

**UNIVERSIDADE SANTA CECÍLIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA  
MESTRADO EM ENGENHARIA MECÂNICA**

**CLOVIS MISSENO DA CRUZ**

**APLICAÇÃO DA REDE NEURAL ARTIFICIAL PARACONSISTENTE EM  
CONTROLE ESTATÍSTICO DE PROCESSO**

**SANTOS/SP**

**2015**

**CLOVIS MISSENO DA CRUZ**

**APLICAÇÃO DA REDE NEURAL ARTIFICIAL PARACONSISTENTE EM  
CONTROLE ESTATÍSTICO DE PROCESSO**

Dissertação apresentada à Universidade Santa Cecília como parte dos requisitos para obtenção de título de mestre no Programa de Pós-Graduação em Engenharia Mecânica, sob orientação do Prof. Dr. João Inácio da Silva Filho e coorientação do Prof. Dr. Mauricio Conceição Mario.

**SANTOS/SP  
2015**

Autorizo a reprodução parcial ou total deste trabalho, por qualquer que seja o processo, exclusivamente para fins acadêmicos e científicos.

Cruz, Clovis Misseno da  
Aplicação da Rede Neural Artificial Paraconsistente em  
Controle Estatístico de Processos.  
/ Clovis Misseno da Cruz.-- 2015.  
n. de f.76

Orientador: Prof. Dr. João Inácio da Silva Filho.  
Coorientador: Prof. Dr. Mauricio Conceição Mario.

Dissertação (Mestrado) -- Universidade Santa Cecília, Programa  
de Pós-Graduação em Engenharia Mecânica, Santos, SP, 2015.

1. Controle estatístico de Processo. 2. Lógica  
Paraconsistente. 3. Rede Neural Artificial Paraconsistente.  
4. Algoritmo

I. Da Silva Filho, João Inácio, orient. II. Mario, Mauricio  
Conceição, coorient. III. Aplicação da Rede Neural Artificial  
Paraconsistente em Controle Estatístico de Processos.

Elaborada pelo SIBi – Sistema Integrado de Bibliotecas - Unisanta

Aos meus pais, Maria de Lourdes Misseno  
da Cruz e Antonio Rodrigues da Cruz.

## **AGRADECIMENTOS**

À minha esposa Cleide B. Fernandes da Cruz e aos meus filhos João Fernandes da Cruz e Luisa Fernandes da Cruz pelo apoio e paciência nestes meses de pesquisa.

Ao professor Dr. João Inácio da Silva Filho pela paciência e confiança como seu aprendiz na Lógica Paraconsistente, pessoa na qual tenho gratidão eterna.

Ao professor Dr. Maurício Conceição Mário pelo reconhecimento do trabalho e demonstração de que as coisas acontecem em seu tempo.

Aos colegas da turma de mestrados da UNISANTA, em especial, ao aluno e amigo Rolden Baptista pelo apoio durante todo o processo.

À equipe da secretaria de Mestrado, Sandra e Imaculada, pelo auxílio e pronto atendimento em todas as fases do processo de estudo.

## RESUMO

Mesmo obtendo-se bons resultados com as técnicas puramente estatísticas, os algoritmos de análises do Controle Estatístico de Processo (CEP) ainda podem ser aprimorados com o objetivo de uma análise mais eficiente capaz de oferecer um melhor tratamento às incertezas que acontecem quando da análise de dados do processo real. Neste trabalho, como uma alternativa para o aprimoramento do CEP no tratamento de informações originadas de Conhecimento Incerto, apresentamos a inclusão nas análises de novos algoritmos construídos com Lógica Paraconsistente (LP). A LP pertence à família de lógicas não-clássicas e apresenta em sua fundamentação a propriedade de aceitar a contradição sem que o conflito anule as conclusões. Através de sua extensão, denominada de Lógica Paraconsistente Anotada (LPA), podemos construir algoritmos especiais para processar sinais de informação nos quais as inconsistências nos valores podem ser suportadas. Neste trabalho são utilizadas as Redes Neurais Artificiais Paraconsistentes (RNAPs), que são estruturas computacionais compostas de células que consistem em algoritmos construídos conforme os fundamentos da Lógica Paraconsistente Anotada (LPA). Por meio de um arranjo lógico que interliga um tipo de algoritmo especial denominado de Célula Neural Artificial Paraconsistente de aprendizagem (CNAPap) e de outros fundamentados em LPA, foram executadas interligações com o objetivo de aumentar o índice de eficiência do Controle Estatístico de Processo. Para a execução deste trabalho de pesquisa foram simulados com Matlab quatro módulos, sendo que o primeiro faz o procedimento de extração de Grau de Evidência da variável aleatória de qualidade de entrada. O segundo contém uma técnica que produz a média móvel dos dados do processo em Grau de Evidência. O terceiro obtém o Intervalo de Evidência Resultante que fornece informação sobre a dispersão dos dados com relação à média. O último módulo gera alarmes quando o processo deixou de ter comportamento aleatório com base nos Graus de Evidência dos módulos anteriores. Por fim, a construção de um arranjo lógico estruturado de forma a serem consideradas as possíveis interligações dos algoritmos em um único módulo computacional que aqui foi denominado de Controlador Paraconsistente Estatístico de Processos – CEP-LPA.

**Palavras-Chave:** Lógica Paraconsistente. Lógica Paraconsistente Anotada. Controle Estatístico de Processo. Rede Neural Artificial Paraconsistente. Algoritmo.

## ABSTRACT

Even achieving good results with purely statistical techniques, the algorithms of analysis of Statistical Process Control (SPC) still can be refined with the aim of a more efficient analysis, able to offer better treatment about uncertainties that occurs at the moment data analysis of real process. In this work, as an alternative to the improvement of the SPC in the treatment of information derived from Uncertain Knowledge, we present the inclusion in the analysis of new algorithms built with Paraconsistent Logic (PL). The PL belongs to the non-classical logic family and has in its foundations the property of accept contradiction without that the conflict invalidate the conclusions. Through its extension, called Paraconsistent Annotated Logic (PAL), we can build special algorithms for processing information signals in which inconsistencies in the values can be tolerated. In this study, are used the Paraconsistent Artificial Neural Networks (PANnet), which are structures computational composed of cells which consisting of algorithms built as the foundations of Paraconsistent Annotated Logic (PAL). Through a logical arrangement that interconnects a special type of algorithm called Paraconsistent Artificial Neural Network Cell of learning (PANCI) and of other foundations of PAL were performed interconnections in order to increase the efficiency ratio of the Statistical Process Control. For the implementation of this research, it has been simulated with Matlab four modules, wherein the first does procedure of extraction of Degree of Evidence from random variable of the input quality. The second has a technique that produces the moving average of the process data into Degree of Evidence. The third obtains the Resultant Evidence Interval, which provides information on the variation of data about the mean. The last module generates alarms when the process no longer has random behavior, based on the Degrees of Evidence of previous modules. Finally, the construction of arrangement structured logic in order to be considered the possible interconnections of the algorithms on a single module computing which is here called Paraconsistent Statistical Process Controller – SPC-*PAL*.

**Keywords:** Paraconsistent Logic. Paraconsistent Annotated Logic. Statistical Process Control. Paraconsistent Artificial Neural Network. Algorithm.

## LISTA DE ILUSTRAÇÕES

FIGURA 1 - CAUSAS ATRIBUÍVEIS E ALEATÓRIAS DA VARIABILIDADE .....	19
FIGURA 2 – EXEMPLOS DE GRÁFICOS $\bar{x}$ E R.....	23
FIGURA 3 – REGRAS DE WESTERN ELECTRIC.....	24
FIGURA 4 – EXEMPLO DE REGRA POR ZONAS.....	25
FIGURA 5 – GRÁFICO DE CONTROLE DE SHEWHART.....	27
FIGURA 6 – GRÁFICO DE CONTROLE CUSUM. ....	27
FIGURA 7 – GRÁFICO DE CONTROLE EWMA .....	29
FIGURA 8 – RETICULADO ASSOCIADO À LÓGICA PARACONSISTENTE ANOTADA DE ANOTAÇÃO COM DOIS VALORES LPA2V. ....	35
FIGURA 9 – SÍMBOLO DE UMA CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE DE APRENDIZAGEM.....	38
FIGURA 10 – SÍMBOLO DE UMA CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE ANALÍTICA. .....	40
FIGURA 11 – SÍMBOLO DE UMA CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE DE DETECÇÃO DE IGUALDADE.....	41
FIGURA 12 – CONTROLADOR PARACONSISTENTE ESTATÍSTICO DE PROCESSOS – CEP-LPA. .....	43
FIGURA 13 – FUNÇÃO ESCORE Z. ....	44
FIGURA 14 – EXTRATOR DE GRAU DE EVIDÊNCIA DE ESCORE Z. ....	45
FIGURA 15 – CURVA NORMAL – DESLOCAMENTO DE MÉDIA. ....	46
FIGURA 16 – CURVA NORMAL – AUMENTO DESVIO PADRÃO. ....	46
FIGURA 17 – VARIAÇÃO DA MÉDIA AMOSTRA A AMOSTRA. ....	49
FIGURA 18 – CURVA DE APRENDIZAGEM DA MÉDIA DAS CNAPAPS.....	50
FIGURA 19 – PERCENTUAL DE ERRO RESIDUAL EM FUNÇÃO DO NÚMERO DE CNAPAP. ....	53
FIGURA 20 – UNIDADE NEURAL ARTIFICIAL PARACONSISTENTE DE EXTRAÇÃO DE MÉDIA MÓVEL- UNAPEMM. ....	53
FIGURA 21 – GRÁFICO DE CONTROLE PARA VALORES INDIVIDUAIS.....	58
FIGURA 22 – GRÁFICO CUSUM TUBULAR.....	58
FIGURA 23 – EXEMPLO GRÁFICO PARA O PADRÃO 9, ITEM 4. ....	67
FIGURA 24 – EXEMPLO GRÁFICO PARA O PADRÃO 1, ITEM 17. ....	67
FIGURA 25 – EXEMPLO GRÁFICO PARA O PADRÃO 5, ITEM 17. ....	68
FIGURA 26 – EXEMPLO GRÁFICO PARA PADRÃO 5, ITEM 18. ....	69
FIGURA 27 – EXEMPLO GRÁFICO PARA O PADRÃO 5, ITEM 19. ....	69

## LISTA DE TABELAS

TABELA 1 – RESULTADOS DO ENSAIO COM UMA CNAPAP.....	48
TABELA 2 – RESULTADO DA APRENDIZAGEM DAS 12 CNAPAPS EM SÉRIE.....	51
TABELA 3 – ERRO RESIDUAL DE ATÉ 12 CNAPAPS EM SÉRIE.....	52
TABELA 4 – 10 PADRÕES SOB CONTROLE ESTATÍSTICO .....	59
TABELA 5 – TIPOS DE ALTERAÇÕES APLICADAS AOS 10 PADRÕES.....	60
TABELA 6 – RESULTADOS DOS ALARMES – PRIMEIRO ALARME .....	62
TABELA 7 – RESULTADOS DOS ALARMES – TEMPO DOS ALARMES .....	64

## LISTA DE SIGLAS

CAPb	Célula Neural Paraconsistente Básica
CEP	Controle Estatístico de Processo
CEP-LPA	Controle Paraconsistente Estatístico de Processo
CNAPa	Célula Neural Artificial Paraconsistente analítica
CNAPdi	Célula Neural Artificial Paraconsistente de detecção de igualdade
CNAPp	Célula Neural Artificial Paraconsistente padrão
CUSUM	Soma Acumulativa
EWMA	Média Móvel Exponencialmente Ponderada
LC	Linha Central
LIC	Limite Inferior de Controle
LIE	Limite Inferior de Especificação
LP	Lógica Paraconsistente
LPA	Lógica Paraconsistente Anotada
LPA2v	Lógica Paraconsistente Anotada com anotação de 2 valores
LSC	Limite Superior de Controle
LSE	Limite Superior de Especificação
Matlab	<i>Software</i> de programação de algoritmos matemáticos
Minitab	<i>Software</i> de análise estatística e probabilística
RAP	Redes de Análise Paraconsistentes
RNA	Rede Neural Artificial
RNAP	Rede Neural Artificial Paraconsistente
UNAP	Unidade Neural Artificial Paraconsistente
UNAPEmm	Unidade Neural Artificial Paraconsistente de Extração de média móvel

