos, sendo muito mais simples que a ART2.

O desenvolvimento da rede Fuzzy-ARTMAP permitiu a adaptação da rede ARTMAP para a utilização de padrões analógicos tanto na entrada como na saída. A rede Fuzzy-ARTMAP é uma generalização da rede binária ARTMAP. Ela é capaz de um aprendizado supervisionado incremental, atualizando-se durante a operação sem “esquecer” o que já aprendeu anteriormente. A rede Fuzzy-ARTMAP pode ser empregada para classificação e/ou associação de padrões binários e/ou analógicos de entrada e saída com dimensão arbitrária.

A rede Fuzzy-ARTMAP incorpora dois módulos Fuzzy-ART: ARTa e ARTb, conectados através de um módulo inter-ART,  $F^{ab}$ , chamado Módulo de Ligação (*map field*). Os Módulos ARTa e ARTb funcionam da mesma maneira que a rede Fuzzy-ART, exceto pela

interação com o módulo de ligação. O módulo de ligação é usado para fazer associações preditivas entre categorias nas redes ARTa e ARTb e para executar a pesquisa de similaridade, onde o nível de vigilância ( $\rho_a$ ) do módulo ARTa aumenta em resposta a um erro de previsão no módulo ARTb. A pesquisa de similaridade reconhece a estrutura de uma categoria de tal maneira que o erro de previsão não será repetido em apresentações subsequentes da mesma entrada. A operação da rede Fuzzy-ARTMAP está bem apresentada em Carpenter (1995)

O algoritmo inicialmente aqui utilizado foi codificado por Lars Liden (laliden@cns.bu.edu) em 1995 sob a forma de um conjunto de subrotinas em C (denominadas de *The Art Gallery*), que rodam em plataforma DOS/Windows e UNIX. É possível usar tais subrotinas em um código pessoal pois a DLL (*Dynamic Linked Library*) é disponibilizada. Suportando tanto aprendizagem supervisionada como não-supervisionada, o pacote computacional emprega dois tipos diferentes de redes: ART, para o modo não supervisionado, e ARTMAP para o modo supervisionado. Ambos os modos de redes são construídos de componentes ART's, os quais podem tomar diferentes formas, inclusive ART1 e Fuzzy-Art.

## 7. Medidas de Desempenho

Um conjunto extenso de simulações é necessário para se testar a capacidade da rede em detectar os diversos padrões não naturais das cartas de controle. Nesse sentido, o algoritmo da rede neural é repetidamente aplicado às sequências de dados e quando o padrão de interesse é detectado, o *run length* (número de pontos até a detecção do padrão não natural) é obtido. Com um número considerável de *run lengths* pode-se ter o cálculo do *ARL*.

Dois tipos de falsos alarmes podem ocorrer na utilização da maioria dos algoritmos que lidam com o reconhecimento dos padrões de CEP. O primeiro resulta quando o algoritmo detecta um padrão não natural qualquer quando ele de fato não existe (ou seja, o processo está sobre controle e o algoritmo diz que não está). O segundo é quando o algoritmo detecta um padrão não natural mas o padrão detectado não corresponde ao padrão alvo simulado (ou seja, há um erro na identificação do padrão, por exemplo, o algoritmo detecta um ciclo quando de fato há um desvio da média). Esse segundo falso alarme é frequentemente mais difícil de evitar pois muitos padrões, incluindo ciclos, contém outros tipos de padrões como por exemplo as tendências.

O desempenho de um sistema de reconhecimento de padrões é usualmente avaliado por sua capacidade de classificação e generalização. A capacidade de classificação avalia se um sistema treinado tem aprendido a classificar corretamente os dados de um conjunto de treinamento enquanto a capacidade de generalização se refere a habilidade do sistema treinado em classificar corretamente dados similares que não foram vistos antes.

Usualmente, a *performance* de uma carta de controle é medida pelo *ARL* e uma importante contribuição, proposta por Hwang & Hubele (1993), usa a expressão abaixo:

$$ARL_{tx} = ARL_t / R_t$$

onde  $R_t$  é a percentagem de padrões no qual o padrão não natural alvo foi detectado primeiramente e  $ARL_t$  é o *ARL* para detectar o padrão não natural alvo.