## LISTA DE SÍMBOLOS

$\tau$	Reticulado finito
$\sim$	Operador de negação
$\mu$	Grau de crença (ou de evidência favorável)
$\lambda$	Grau de descrença (ou evidência desfavorável)
$\mathbb{R}$	Conjunto dos números reais
T	Inconsistente
V	Verdadeiro
$\perp$	Paracompleto ou Indeterminado
$\rho T$	Conotação de Inconsistente à proposição $p$
$\rho 1$	Conotação de Verdade à proposição $p$
$\rho 0$	Conotação de Falsidade à proposição $p$
$\rho \perp$	Conotação de Paracompleteza à proposição $p$
$P\mu$	Sentença proposicional
QUPC	Quadrado Unitário no Plano Cartesiano
$Gc$	Grau de Certeza
$Gct$	Grau de Contradição
p	Proposição Inicial
$V_{icc}$	Valor limite inferior de Controle de certeza
$V_{ici}$	Valor limite inferior de Controle de incerteza
S1	Saída discreta
S2a	Saída analógica
S2b	Saída analógica
$G_{cmáxV}$	Valor máximo para um estado lógico de Verdade
$G_{cmáxF}$	Valor máximo para um estado lógico de Falsidade
$\varphi$	Intervalo de certeza
$\varphi_{(\pm)}$	Intervalo de Certeza sinalizado
$\varphi_E$	Intervalo De Evidência Resultante
$\varphi_{E(\pm)}$	Intervalo De Evidência Resultante Sinalizado

## SUMÁRIO

1. INTRODUÇÃO.....	13
1.1. OBJETIVOS.....	15
1.1.1. OBJETIVOS GERAIS.....	15
1.1.2. OBJETIVOS ESPECÍFICOS.....	15
1.2. JUSTIFICATIVA.....	15
1.3. RELEVÂNCIA DO TEMA.....	16
1.4. ORGANIZAÇÃO DA DISSERTAÇÃO.....	17
2. CONTROLE ESTATÍSTICO DE PROCESSO.....	18
2.1. GRÁFICOS DE CONTROLE PARA VARIÁVEIS.....	20
2.2. PADRÕES NÃO ALEATÓRIOS EM GRÁFICOS DE CONTROLE.....	23
2.2.1. GRÁFICOS DE CONTROLE DE CUSUM.....	26
2.2.2. GRÁFICO DE CONTROLE DA MÉDIA MÓVEL EXPONENCIALMENTE PONDERADA.....	28
2.2.3. RECONHECIMENTO DE PADRÕES.....	30
3. REDE NEURAL ARTIFICIAL PARACONSISTENTE.....	32
3.1. LÓGICAS NÃO CLÁSSICAS.....	32
3.1.1. LÓGICA NÃO CLÁSSICA E REDES NEURAIS ARTIFICIAIS.....	32
3.2. LÓGICA PARACONSISTENTE - LP.....	33
3.2.1. A LÓGICA PARACONSISTENTE ANOTADA - LPA.....	33
3.2.2. LÓGICA PARACONSISTENTE ANOTADA COM ANOTAÇÃO DE DOIS VALORES - LPA2V.....	34
3.3. CÉLULAS NEURAIS ARTIFICIAIS PARACONSISTENTES.....	36
3.3.1. CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE DE APRENDIZAGEM - CNAPAP.....	37
3.3.2. CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE ANALÍTICA - CNAPA.....	39
3.3.3. CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE DE DETECÇÃO DE IGUALDADE - CNAPDI.....	40
3.3.4. UNIDADE NEURAL ARTIFICIAL PARACONSISTENTE - UNAP.....	42
4. CONTROLADOR PARACONSISTENTE ESTATÍSTICO DE PROCESSOS – CEP-LPA.....	43
4.1. MÓDULO EXTRATOR DE EVIDÊNCIA.....	44
4.2. UNIDADE NEURAL ARTIFICIAL PARACONSISTENTE DE EXTRAÇÃO DE MÉDIA MÓVEL – UNAPEMM.....	47
4.3. O MÓDULO DE MÉDIA.....	54
4.4. O MÓDULO DE DISPERSÃO.....	54
4.5. MÓDULO DE DETECÇÃO.....	55
5. SIMULAÇÕES.....	57
5.1. GERAÇÃO DOS PADRÕES.....	57
5.2. GERAÇÃO DOS PADRÕES MODIFICADOS.....	59
5.3. CONFIGURAÇÃO DO CEP-LPA.....	61
6. RESULTADOS E DISCUSSÕES.....	62
6.1. DISCUSSÕES – ASPECTOS GERAIS DAS SIMULAÇÕES.....	70
7. CONCLUSÕES.....	72
7.1. TRABALHOS FUTUROS.....	73
REFERÊNCIAS BIBLIOGRÁFICAS.....	74

## 1. INTRODUÇÃO

Em âmbito empresarial existe no cenário atual uma alta competitividade entre as empresas, condição esta que foi gerada com a abertura do mercado e técnicas avançadas de produção.

O aumento da competitividade no setor produtivo traz como efeito a exigência cada vez maior das empresas ofertarem produtos e serviços de alta qualidade aos seus clientes. Frente a essa situação, não se tem outro caminho a não ser a busca contínua da melhoria da qualidade.

A gestão da qualidade com suas ferramentas tem papel fundamental no processo de manutenção e melhoria da qualidade, sendo que a melhoria da qualidade normalmente está diretamente ligada à elevação das qualificações dos produtos e serviços ofertados.

Para enfrentar com sucesso tal desafio, as equipes responsáveis pelo desenvolvimento e produção têm que estar sempre inovando em seus produtos e processos produtivos. Por outro lado, essa condição de alta competitividade levou a necessidade de estudos científicos mais aprofundados que tratassem sobre a análise e o controle de processos, objetivando que tomadas de decisão fossem mais direcionadas, contribuindo, desta forma, para o aumento da eficiência e oferecendo qualidade à produção. Com isso, reconhecendo a importância crucial da gestão da qualidade, as pesquisas procuram aprimorar modelos de gestão com base nos padrões que melhor se adequem à oferta de serviços ou ao processo de produção.

O Controle Estatístico de Processo (CEP) é formado por um conjunto de técnicas que visa ao controle e melhoria da qualidade (MONTGOMERY, 2012). Dentre as técnicas do CEP, os gráficos de Shewhart são ferramentas consagradas de gestão de qualidade.

Os gráficos de Shewhart têm o objetivo fornecer informações sobre a variabilidade do processo através de análises estatísticas das variáveis que refletem a condição de qualidade do mesmo. Por meio dessas análises, os gráficos de Shewhart indicam quando o processo passou para uma condição de qualidade insatisfatória, porém, outros gráficos de controle como o da Soma Cumulativa (CUSUM) e a Média Móvel Exponencialmente Ponderada (EWMA) apresentaram

aprimoramentos no controle da variabilidade do processo, principalmente no que tange à detecção de pequenos desvios nas variáveis (MONTGOMERY, 2012) (COSTA, EPPRECHT, CARPINETTI, 2012).

Com o objetivo de melhorar a gestão da qualidade com base no controle da variabilidade do processo, surgiram, ao longo dos anos, novas formas de analisar a condição de qualidade do processo, sendo uma delas ancorada no reconhecimento de padrões da forma dos gráficos ou das informações das variáveis do processo.

O reconhecimento de padrão abrange vários problemas práticos, tais como: reconhecimento de fala, reconhecimento de caracteres, detecção de falhas em máquinas e diagnóstico médico (BISHOP, 1995).

As primeiras técnicas de reconhecimento de padrão foram baseadas em análises estatísticas e probabilística (BISHOP, 1995), porém, recentemente, as Redes Neurais Artificiais (RNAs) que são técnicas de Inteligência Artificial (IA) e têm seus fundamentos na maneira pela qual o cérebro faz o tratamento de informações, estão em desenvolvimento e obtendo bons resultados.

Alguns pesquisadores aplicaram técnicas de RNA nos gráficos de controle, tendo como principal objetivo reconhecer padrões de comportamento não aleatórios, que indicariam a possível perda da qualidade do processo. Na maioria dos casos, eles se orientaram nos padrões não aleatórios listados em Western Electric (1956).

Uma aplicação das RNA em Controle Estatístico de Processo que obteve bons resultados pode ser vista em Balestrassi (2000).

Novas pesquisas e aplicações de RNA surgem a cada dia, assim como as realizadas por Da Silva Filho e Abe (2001), que apresentaram algoritmos de uma nova classe de RNA, chamada Rede Neural Artificial Paraconsistente (RNAP).

A Rede Neural Artificial Paraconsistente (RNAP) tem como base a Lógica Paraconsistente Anotada (LPA), que, por sua vez, tem origem na Lógica Paraconsistente (LP), que apresenta em sua fundamentação a propriedade de aceitar a contradição sem que conflitos anulem as conclusões (DA SILVA FILHO, ABE, 2001).

Com a LPA podemos construir algoritmos especiais para processar sinais de informação nos quais as inconsistências nos sinais de informação podem ser suportadas e, portanto, será uma boa alternativa para técnicas inovadoras agregando valor ao Controle Estatístico de Processo e à gestão da qualidade.

## **1.1. OBJETIVOS**

### **1.1.1. OBJETIVOS GERAIS**

Esta pesquisa apresenta, como objetivo principal, encontrar novas formas de efetuar o Controle Estatístico de Processo aplicando algoritmos estruturados em Lógica Paraconsistente Anotada.

### **1.1.2. OBJETIVOS ESPECÍFICOS**

Como objetivos específicos consideramos encontrar novas formas de detalhar o comportamento de uma Rede Neural Artificial Paraconsistente (RNAP) funcionando como ferramenta computacional no Controle Estatístico de Processo, aplicada no apoio à gestão da qualidade.

## **1.2. JUSTIFICATIVA**

“A qualidade tornou-se um dos mais importantes fatores de decisão dos consumidores na seleção de produtos e serviços que competem entre si.” (MONTGOMERY, 2012, p.1). Ainda segundo Montgomery (2012), a qualidade é inversamente proporcional à variabilidade, logo, manter a qualidade é não permitir o aumento da variabilidade. Logo, melhorar a qualidade está diretamente relacionada à redução da variabilidade dos processos.

Desde a publicação de *Quality Control* em 1926 por Walter Andrew Shewhart, os gráficos de controle de média e amplitude são utilizados frequentemente no Controle Estatístico de Processo (SHEWHART, 1926). Apesar de serem fortemente aplicados, estes gráficos podem não ser suficientemente sensíveis para detectar pequenas variações, na ordem de  $1,5\sigma$  ou menos, isto porque não levam em consideração os valores historicamente obtidos, ignorando as informações dadas pela sequência de pontos (MONTGOMERY, 2012). Esta é uma condição importante para motivar novas pesquisas, pois as detecções de pequenos desvios podem levar à correção de problemas antes mesmo que eles afetem a qualidade do produto ou perda da produção.

Para melhorar a eficiência da gestão da qualidade a partir do Controle Estatístico de Processo, neste trabalho foram desenvolvidas formas de realizar o Controle Estatístico de Processo aplicando as Redes Neurais Artificiais Paraconsistentes (RNAPs), que são estruturas computacionais compostas por Células, as quais consistem em algoritmos construídos nos fundamentos da Lógica Paraconsistente Anotada (LPA).

A principal estrutura computacional foi desenvolvida por meio de um arranjo lógico que interliga um tipo de algoritmo especial denominado Célula Neural Artificial Paraconsistente de aprendizagem (CNAPap) e, em conjunto com outras Células, formaram um arranjo lógico computacional batizado de Controlador Paraconsistente Estatístico de Processos – CEP-LPA, que demonstrou a capacidade de realizar, de maneira eficiente, o Controle Estatístico de Processo mesmo na presença de dados incertos.

### **1.3. RELEVÂNCIA DO TEMA**

Desde o início da revolução industrial, a gestão da qualidade tornou-se extremamente importante, pois colabora de maneira significativa para a manutenção da competitividade e à saúde financeira das empresas.

Uma boa gestão da qualidade passa por efetivos processos de análise que dependem de conhecimento dos fatores que produzem a variabilidade em seus processos. É através dos monitoramentos destes, que se pode, então, reduzir os índices de variação, logo, influenciando positivamente os índices de qualidade.

A estatística utilizada no CEP é, sem dúvida, uma ferramenta de trabalho poderosa; no entanto, há premente necessidade de tornar este controle mais eficiente, tanto na análise, como na extração do conhecimento.

Essa eficiência somente será conseguida com inovação nas técnicas aplicadas nas análises dos dados de controle e sistematização desses dados de modo a facilitar a análise. Considerando que para isto acontecer, são necessários novos algoritmos. Assim, esta pesquisa sobre aplicação da Lógica Paraconsistente se mostra com alto grau de relevância, pois serão investigadas novas formas de tratamento de dados e análises para o apoio à gestão de qualidade.

Como a Lógica Paraconsistente tem em sua estrutura teórica propriedades que não podem ser abrigadas pela lógica clássica, tudo indica que os algoritmos Paraconsistente compondo um CEP poderão apresentar melhores resultados.

#### **1.4. ORGANIZAÇÃO DA DISSERTAÇÃO**

Esta dissertação está organizada da seguinte forma:

No Capítulo 1 foram introduzidos, de forma geral, os principais conceitos relacionados a este estudo, como informações preliminares sobre as relevâncias do Controle Estatístico de Processo e das Redes Neurais Artificiais Paraconsistentes, além dos objetivos pretendidos na pesquisa.

O Capítulo 2 faz uma descrição pormenorizada do Controle Estatístico de Processo, com suas principais abordagens na gestão da qualidade.

O Capítulo 3 apresenta as informações relevantes sobre a Lógica Paraconsistente e os algoritmos das Células Neurais Artificiais Paraconsistentes utilizadas neste trabalho.

No Capítulo 4 é apresentado o Controlador Paraconsistente Estatístico de Processos - CEP-LPA, objeto principal deste trabalho.

O Capítulo 5 apresenta os dados para as simulações.

No Capítulo 6 encontramos as discussões e os resultados obtidos nas simulações.

E, por fim, no Capítulo 7 estão descritas as conclusões e as sugestões de trabalhos futuros.

## 2. CONTROLE ESTATÍSTICO DE PROCESSO

O Controle Estatístico de Processo (CEP) é um conjunto de ferramentas do controle da qualidade que tem como base a análise estatística de variáveis determinantes para definir a qualidade de um produto ou serviço (MONTGOMERY, 2012). As ferramentas do CEP ajudam a identificar, classificar, priorizar e até antever problemas de qualidade. Uma abordagem geral sobre as ferramentas pode ser consultada em Montgomery (2012).

O controle da variabilidade das características de produtos ou serviços é de suma importância, pois afeta diretamente a percepção de qualidade do cliente e em casos extremos, a fabricação de produtos fora da especificação, podem levar a danos materiais e pessoais.

A fabricação de um produto ou fornecimento de um serviço depende de um conjunto ordenado de ações, pessoas, máquinas e matérias-primas formando um grande processo de produção.

Segundo Campos (1992, p.19), uma empresa é um grande processo divisível em processos menores, permitindo o controle do todo através de controle sobre cada subprocesso, os indicadores de cada processo são índices numéricos que refletem a qualidade de cada processo.

As empresas desejam manter a variabilidade de seus processos dentro de limites que garantam que seus produtos e serviços estejam dentro das especificações. Quando economicamente viável, elas buscam alterar seus processos para alcançar outros patamares de qualidade, dando a elas condições diferenciadas no mercado, porém, isto acaba exigindo controles mais rígidos sobre os parâmetros de qualidade.

“Em qualquer processo de produção, independentemente de quão bem planejado ou cuidadosamente mantido ele seja, certa quantidade de variabilidade inerente ou natural sempre existirá” (MONTGOMERY, 2012, p. 96).

Os Gráficos de controle são uma das mais importantes ferramentas do CEP, pois atuam no controle da variabilidade das características de qualidade. Eles são baseados na distribuição estatística das variáveis de um processo.

Os Gráficos de controle foram primeiramente desenvolvidos pelo Dr. Walter A. Shewhart, do *Bell Telephone Laboratories*, nos anos 20. Ele denominou a

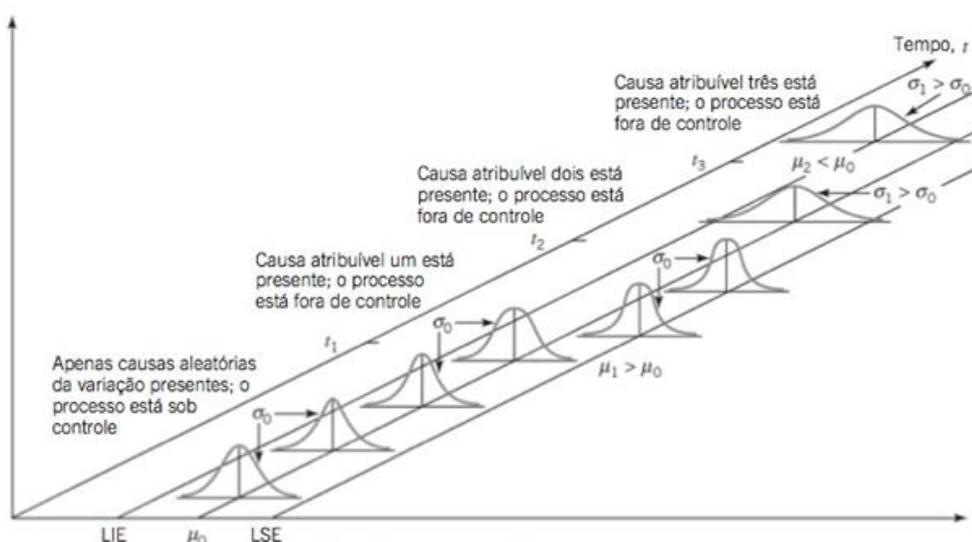
variabilidade inerente ou natural de um processo como causas aleatórias, hoje chamada por outros autores de causas comuns. Ele também determinou que quaisquer causas não aleatórias são denominadas como causas atribuíveis, também chamadas de causas especiais, em publicações recentes de outros autores (SHEWHART, 1926) (MONTGOMERY, 2012) (COSTA, EPPRECHT, CARPINETTI, 2012).

As causas atribuíveis ou especiais são totalmente indesejáveis e podem ocorrer por falha em equipamento, má qualidade da matéria-prima, erro operacional, equipamentos mal ajustados entre outros fatores.

Segundo os estudos de Shewhart (1926), quando um processo possui somente causas aleatórias é dito como sob controle estatístico. Nesta condição, suas características de qualidade representadas por variáveis aleatórias possuem distribuição normal com média sendo o valor de tendência central e o desvio padrão indicando a dispersão da variável em torno da média.

Com base em técnicas estatísticas de análise de dispersão da variável aleatória, é possível determinar, com certo grau de confiança, limites superior e inferior no qual a variável aleatória pode apresentar valores. Dentro destes limites o processo é considerado sob controle estatístico.

A ocorrência de causas especiais ou atribuíveis altera a distribuição normal em sua média e/ou desvio padrão. Essas alterações podem ultrapassar os limites inferior e superior determinados quando o processo estava sob controle estatístico. Um exemplo gráfico da teoria de Shewhart pode ser visto na Figura 1.



**Figura 1 - Causas atribuíveis e aleatórias da variabilidade**  
 Fonte: (MONTGOMERY, 2012).

## 2.1. GRÁFICOS DE CONTROLE PARA VARIÁVEIS

Os gráficos de controle para variáveis utilizam os fundamentos de Shewhart e são aplicados quando as características de qualidade do processo podem ser expressas de maneira numérica, podendo, assim, serem tratadas estatisticamente como variáveis aleatórias de qualidade (MONTGOMERY, 2012) (COSTA, EPPRECHT, CARPINETTI, 2012).

As variáveis aleatórias de qualidade possuem as mesmas características de uma variável aleatória, como tendência central e dispersão, e com base nesta evidência, foram criados os principais gráficos de controle.

O gráfico de controle  $\bar{x}$ , também chamado de gráfico de controle de média, é utilizado para controle da tendência central do processo, onde a média amostral de  $n$  amostras é calculada em intervalos de tempo, e seu resultado é plotado graficamente. A média amostral deve variar em torno da média populacional representada por uma linha central (LC) e seus valores devem estar contidos dentro dos limites inferior de controle (LIC) e superior de controle (LSC). Valores fora desses limites indicam que o processo não está mais sob controle estatístico, evidenciando a presença de causas especiais que devem ser investigadas (MONTGOMERY, 2012) (COSTA, EPPRECHT, CARPINETTI, 2012).

Para determinação dos limites de controle é necessário conhecermos a média ( $\mu$ ) e o desvio padrão ( $\sigma$ ) do processo, quando está sob controle estatístico. Na prática, esses valores não são conhecidos com precisão absoluta; por isso, utiliza-se uma estimativa criada com amostras do próprio processo, onde se tem praticamente a certeza de que não existem causas especiais (COSTA, EPPRECHT, CARPINETTI, 2012).

Os limites do gráfico de controle  $\bar{x}$  são calculados com base no desvio padrão da média amostral, conforme seguem:

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Sendo:

$\sigma_{\bar{x}}$  é o desvio padrão da média do processo;

$\sigma$  é o desvio padrão do processo;

$n$  é o número de amostras.

O limite superior de controle é obtido adicionando a média  $\mu$  o valor de 3 desvios-padrão da média amostral,

$$LSC = \mu + 3\sigma_{\bar{x}}$$

O limite inferior é obtido subtraindo a média  $\mu$  o valor de 3 desvios-padrão da média amostral,

$$LIC = \mu - 3\sigma_{\bar{x}}$$

E a linha central representa a média,

$$\text{Linha central} = \mu$$

O valor de  $\pm 3\sigma$  tem relação direta com o teste de hipótese do valor da média amostral ser aceito como igual à média do processo, tendo as seguintes hipóteses:

$$H_0: \mu = \bar{x}, \text{ hipótese nula}$$

$$H_1: \mu \neq \bar{x}, \text{ hipótese alternativa}$$

Utilizando  $\pm 3\sigma$  se estabelece a confiança de 99,73% de que a média do processo está dentro dos limites de controle. Dessa forma, uma amostra da média do processo que esteja dentro do intervalo de controle atende à hipótese nula, que afirma que o processo está sob controle estatístico, e uma amostra fora dos limites representa a hipótese alternativa, que indica a presença de causas especiais (RIBEIRO, C CATEN, 2012)

O método inferencial de controle da média, acima descrito, pode levar a uma avaliação errada se o processo está ou não sob controle estatístico.

Existe a probabilidade 0,27% de uma amostra da média situada próxima dos limites de controle ser interpretada erroneamente. A amostra pode estar fora dos limites de controle, mas o processo está sob controle, indicando erro tipo I ou a amostra está dentro dos limites, mas o processo possui causas especiais, indicando erro tipo II (RIBEIRO, C CATEN, 2012).

O erro tipo I pode levar à decisão errada de parada da produção para investigar causas especiais, sendo que elas não existem, causando queda na produtividade. Já a não detecção de causas especiais no erro tipo II pode levar à produção de itens fora dos limites de especificação, causando sérios problemas de qualidade.

Como foi exposto, em aplicações usuais, no controle de tendência central do processo é utilizado o gráfico  $\bar{x}$ , já para o controle de dispersão é utilizado o gráfico de controle de amplitude, também chamado de gráfico  $R$ .

No gráfico  $R$  é calculada a média das amplitudes das amostras e plotada em um gráfico que contém uma linha central que representa a amplitude média, e os limites inferior e superior, em que a média das amplitudes não pode exceder.

A linha central representa a média das amplitudes da amostra,

$$\text{Linha central} = \bar{R}$$

O limite superior de controle é obtido multiplicando a média das amplitudes das amostras por um estimador que depende da quantidade de amostra,

$$LSC = D_4 \bar{R}$$

Da mesma forma, o limite inferior de controle é obtido multiplicando a média das amplitudes das amostras por um estimador que depende da quantidade de amostra,

$$LIC = D_3 \bar{R}$$

Os estimadores  $D_3$  e  $D_4$  são tabelados e dependem da quantidade de amostra (MONTGOMERY, 2012, p. 131).

Para ilustrar o uso dos gráficos de controle  $\bar{x}$  e  $R$  são apresentados na Figura 2 uma variável aleatória que representa a dimensão longitudinal em milímetros de uma peça, que tem sua média igual a 500 mm e desvio padrão igual a 1 mm, sendo que a cada amostragem foram selecionadas 5 peças e realizadas 60 amostras ao longo do tempo.

A média da dimensão longitudinal é calculada e plotada no gráfico  $\bar{x}$ . Verificamos a média das amplitudes no gráfico  $R$ . Ambas apresentaram valores dentro dos limites de controle, indicando que o processo está sob controle estatístico, ou seja, na condição do exemplo é improvável ter ocorrido alguma causa especial que alterou a média ou a dispersão do processo de fabricação.

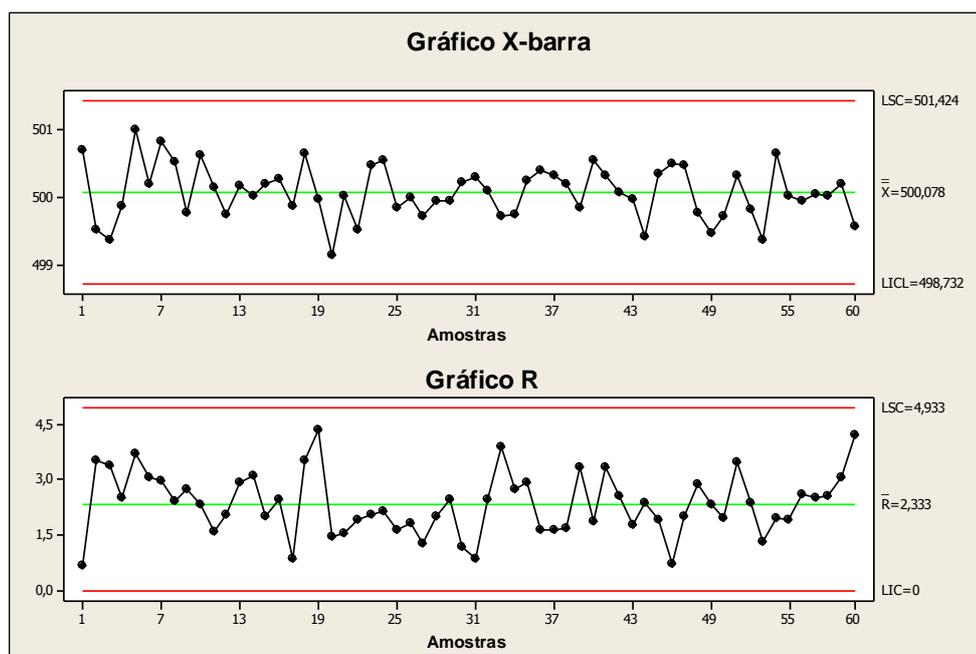


Figura 2 – Exemplos de gráficos  $\bar{x}$  e  $R$ .