O valor de  $ARL_{tx}$  descreve em síntese uma medida de desempenho de quão boa a rede é capaz em detectar um determinado tipo de padrão. É desejável que o  $ARL_{tx}$  seja baixo para o estado do processo em que haja padrões não naturais e alto para o caso de padrões normais.

Assim, no teste do desempenho da rede neural, uma medida deve ser avaliada em termos de ambos os erros (tipo I e tipo II), isto é, tanto os padrões não naturais quanto os padrões naturais devem ser usados para testar e computar essa medida. Um sistema de

reconhecimento de padrões não pode ser garantidamente útil na prática se ele não considera ambos os erros.

## 8. Resultados e Conclusões

Os resultados do reconhecimento de padrões dos gráficos de controle são surpreendentes se comparados ao reconhecimento feito por um especialista (um estudo pormenorizado está sendo feito nesse sentido) com taxas de acerto na ordem de 84%. Imagine a complexidade e o tempo para um especialista investigar padrões variantes com o tempo em 3200 cartas de controle!. Algumas preliminares conclusões são dadas a seguir:

- Devido a sua grande quantidade, a ordem de apresentação dos padrões de treinamento não evidenciou maiores discrepâncias nos resultados (teste de Fisher).
- O tempo de processamento, extremamente curto em relação ao treinamento por *Backpropagation*, mostrou ser uma importante vantagem nesse tipo de metodologia, ainda mais quando consideramos que a plasticidade é uma das características desse tipo de rede. Para tarefas semelhantes, em tempo real, intervalos pequenos de treinamento podem ser incorporados no sentido de detectar *deslocamentos de níveis* ou o aprendizado de novos padrões das séries temporais sob investigação (nesse caso o modelamento por meio de ARMA e ARIMA são extremamente complexos).

Algumas vantagens da rede Fuzzy-Artmap devem ser enfatizadas pois atendem a uma gama de processos que lidam com reconhecimento de padrões, principalmente aqueles que tratam com sistemas automatizados de manufatura, uma tendência dos processos atuais.

- Tratar simultaneamente diversos tipos de informações, provenientes de diversas fontes, analisando-as em tempo real;
- Adaptar-se a mudanças no processo e *aprender* com problemas e exemplos ocorridos durante sua operação, mesmo que esses exemplos não tenham sido estruturados;
- Estabelecer correlações entre um grande número de variáveis, mesmo que essas relações não sejam bem definidas e que haja interação entre as variáveis;
- Tratar situações novas, generalizando através da experiência passada;

## 9. Bibliografia

1. Schalkoff, R.J. (1990) *Artificial Intelligence*, McGraw-Hill, New York.
2. Luger, G. F.; Stubblefield, W. A. (1993), *Artificial Intelligence – Structures and Strategies for Complex Problem Solving*. Benjamin/Cummings, California.
3. Russel S.; Norvik, P. (1995) *Artificial Intelligence*, Prentice Hall New Jersey
4. Nelson L.S.(1985) Interpreting Shewhart X-bar Control Charts, *Journal of Quality Technology*, vol 17,2.
5. Hwang H.B.;Hubele N.F.,X-Bar Control Chart Pattern Identification Through Efficient Off-line Neural Network Training, *IIE Transactions*, Vol 25, 3, May 1993
6. Guo, Y.;Dooley, K. J.(1992) *Identification of Change Structure in Statistical Process Control*, *International Journal of Production Research*, vol 30 7 ;
7. Tontini G. (1995) *Automatização da Identificação de Padrões em Gráficos de Controle Estatístico de Processos (CEP) Através de Redes Neurais com Lógica Difusa* - Tese de Doutorado UFSC;
8. Mittag, H. J.; Rinne, H. (1993 ) *Statistical methods of Quality Assurance* Chapman&Hall -Glasgow -393-44;
9. Cheng, C.S. (1997) *A neural Network Approach for the analysis of Control Chart Patterns*- *Int. J. Prod. Res.*, Vol.35, No 3, 667-697.
10. Carpenter G. A; Grossberg S. (1995) Fuzzy-ARTMAP: A Synthesis of Neural Networks and Fuzzy Logic for Supervised Categorization and Nonstationary Prediction; In *Fuzzy Sets, Neural Networks, and Soft Computing*. Yager, R.R. and Zadeh, L. A;