Com base nos fundamentos apresentados até o momento, a variável aleatória se encontra sob controle estatístico, pois seus valores amostrais se apresentaram dentro dos limites de controle em sua média e em sua dispersão. Porém, a tomada de decisão sob a condição do processo, somente com base nos limites de controle, pode não ser suficiente para indicar sua aleatoriedade, fator fundamental de um processo sob controle estatístico.

Para melhorar o desempenho dos gráficos de controle foram criadas técnicas complementares como: avaliação do comportamento dos pontos ao longo do tempo, gráficos avançados e reconhecimento de padrões.

## 2.2. PADRÕES NÃO ALEATÓRIOS EM GRÁFICOS DE CONTROLE

A sequência que as amostras se apresentam pode indicar perda da aleatoriedade do processo, mesmo quando as amostras plotadas estão dentro dos

limites de controle. Na obra *Statistical Quality Control Handbook da Western Electric* (1956) são listados um conjunto de 15 padrões não aleatórios. Estes padrões possuem características em seus pontos que indicam um viés determinístico, logo, não estatístico; um sinal forte de que o processo possui causas especiais.

Segundo Balestrassi (2000), dentre os 15 padrões não aleatórios os 6 mais comuns são: Desvio de Média, Tendência, Variações Sistemáticas, Ciclos, Misturas e Estratificação. Balestrassi (2000) utilizou técnicas de Redes Neurais Artificiais (RNA) para identificação dos 6 padrões em gráficos de controle.

Uma técnica mais simples foi sugerida pela Western Electric (1956). Foi proposto um conjunto de regras para detecção baseado em zonas determinadas por conceitos estatísticos. Estas regras são capazes de detectar que o processo não está sob controle estatístico mesmo com seus pontos dentro dos limites de controle (MONTGOMERY, 2012).

Na Figura 3 apresentamos o conjunto de regras por zona sugerida pela Western Electric (1956). As regras são aplicadas de maneira independente acima e abaixo da linha central (LC) e as zonas são divididas em saltos de desvio padrão.

3 $\sigma$	<b>A</b>	2 pontos em 3 pontos consecutivos na região A ou acima
2 $\sigma$	<b>B</b>	4 pontos em 5 pontos consecutivos na região B ou acima
1 $\sigma$	<b>C</b>	8 pontos consecutivos na região C ou abaixo
LC	<b>C</b>	8 pontos consecutivos na região C ou acima
-1 $\sigma$	<b>B</b>	4 pontos em 5 pontos consecutivos na região B ou abaixo
-2 $\sigma$	<b>A</b>	2 pontos em 3 pontos consecutivos na região A ou abaixo
-3 $\sigma$		

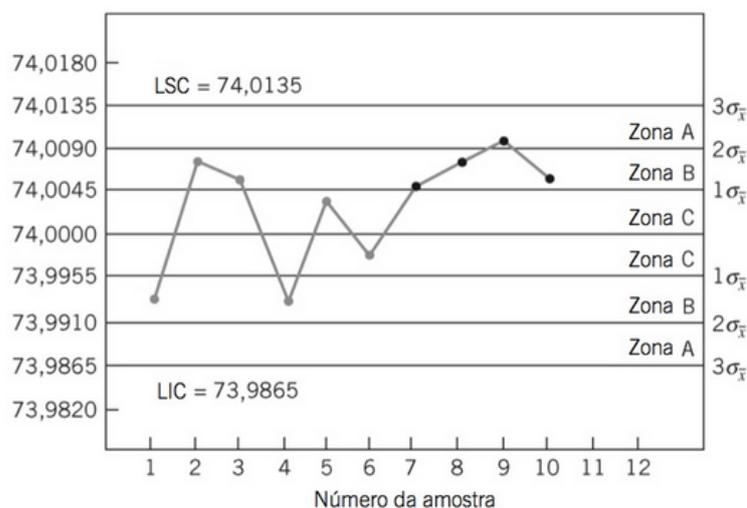
**Figura 3 – Regras de Western Electric.**  
**Fonte: WESTERN ELECTRIC (1956).**

Outros pesquisadores como Nelson (1985) e Grant e Leavenworth (1988), citados por Balestrassi (2000), apresentaram regras complementares com o objetivo de facilitar ainda mais a detecção de padrões não aleatórios. Porém, a

implementação de várias regras pode tornar a interpretação do gráfico complexa e também levar ao erro tipo II, em que o processo é dito com causas especiais, porém, elas não existem (MONTGOMERY, 2012) (COSTA, EPPRECHT, CARPINETTI, 2012).

Um exemplo da aplicação das regras da *Western Electric* está em Montgomery (2012, p. 108), onde, em um gráfico de controle  $\bar{x}$ , são plotados o conjunto de 10 amostras da média de um processo e aplicando a regra “4 pontos em 5 consecutivos na região B ou acima”, a partir da sexta amostra, como pode ser visto na Figura 4.

Verificamos que o ponto frágil da técnica de regras suplementares é que não é capaz de identificar o tipo de padrão do gráfico, mas somente de detectar que ele se tornou não aleatório.



**Figura 4 – Exemplo de regra por zonas.**  
**Fonte: MONTGOMERY (2012).**

Os padrões não aleatórios, ainda que dentro dos limites de controle, causam alterações na média e ou variância do processo. Com base nessa constatação outras técnicas estatísticas foram criadas com objetivo de detectar pequenos desvios, entre elas a CUSUM e a EWMA. Uma breve explanação sobre estas técnicas é dada a seguir.

### 2.2.1. GRÁFICOS DE CONTROLE DE CUSUM

O gráfico de controle de Soma Cumulativa (CUSUM, *Cumulative Sum*) é uma alternativa para detecção de pequenos desvios de média, ou no caso de medidas individuais (amostra de tamanho  $n=1$ ), pequenos desvios com relação ao valor alvo.

A proposta inicial do CUSUM foi formulada por E.S. Page em 1954, na Inglaterra (ALVES, 2003).

O método CUSUM baseia-se no fato de que a somatória dos desvios com relação à média ou ao valor alvo fará os valores plotados excursionar em torno da média, quando não houver desvio da média do processo. No entanto, se valores acima ou abaixo da média tornam-se preponderantes, o gráfico apresentará um desvio de magnitude suficiente para constatação de que a média foi deslocada (ALVES, 2003).

O CUSUM Tubular é o tipo mais comum dos algoritmos CUSUM (ALVES, 2003) nele os desvios positivos com relação ao valor alvo são indicados pela estatística  $C^+$  e os valores negativos são indicados pela estatística  $C^-$ , conforme abaixo:

$$C_i^+ = \max[0, x_i - (\mu_0 + K) + C_{i-1}^+]$$

$$C_i^- = \max[0, (\mu_0 - K) - x_i + C_{i-1}^-]$$

O valor  $K$ , chamado de tolerância, é calculado pela expressão

$$K = \frac{|\mu_1 - \mu_0|}{2}$$

onde,  $\mu_1$  é o valor do desvio de média que se deseja detectar.

Nas estatísticas  $C^+$  e  $C^-$  a função *max* leva o resultado a zero sempre que a função interna apresenta valor negativo.

No gráfico CUSUM Tubular os limites de controle são representados por um intervalo de decisão  $H$ , segundo Montgomery (2012), um valor razoável para  $H = 5\sigma$ .

Estudos completos do CUSUM Tubular e de outra técnica de CUSUM, chamada Máscara V, são apresentados por Alves (2003).

Para exemplificar a comparação entre o gráfico de Shewhart e CUSUM Tubular, temos nas figuras 5 e 6, respectivamente, o gráfico de Shewhart e CUSUM Tubular. Ambos têm seus pontos calculados a partir do mesmo conjunto de dados, que tem média igual a 10 e desvio padrão igual a 1 até a vigésima amostra. Da vigésima primeira até a trigésima, a média é igual 11 e o desvio padrão se mantém igual a 1.

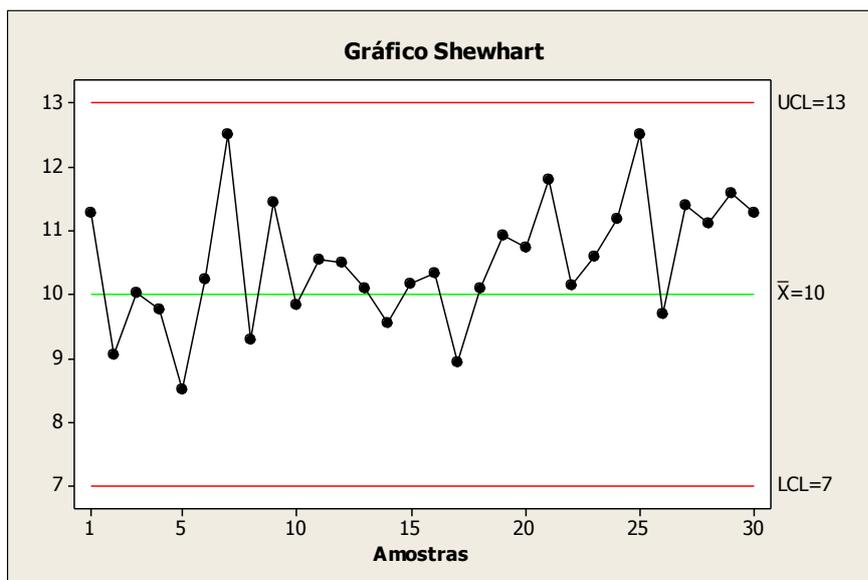


Figura 5 – Gráfico de controle de Shewhart.

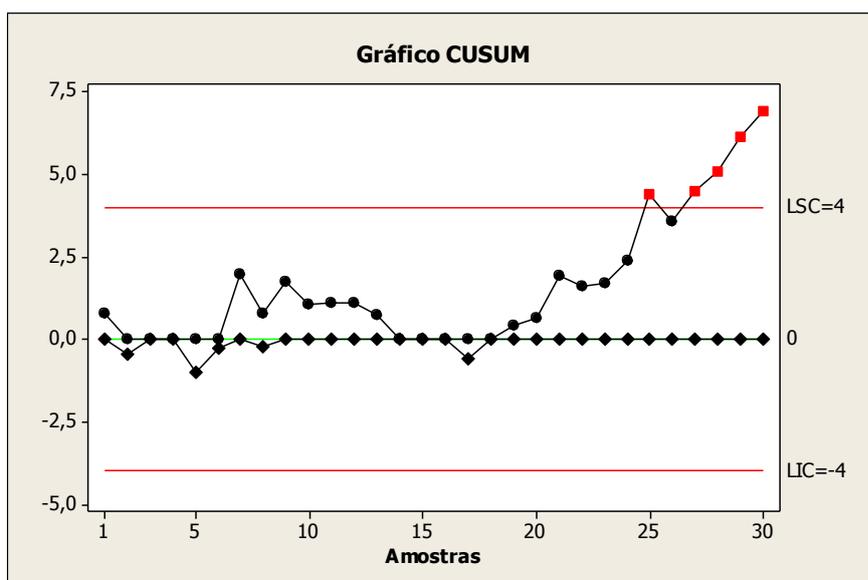


Figura 6 – Gráfico de controle CUSUM.

Verificamos que no gráfico de Shewhart, na Figura 5, a variação da média de 10 para 11, a partir da vigésima primeira amostra, não foi detectada. Já no gráfico

CUSUM Tubular da Figura 6, foi ultrapassado o limite de controle a partir da vigésima quinta amostra, indicando que o processo possui causas especiais.

Este exemplo demonstra que o gráfico CUSUM é sensível a pequenos desvios, que não são detectados pelo gráfico de controle de Shewhart.

O gráfico CUSUM tem bom desempenho para detectar pequenos desvios de média, mas é lento para grandes desvios. Em virtude desse fato, alguns pesquisadores estão utilizando a combinação de várias técnicas, como no caso do trabalho de Henning, Fernandes, Konrath (2013), que utilizaram a combinação de Shewhart – CUSUM no Controle Estatístico de Processo de um bloco usinado.

### 2.2.2. GRÁFICO DE CONTROLE DA MÉDIA MÓVEL EXPONENCIALMENTE PONDERADA

O gráfico de controle de média móvel exponencialmente ponderada (EWMA, *Exponentially Weighted Moving Average*) foi proposto por Robert (1959) e apresenta bom desempenho na detecção de pequenas variações. Ele pode ser usado tanto para medidas individuais quanto para controle de média, através de subgrupos racionais (MONTGOMERY, 2012) MENDES (2004).

Segundo descrição da EWMA por Mendes (2004, p.49), a EWMA consiste na média ponderada exponencialmente das observações: os pesos decaem de acordo com a idade das observações, em progressão geométrica, cujo fator é determinado pela constante de amortecimento  $\lambda$ .

Os valores plotados no gráfico de controle EWMA são definidos por:

$$z_i = \lambda x_i + (1 - \lambda)z_{i-1}$$

onde  $0 < \lambda \leq 1$  e  $i$  representa a ordem da observação. Normalmente, o valor inicial  $z_0 = \mu_0$  (valor alvo ou médio).

Os limites de controle do gráfico EWMA são dados por:

$$LSC = \mu_0 + L\sigma \sqrt{\frac{\lambda}{\lambda - 2} [1 - (1 - \lambda)^{2i}]}$$

$$LC = \mu_0$$

$$LIC = \mu_0 - L\sigma \sqrt{\frac{\lambda}{\lambda - 2} [1 - (1 - \lambda)^{2i}]}$$

onde  $\mu_0$  é o valor médio ou alvo, L é o coeficiente de abertura do gráfico e  $\lambda$  determina o peso das observações.

No gráfico EWMA os limites de controle não são fixos, ele tende a se estabilizar após algumas amostras.

O gráfico de controle de EWMA da Figura 7, foi construído com os mesmos dados dos gráficos das Figura 5 e 6, e possui parâmetros  $\lambda = 0,2$  e  $K=1$ .

Comparando os gráficos EWMA e CUSUM vemos que possuem desempenho semelhante; porém o algoritmo do EWMA é de implementação relativamente mais simples.

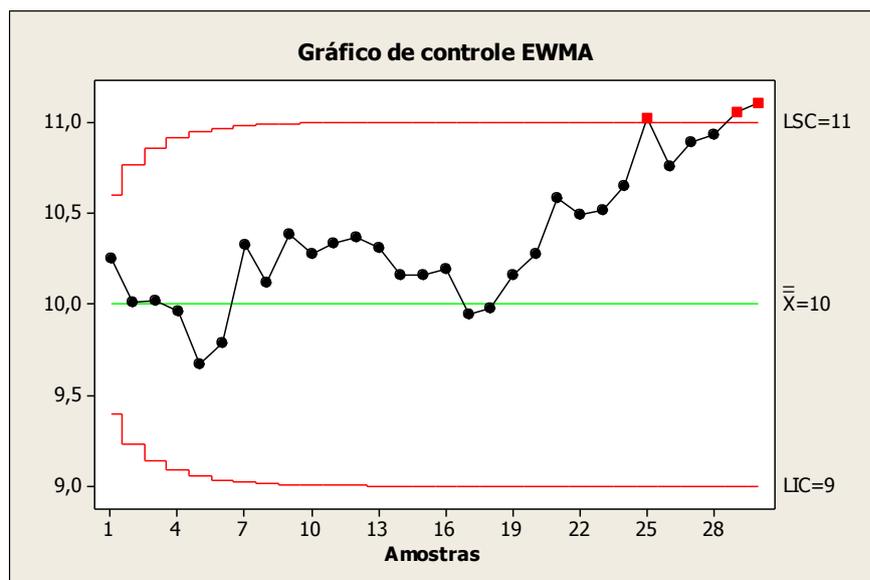


Figura 7 – Gráfico de controle EWMA.

Os gráficos CUSUM e EWMA são bons para pequenos desvios, mas pouco sensíveis para mudanças bruscas. Para contornar esse problema, indicamos o uso combinado com o gráfico de controle de Shewhart (MONTGOMERY, 2012) (HENNING, FERNANDES, KONRATH, 2013).

As técnicas estatísticas formam um conjunto eficiente na detecção de alterações de um processo, porém, podem ser aprimoradas por algoritmos de Inteligência Artificial (IA), principalmente com técnicas de Redes Neurais Artificiais em virtude de possuírem a capacidade de reconhecer padrões.

### 2.2.3. RECONHECIMENTO DE PADRÕES

O desenvolvimento da informática se tornou possível o uso de técnicas computacionais que tentam imitar o cérebro humano, chamadas de Redes Neurais Artificiais (RNAs). Elas normalmente, são empregadas em aplicações de reconhecimento de padrões (BISHOP, 1995). Isto motivou vários pesquisadores em aplicar tais técnicas em Controle Estatístico de Processo, principalmente, com o objetivo de reconhecer os padrões não aleatórios listados por Western Electric (1958).

Balestrassi (2000) aplicou um conjunto de técnicas de RNA em Controle Estatístico de Processo para reconhecer 6 padrões não aleatórios e obteve bons resultados.

No trabalho de Smith (1994) *apud* Faccio, Werner (2010), os resultados de uma Rede Neural Artificial por retropropagação do erro foram comparados aos gráficos de controle de média e amplitude, e observou-se que a RNA obteve desempenho semelhante para grandes desvios e superior para pequenos.

Shaban *et al.* (2010) propôs um algoritmo RNA capaz de identificar três padrões básicos de gráficos de controle: natural, desvio de média e tendência, e os comparou com pesquisas anteriores e obteve resultados superiores.

Faccio e Werner (2010) realizaram um comparativo entre um gráfico Soma Cumulativa (CUSUM) e uma RNA de Função de Base Radial (RBF) que comprovaram a eficácia da RNA frente à CUSUM.

As aplicações relacionadas às RNAs em CEP baseiam-se no fato de que um analista bem treinado, de posse dos gráficos de controle, é capaz de reconhecer mudanças e até vincular possíveis causas às alterações; porém, é passível de erros em suas avaliações. A RNA pode auxiliá-lo em suas decisões reduzindo os erros tipo I e II e diminuir o tempo de detecção das causas especiais.

Neste trabalho foi escolhida a Rede Neural Artificial Paraconsistente (RNAP), que tem seus fundamentos originados da Lógica Paraconsistente (LP), por ter demonstrado, em outras aplicações, a capacidade de trabalhar com o reconhecimento de padrão, estatística e probabilidade, além de dar tratamento para informações incertas, que, normalmente, estão presentes nestes tipos de aplicações.

Na revisão sobre a Rede Neural Artificial Paraconsistente não foi encontrada nenhuma aplicação da RNAP em Controle Estatístico de Processo; porém, outras aplicações importantes e correlacionadas a este trabalho estão listadas a seguir.

Souza (2013) criou uma RNAP de reconhecimento de caracteres numéricos manuscritos e Caracteres Magnéticos Codificados em 7 Barras utilizados em cheques bancários brasileiros. Esta RNAP apresentou 97,85% de acertos para Caracteres Magnéticos Codificados em 7 Barras e 91% de acertos para Caracteres Numéricos Manuscritos.

Lopes (2009) apresentou uma aplicação de RNAP como método de auxílio no diagnóstico da doença de Alzheimer, através do reconhecimento de padrões dos sinais de eletroencefalograma de pacientes. A RNAP apresentou concordância com o diagnóstico clínico de 82% de sensibilidade e 31% de especificidade.

Souza (2009) e Da Silva Filho (2008) com os trabalhos: “Métodos de apoio à decisão médica para análise em diabetes *mellitus* gestacional utilizando a probabilidade pragmática na Lógica Paraconsistente anotada; dois valores para melhor precisão de resposta” e “Lógica Paraconsistente e Probabilidade Pragmática no tratamento de incertezas”, respectivamente, combinaram o uso da probabilidade com a Lógica Paraconsistente.

Outros trabalhos aproximaram a estatística da Lógica Paraconsistente, como pode ser visto em Da Silva Filho *et al* (2012) “Estatística Descritiva Paraconsistente Aplicada ao Estudo de Poluição de Resíduos Sólidos em Ambiente Costeiro Marinho” e Damin e Da Silva Filho (2012) “Utilização da Distribuição de Frequência Estatística Associada à Lógica Paraconsistente Anotada de 2 valores: o Modelo de dois Peritos em Vistorias de Engenharia”.

Com isso, fica demonstrada que a Lógica Paraconsistente possui características que atendem aos três pilares do Controle Estatístico de Processo: a estatística, a probabilidade e o reconhecimento de padrões.

### **3. REDE NEURAL ARTIFICIAL PARACONSISTENTE**

Mesmo com o avanço tecnológico que estamos vivenciando atualmente, estudos têm demonstrado que, em algumas situações reais, o cérebro humano é capaz de realizar tarefas que os computadores modernos não conseguem realizar. Verificamos que estas situações ditas como reais geralmente são as que trazem um grande índice de incertezas devido às fontes de informação serem, por natureza, contraditórias ou ambíguas. Para estas situações de incertezas, a lógica clássica, por ser estruturada em fundamentos binários, não consegue aplicar um tratamento adequado aos dados que tragam conclusões capazes de responder de maneira satisfatória.

#### **3.1. LÓGICAS NÃO CLÁSSICAS**

No intuito de oferecer alternativas para tratamento eficiente em situações incertas, nas quais a lógica clássica não consegue bons resultados, foram criados outros tipos de lógicas que se fundamentam em leis que desafiam os conceitos binários da Lógica Clássica e, por isso, são denominadas de lógicas não clássicas. Entre estas se podemos destacar: as Lógicas Fuzzy, Lógicas Multivaloradas, Paraconsistentes, entre outras.

Recentemente, múltiplas teorias e técnicas de tratamento de sinais incertos estão sendo desenvolvidas em Inteligência Artificial aplicando lógicas não clássicas nas mais variadas áreas do conhecimento (ABE, 1992).

##### **3.1.1. LÓGICA NÃO CLÁSSICA E REDES NEURAIIS ARTIFICIAIS**

Na procura de novas Técnicas de Inteligência Artificiais que tentam modelar o comportamento do cérebro apareceram vários estudos relacionados às lógicas não clássicas. O objetivo principal é aumentar a eficiência das máquinas frente a estas situações reais que são retratadas por dados originários do Conhecimento Incerto.

Dentre as diversas técnicas de Inteligência Artificial, tem havido destaque a de estruturação de redes neurais artificiais, que se baseia na criação de unidades primárias chamadas de neurônios artificiais.

Em Da Silva Filho e Abe (2001) foi apresentado um modelo de Rede Neural Artificial que utiliza como estruturação de seus algoritmos, a Lógica Paraconsistente Anotada com anotação de dois valores (LPA2v).

Conforme pode ser visto em Da Silva Filho e Abe (2001) e Da Silva Filho, Abe e Lambert-Torres (2008), as Redes Neurais Artificiais Paraconsistentes (RNAPs) apresentam algumas características distintas das demais redes estudadas na literatura, principalmente porque a sua construção está assentada em ideias baseadas na Lógica Paraconsistente (LP), que possui como principal característica, aceitar contradição em seus fundamentos. Como as Redes Neurais Artificiais Paraconsistentes (RNAPs) serão utilizadas neste trabalho para desenvolver o Controlador Paraconsistente Estatístico de Processos – CEP-LPA, os seus algoritmos serão detalhados a seguir.

Para o entendimento dos algoritmos das RNAPs, primeiramente, serão apresentados os principais fundamentos da Lógica Paraconsistente com anotação de dois valores (LPA2v).

### **3.2. LÓGICA PARACONSISTENTE - LP**

A Lógica Paraconsistente (LP) é um tipo de lógica não clássica que apresenta em sua fundamentação a propriedade de aceitar a contradição sem trivialização, portanto, sem que o conflito ocasionado pela inconsistência anule as conclusões. (DA SILVA FILHO, ABE, 2001).

O histórico da Lógica Paraconsistente pode ser encontrado em Abe (2006).

#### **3.2.1. A LÓGICA PARACONSISTENTE ANOTADA - LPA**

As Lógicas Paraconsistentes Anotadas (LPA) são classes de Lógicas Paraconsistentes que possuem um reticulado associado e foram introduzidas pela primeira vez em programação lógica por Subrahmanian (SUBRAHMANIAN, 1987).

Com a LPA, fazendo interpretações em seu Reticulado associado, podemos construir algoritmos especiais para processar sinais de informação nos quais as inconsistências nos sinais de informação podem ser suportadas.

Os métodos de tratamento de incerteza aqui apresentados utilizam os fundamentos de uma extensão da Lógica Paraconsistente Anotada denominada de

Lógica Paraconsistente Anotada com anotação de dois valores (LPA2v) (DA SILVA FILHO, 1999).

### 3.2.2. LÓGICA PARACONSISTENTE ANOTADA COM ANOTAÇÃO DE DOIS VALORES - LPA2V

Na Lógica Paraconsistente Anotada (LPA) as fórmulas proposicionais vêm acompanhadas de anotações. Cada anotação, pertencente a um reticulado finito  $\tau$ , atribui valores à sua correspondente fórmula proposicional (DA SILVA FILHO, 1999).

Para obter um maior poder de representação sobre o quanto as anotações, ou evidências expressam o conhecimento sobre a proposição utilizando um reticulado formado por pares ordenados, tal que:

$$\tau = \{(\mu, \lambda) \mid \mu, \lambda \in [0,1] \subset \mathcal{R}\}$$

Neste caso, é fixado um operador  $\sim: |\tau| \rightarrow |\tau|$  onde;  $\sim$  constitui o “significado” do símbolo lógico de negação  $\neg$  do sistema que será considerado.

Se  $p$  é uma fórmula básica, o operador  $\sim: |\tau| \rightarrow |\tau|$  é definido como:

$$\sim[(\mu, \lambda)] = (\lambda, \mu)$$

onde,  $\mu, \lambda \in [0,1] \subset \mathcal{R}$

Considerando então:

$(\mu, \lambda)$ : Uma Anotação de  $P$ .

$P_{(\mu, \lambda)}$ : Sinal Lógico Paraconsistente em que os graus de Evidência favorável e desfavorável compõem uma Anotação que atribui uma conotação lógica à Proposição  $P$ .

Desse modo, a associação de uma anotação  $(\mu, \lambda)$  à uma proposição  $P$  significa que:

o *Grau de Evidência* favorável em  $P$  é  $\mu$ ;

o *Grau de Evidência* desfavorável, ou contrária, é  $\lambda$ .

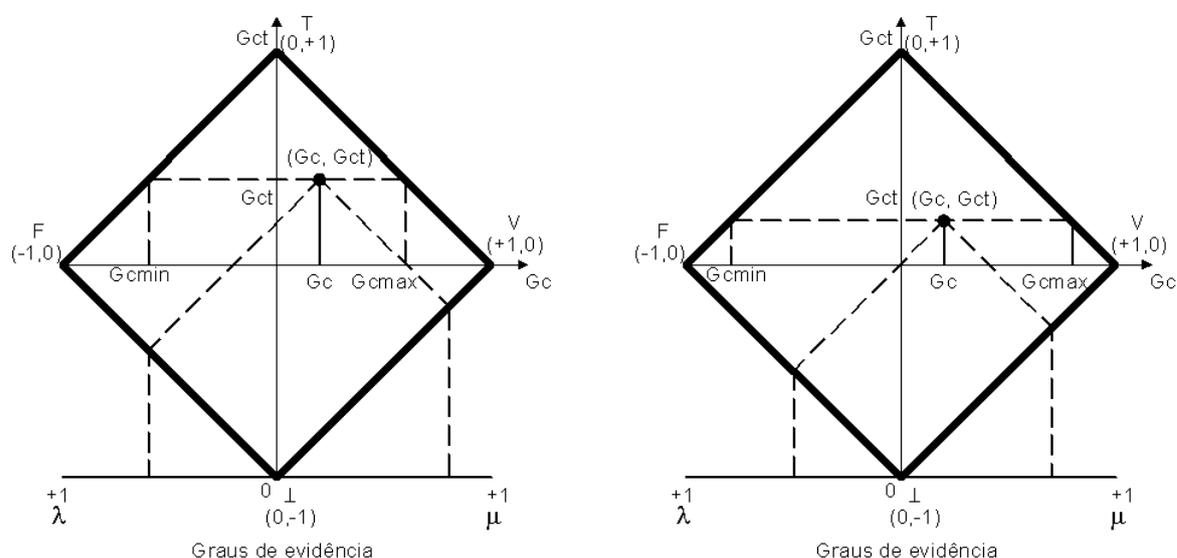
Intuitivamente, em tal reticulado temos (conforme Figura 8):

$P_{(\mu, \lambda)} = P_{(1, 0)}$ : indicando 'existência de evidência favorável total e evidência desfavorável nula', atribuindo uma conotação de *Verdade* à proposição;

$P_{(\mu, \lambda)} = P_{(0, 1)}$ : indicando 'existência de evidência favorável nula e evidência desfavorável total', atribuindo uma conotação de *Falsidade* à proposição;

$P_{(\mu, \lambda)} = P_{(1, 1)}$ : indicando 'existência de evidência favorável total e evidência desfavorável total' atribuindo uma conotação de *Inconsistência* à proposição;

$P_{(\mu, \lambda)} = P_{(0, 0)}$ : indicando 'existência de evidência favorável nula e evidência desfavorável nula', atribuindo uma conotação de *Indeterminação* à proposição.



**Figura 8 – Reticulado associado à Lógica Paraconsistente Anotada de anotação com dois valores LPA2v.**

**Fonte: DA SILVA FILHO, ABE, LAMBERT-TORRES (2008).**

Por meio de transformações lineares em um Quadrado Unitário no Plano cartesiano (QUPC) e o Reticulado representativo da LPA podemos chegar à transformação:  $T(X, Y) = (x-y, x+y-1)$ . Relacionando os componentes da transformação  $T(X, Y)$ , conforme a nomenclatura usual da LPA2v, vem que:

$$X = \mu \text{ Grau de Evidência favorável}$$

$$Y = \lambda \text{ Grau de Evidência desfavorável}$$

Do primeiro termo obtido no par ordenado da equação da transformação temos:

$$x - y = \mu - \lambda$$

A qual denominamos de Grau de certeza  $G_c$ . Portanto, o Grau de certeza é obtido por:

$$G_c = \mu - \lambda$$

Os valores de  $G_c$ , que pertencem ao conjunto  $\mathfrak{R}$ , variam no intervalo fechado +1 e -1 e estão no eixo horizontal do reticulado, o qual é denominado de “*Eixo dos Graus de Certeza*”. Quando  $G_c$  resultar em +1 significa o estado lógico resultante da análise paraconsistente é Verdadeiro V, e quando  $G_c$  resultar em -1 significa que o estado lógico resultante da análise é Falso F.

Do segundo termo obtido no par ordenado da equação da transformação temos:

$$x + y - 1 = \mu + \lambda - 1$$

a qual denominamos de Grau de Contradição  $G_{ct}$ . Portanto, o Grau de Contradição é obtido por:

$$G_{ct} = \mu + \lambda - 1$$

E seus valores, que pertencem ao conjunto  $\mathfrak{R}$ , variam no intervalo fechado +1 e -1 e estão no eixo vertical do reticulado, que é denominado de “*Eixo dos graus de Contradição*”. Quando  $G_{ct}$  resultar em +1 significa o estado lógico resultante da análise é o Inconsistente T, e quando  $G_c$  resultar em -1 significa que o estado lógico resultante da análise é o Indeterminado  $\perp$ .

### 3.3. CÉLULAS NEURAIS ARTIFICIAIS PARACONSISTENTES

A Rede Neural Artificial Paraconsistente (RNAP), pode ser considerada como uma estrutura lógica composta de algoritmos baseados em Lógica Paraconsistente do tipo LPA2v, construída com a finalidade de simular o comportamento do cérebro humano.

As RNAPs são compostas de algoritmos paraconsistentes interligados, os quais, conforme visto em Da Silva Filho e Abe (2001) e Da Silva Filho, Abe e Lambert-Torres (2008), são denominados de Células Neurais Artificiais Paraconsistentes – CNAPs.

A seguir, apresentamos os diversos tipos de CNAPs que foram utilizados neste trabalho.

### 3.3.1. CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE DE APRENDIZAGEM - CNAPap

A Célula Neural Artificial Paraconsistente de aprendizagem é utilizada em Redes Neurais Artificiais Paraconsistentes como unidades de memórias e sensores de padrões em camadas primárias (DA SILVA FILHO, ABE, 2001). Por exemplo, uma CNAPap pode ser treinada para aprender um padrão utilizando o método de análise Paraconsistente aplicado através de um algoritmo.

A aprendizagem é um processo progressivo em que a saída futura ( $\mu_{E(i+1)}$ ) é obtida com a iteração do valor do Grau de evidência na entrada 1 ( $\mu_1$ ) com o complemento da saída atual, chamada de Grau de evidência desfavorável da entrada 2 ( $\lambda_{2(i)}$ ). Além disso, o Grau de evidência desfavorável da entrada 2 sofre a ação de um fator, chamado Fator de aprendizagem ( $F_A$ ), que pode assumir valores entre 0 e 1 e influência diretamente na velocidade da aprendizagem.

A equação abaixo é uma forma de expressar o processo progressivo de aprendizagem.

$$\mu_{E(i+1)} = \frac{\{\mu_1 - (\lambda_{2(i)})F_A\} + 1}{2}$$

Onde,

$\mu_1$	é o Grau de evidência presente na entrada 1
$\mu_{E(i+1)}$	é o próximo valor de saída
$\lambda_{2(i)}$	é o valor presente do Grau de evidência desfavorável
$F_A$	é o Fator de aprendizagem

O fator de aprendizagem  $F_A$  é um valor real, igual ou maior que 0, atribuído arbitrariamente por ajustes externos. Quanto maior for o valor de  $F_A$ , maior é a rapidez de aprendizado da Célula. Se  $F_A=1$  dizemos que a célula tem uma capacidade natural de aprendizagem. A capacidade natural de aprendizagem irá diminuir à medida que o ajuste de  $F_A$  se aproxima de 0.

Um algoritmo simplificado para aprendizagem de qualquer valor entre 0 e 1 é mostrado a seguir, como também o símbolo da CNAPap (conforme Figura 9):

1. Início

$$\begin{aligned}\mu_1 &= 0,5 \\ \mu_E = \mu_2 &= 0,5 \\ \lambda_2 &= 1 - \mu_2\end{aligned}$$

2. Entre com o valor do Fator de aprendizagem

$$0 \leq F_A \leq 1$$

3. Entre com o valor do Grau de evidência na entrada 1

$$0 \leq \mu_1 \leq 1$$

4. Calcule o valor Grau de evidência resultante da saída

$$\mu_E = \frac{\{\mu_1 - (\lambda_2)F_A\} + 1}{2}$$

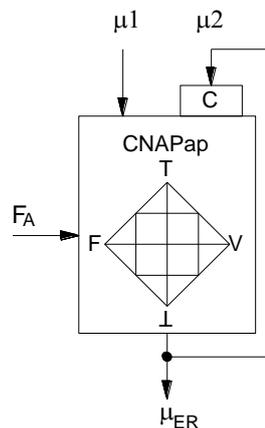
5. Atualiza o valor do Grau de evidência da entrada 2

$$\mu_2 = \mu_E$$

6. Atualize o valor do Grau de evidência desfavorável 2

$$\lambda_2 = 1 - \mu_2$$

7. Retorne ao passo 3



**Figura 9 – Símbolo de uma Célula Neural Artificial Paraconsistente de aprendizagem.  
Fonte: DA SILVA FILHO, ABE, LAMBERT-TORRES (2008).**

O algoritmo completo da Célula Neural Artificial Paraconsistente de aprendizagem (CNAPap) pode ser consultado em Da Silva Filho e Abe (2001) e Da Silva Filho, Abe e Lambert-Torres (2008).

### 3.3.2. CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE ANALÍTICA - CNAPa

A Célula Neural Artificial Paraconsistente analítica (CNAPa) tem em seu algoritmo o princípio da LPA2v, incluída a possibilidade de ajustes nos limiares de decisão. Os fatores de ajustes da CNAPa chamados de Fator de tolerância à Certeza ( $Ft_c$ ) e Fator de tolerância à Contradição ( $Ft_{ct}$ ). Estes dois fatores em conjunto ajustam a parte interna do reticulado LPA2v, alterando os pontos de decisão. (DA SILVA FILHO, ABE, LAMBERT-TORRES, 2008)

O símbolo da CNAPa pode ser mostrado na Figura 10 e seu algoritmo é descrito a seguir:

1. Entre com o valor do Grau de Evidência na entrada 1

$$0 \leq \mu_1 \leq 1$$

2. Entre com o valor do Grau de Evidência de entrada 2

$$0 \leq \mu_2 \leq 1$$

3. Entre com o valor do Fator de tolerância à Contradição

$$0 \leq Ft_{ct} \leq 1$$

4. Calcule os valores superior e inferior de controle de Contradição

$$V_{scct} = \frac{1 + Ft_{ct}}{2} e V_{icct} \frac{1 - Ft_{ct}}{2}$$

5. Entre com o valor do Fator de tolerância à Certeza

$$0 \leq Ft_c \leq 1$$

6. Calcule os valores superior e inferior de controle de Certeza

$$V_{scc} = \frac{1 + Ft_c}{2} e V_{icc} \frac{1 - Ft_c}{2}$$

7. Transforme o Grau de Evidência 2 em Grau de Evidência desfavorável

$$\lambda_2 = 1 - \mu_2$$

8. Calcule o Grau de Contradição normalizado

$$\mu_{ctr} = \frac{\mu_1 + \lambda_2}{2}$$

9. Calcule o Grau de Evidência normalizado

$$\mu_E = \frac{(\mu_1 - \lambda_2) + 1}{2}$$

10. Calcule o Intervalo de Evidência resultante

$$\varphi_E = 1 - |2\mu_{ctr} - 1|$$

11. Apresente os sinais resultantes das saídas a partir das condicionais:

$$\begin{aligned} & \text{Se } V_{scct} > \mu_{ctr} > V_{icct} \text{ e } V_{scc} \leq \mu_E \leq V_{icc} \\ & \text{então } S_1 = \mu_E \text{ e } S_2 = \varphi_E, \\ & \text{senão } S_1 = 0,5 \text{ e } S_2 = \varphi_E \end{aligned}$$

12. FIM

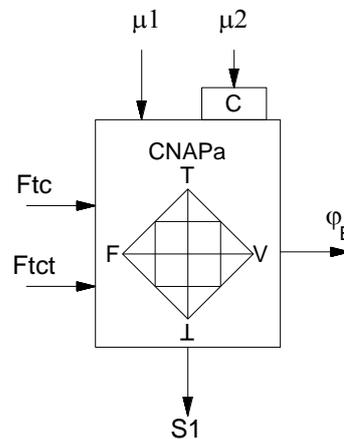


Figura 10 – Símbolo de uma Célula Neural Artificial Paraconsistente analítica.  
Fonte: DA SILVA FILHO, ABE, LAMBERT-TORRES (2008).

### 3.3.3. CÉLULA NEURAL ARTIFICIAL PARACONSISTENTE DE DETECÇÃO DE IGUALDADE - CNAPDI

A Célula Neural Artificial Paraconsistente de Detecção de igualdade executa a comparação entre dois valores de Graus de Evidência aplicados em suas entradas e através do Grau de Contradição normalizado  $\mu_{ctr}$  e do Fator de Tolerância à Contradição  $F_{tct}$ , fornece na saída  $S_1$  um sinal lógico 0 (“Falso”) ou 1 (“Verdadeiro”). (DA SILVA FILHO, ABE, LAMBERT-TORRES, 2008).

O símbolo da CNAPdi está na Figura 11 e seu algoritmo é descrito a seguir:

1. Entre com o valor do Grau de Evidência na entrada 1

$$0 \leq \mu_1 \leq 1$$

2. Entre com o valor do Grau de Evidência de entrada 2

$$0 \leq \mu_2 \leq 1$$

3. Entre com o valor do Fator de tolerância à Contradição

$$0 \leq Ft_{ct} \leq 1$$

4. Calcule os valores superior e inferior de controle de Contradição

$$V_{scct} = \frac{1 + Ft_{ct}}{2} \text{ e } V_{icct} = \frac{1 - Ft_{ct}}{2}$$

5. Transforme o Grau de Evidência 2 em Grau de Evidência desfavorável

$$\lambda_2 = 1 - \mu_2$$

6. Calcule o Grau de Contradição normalizado

$$\mu_{ctr} = \frac{\mu_1 + \lambda_2}{2}$$

7. Apresente os sinais resultantes das saídas a partir das condicionais:

$$\text{Se } V_{scct} > \mu_{ctr} > V_{icct} \text{ então } S_1 = 1 \text{ Senão } S_1 = 0$$

8. Fim

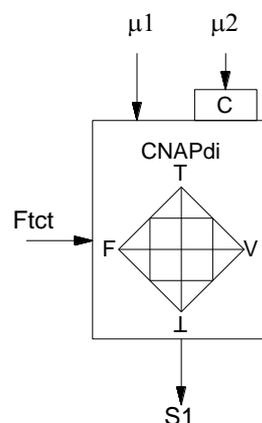


Figura 11 – Símbolo de uma Célula Neural Artificial Paraconsistente de detecção de igualdade.  
Fonte: DA SILVA FILHO, ABE, LAMBERT-TORRES (2008).

### **3.3.4. UNIDADE NEURAL ARTIFICIAL PARACONSISTENTE - UNAP**

Uma Unidade Neural Artificial Paraconsistente é formada por um conjunto de Células Neurais Artificiais Paraconsistentes (CNAPs), e como unidade, é capaz de executar uma determinada função, como por exemplo: conexão, aprendizado, competição e seleção entre outras. (DA SILVA FILHO, ABE, LAMBERT-TORRES, 2008).

A utilização de UNAPs facilita a construção de sistemas complexos, como na construção de sistema que tenta imitar o funcionamento do cérebro humano.

Em Da Silva Filho, Abe e Lambert-Torres (2008) são apresentadas várias UNAPs compostas de Células Neurais Artificiais Paraconsistentes interligadas.

Neste trabalho foi criada uma nova UNAP denominada Unidade Neural Artificial Paraconsistente de Extração de média móvel (UNAPEmm) e o detalhamento do seu algoritmo pode ser visto no Capítulo 4.

#### 4. CONTROLADOR PARACONSISTENTE ESTADÍSTICO DE PROCESSOS – CEP-LPA

O Controlador Paraconsistente Estatístico de Processos – CEP-LPA é formado por quatro módulos: Módulo Extrator de Evidência, Módulo de Média, Módulo de Dispersão e Módulo de Detecção.

Os módulos e suas interligações estão no diagrama da Figura 12.

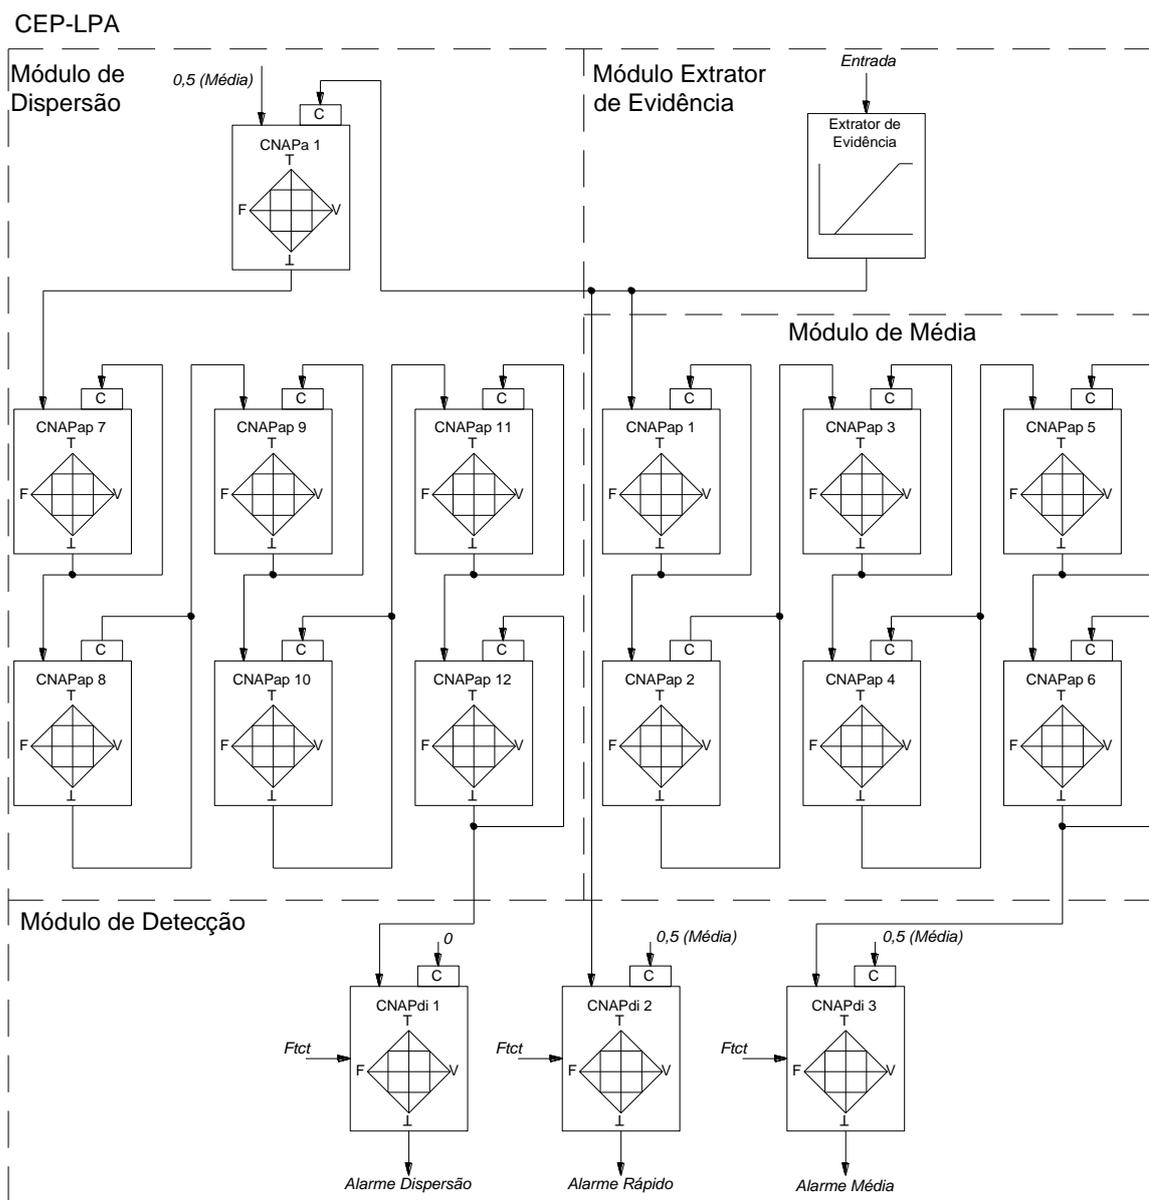


Figura 12 – Controlador Paraconsistente Estatístico de Processos – CEP-LPA.

#### 4.1. MÓDULO EXTRATOR DE EVIDÊNCIA

O Módulo Extrator de Evidência possui a função de extrair o Grau de Evidência da variável aleatória a ser controlada e fornecer estas evidências devidamente valoradas as demais partes do sistema.

A extração de evidência é a primeira parte de qualquer arranjo de Lógica Paraconsistente. Esta ação consiste no modelamento das informações originadas de fontes reais de informação em valores de saída denominados graus de evidência, que podem assumir valores no intervalo fechado  $[0, 1]$  e devem refletir da melhor maneira possível as informações originais.

Foi considerada uma fonte de informação que possui uma variável aleatória  $x$  distribuída normalmente e transformada em um escore  $z$  (ou *z-score*), que é uma medida de posição que indica o número de desvios-padrão de um valor a partir da média (FABER; LARSON, 2010). O escore  $z$  é obtido através da expressão

$$z = \frac{x - \bar{x}}{\sigma}$$

onde:

$x$  é o valor da variável

$\bar{x}$  é a média aritmética

$\sigma$  é o desvio-padrão

Na Figura 13 está um exemplo de transformação de  $x$  em escore  $z$ , para média igual a 0 e desvio padrão igual a 1.

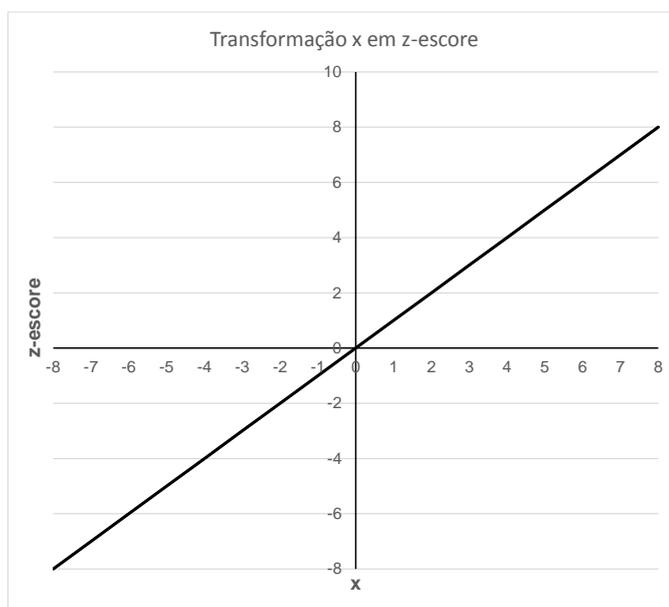


Figura 13 – Função escore z.

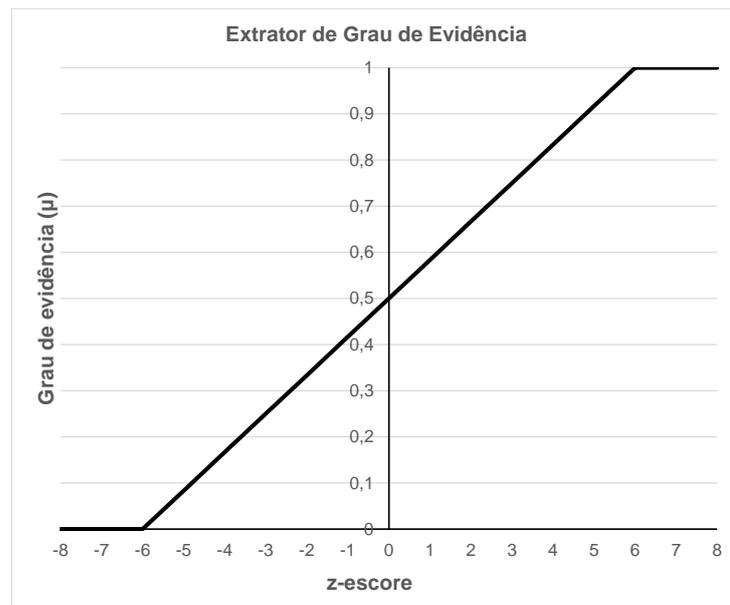
Na aplicação o uso do escore  $z$  facilitou os ajustes do sistema, pois, independente da média e do desvio-padrão da variável  $x$ , os valores  $z$  ficam em um intervalo de  $\pm 3z$  quando o processo, grosso modo, está sob controle estatístico.

A extração de evidência da variável aleatória se dá através da transformação de escore  $z$  em grau de evidência  $\mu$ . Para isso, foi utilizada uma função linear de transformação, conforme expressões abaixo:

$$\mu = \begin{cases} 0 & \text{se } z < -6 \\ \frac{z}{12} + 0,5 & \text{se } z \in [-6, 6] \\ 1 & \text{se } z > 6 \end{cases}$$

Onde,  $\mu$  é o grau de evidência.

A função da extração de grau de evidência está graficamente exposta na Figura 14.



**Figura 14 – Extrator de Grau de Evidência de escore  $z$ .**

Observando os gráficos das Figura 13 e 14, é possível perceber que existe uma relação direta entre a variável aleatória e o grau de evidência. Por exemplo, se a variável aleatória  $x$  for igual à média, o escore  $z$  torna-se igual a 0 e o grau de evidência assume o valor de 0,5, logo, a média do sistema sempre será representada pelo grau de evidência igual a 0,5, independente de quanto for a média e desvio padrão dos dados reais.

O valor de escore  $z$  depende da média e do desvio padrão. Como exemplo; sendo  $x = -3$ , em um sistema com  $\bar{x} = 0$  e  $\sigma = 1$ ,  $z = -3$  e  $\mu = 0,25$ , verificamos que para o mesmo caso se  $x = 3$ ,  $z = 3$  e  $\mu = 0,75$ .

Com base no exemplo anterior, porém, alterando o desvio padrão para  $\sigma = 0,5$ , temos  $z = -6$  e  $\mu = 0$  para  $x = -3$  e  $z = 6$  e  $\mu = 1$  para  $x = 3$ .

Os limites superior e inferior de escore  $z$ , respectivamente, 6 e -6 foram escolhidos de forma a permitir o deslocamento da média curva normal padrão  $\pm 2\sigma$ , (conforme Figura 15), ou considerando a curva normal padrão de média zero e duplicando o desvio padrão, ou seja,  $\sigma = 2$ , (conforme Figura 16), sem que os valores saturassem o grau de evidência.

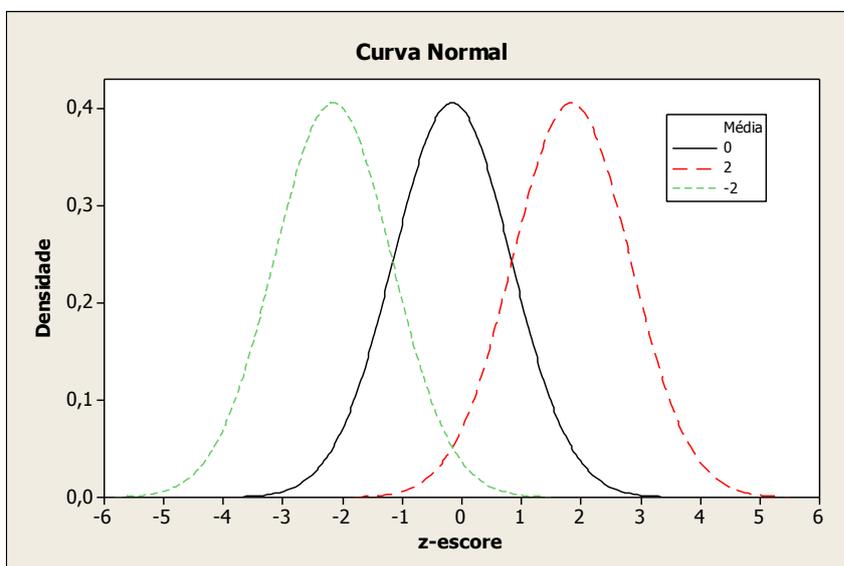


Figura 15 – Curva Normal – deslocamento de média.

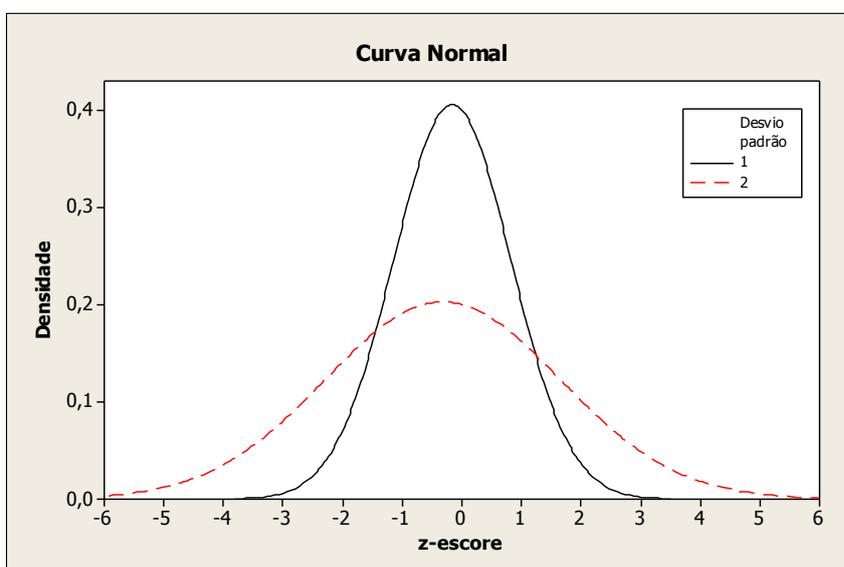


Figura 16 – Curva Normal – aumento desvio padrão.

## 4.2. UNIDADE NEURAL ARTIFICIAL PARACONSISTENTE DE EXTRAÇÃO DE MÉDIA MÓVEL – UNAPEMM

A Unidade Neural Artificial Paraconsistente de Extração de média móvel – UNAPEmm – tem papel fundamental no funcionamento do Controlador Paraconsistente Estatístico de Processos – CEP-LPA.

Como já dito, a UNAPEmm foi criada durante o processo de pesquisa e desenvolvimento deste trabalho. Devido à sua importância, este subcapítulo é dedicado ao processo de construção da UNAPEmm.

A UNAPEmm tem, em sua base, um tipo especial de Célula Neural Artificial Paraconsistente (CNAP), denominada de Célula Neural Artificial Paraconsistente de aprendizagem (CNAPap), que possui a capacidade de reproduzir em sua saída um grau de evidência aprendido a partir de iterações de grau de evidência em sua entrada.

Na estrutura computacional do CEP-LPA temos duas UNAPEmm; uma no Módulo de Média, formada pelas CNAPaps de 1 a 6 e a outra no Módulo de Dispersão, formada pelas CNAPaps de 7 a 12.

A construção da UNAPEmm nasceu da necessidade de se obter o valor médio de uma variável aleatória coletada dinamicamente.

Conforme já foi exposto, a base da UNAPEmm é a Célula Neural Artificial Paraconsistente de Aprendizagem (CNAPap), que é capaz de aprender valores reais no intervalo fechado [0,1]. Considerando seu algoritmo apresentado com fator de aprendizagem igual a um, temos a equação:

$$\mu_{E(i)} = \frac{\mu_i - (1 - \mu_{E(i-1)}) + 1}{2}$$

Onde:

$\mu_i$  grau de evidência favorável apresentado na entrada

$\mu_{E(i-1)}$  grau de evidência resultante anterior

$\mu_{E(i)}$  grau de evidência resultante na saída

Uma UNAPEmm completa está exemplificada na Figura 20, construída com seis CNAPap interligadas serialmente. Até chegar a essa configuração final houve um estudo passo a passo, que, com base em resultados foi acrescentando CNAPap

uma a uma. Este estudo foi executado utilizando uma planilha eletrônica *Excel* e seus passos e resultados estão detalhados a seguir.

Inicialmente, utilizou-se uma única CNAPap e foi apresentada em sua entrada uma sequência de um e zero, que representam, respectivamente, o grau de evidência máximo e grau de evidência mínimo. O resultado dessa simulação está na Tabela 1.

**Tabela 1 – Resultados do Ensaio com uma CNAPap.**

Amostra	$\mu(i)$	$\mu_{E(i)}$
1	0,000000	0,000000
2	1,000000	0,500000
3	0,000000	0,250000
4	1,000000	0,625000
5	0,000000	0,312500
6	1,000000	0,656250
7	0,000000	0,328125
8	1,000000	0,664063
9	0,000000	0,332031
10	1,000000	0,666016
11	0,000000	0,333008
12	1,000000	0,666504
13	0,000000	0,333252
14	1,000000	0,666626
15	0,000000	0,333313
16	1,000000	0,666656
17	0,000000	0,333328
18	1,000000	0,666664
19	0,000000	0,333332
20	1,000000	0,666666
21	0,000000	0,333333
22	1,000000	0,666667
23	0,000000	0,333333
24	1,000000	0,666667
25	0,000000	0,333333

O valor do grau de evidência resultante esperado na saída da CNAP é meio, pois equivale ao valor da média esperada estatisticamente, porém, conforme os resultados obtidos e expostos na Tabela 1, após aproximadamente 20 amostras, o valor de saída estabilizou, mas não ficou constante em meio, apresentando uma

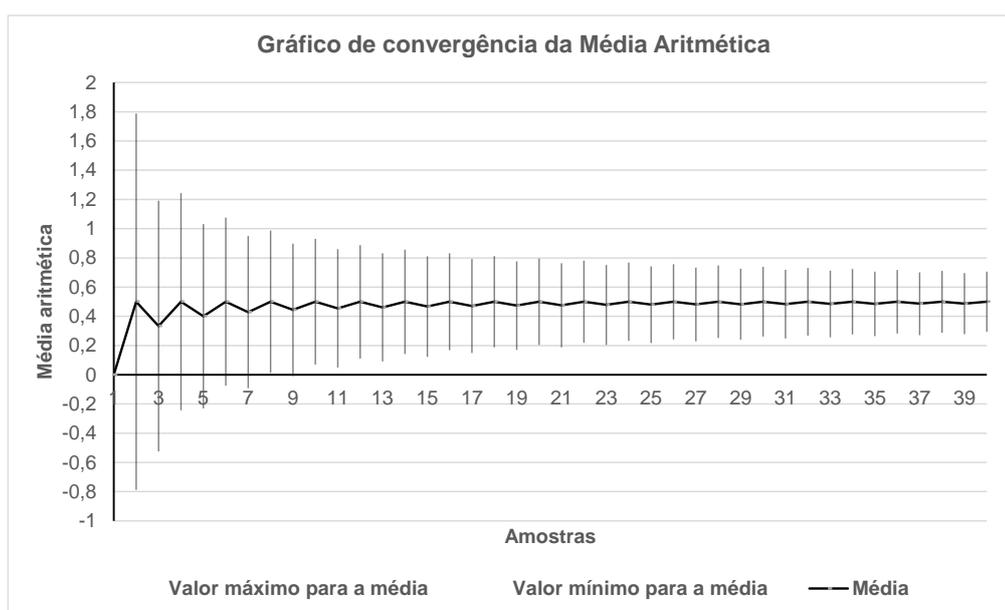
variação cíclica em saltos entre mínimos e máximos de 0,333333 e 0,666667, respectivamente.

Embora o resultado desse primeiro ensaio não fornecesse na saída o valor da média esperada, este acabou revelando informações valiosas que traçaram um paralelo entre a estatística e a Lógica Paraconsistente.

Para isto, consideramos o fato de que, na estatística, a média aritmética entre dois valores zero e um fornece o resultado de meio, mas considerando que esses dois valores são amostras, e não dados populacionais, a média encontrada carrega uma quantidade de incerteza, chamada na estatística de erro padrão da média ou desvio padrão da média. Esta incerteza é dada pela expressão abaixo:

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Verificamos que para o caso simulado, até a amostra 20, o erro padrão da média é de aproximadamente 0,1147. Considerando uma distribuição normal e estabelecendo um índice de confiança de 99%, verificamos que a média aritmética está dentro do intervalo de 0,2046 a 0,7954. Esta comparação é feita considerando como valor central 0,5, como pode ser observado no gráfico da Figura 17.



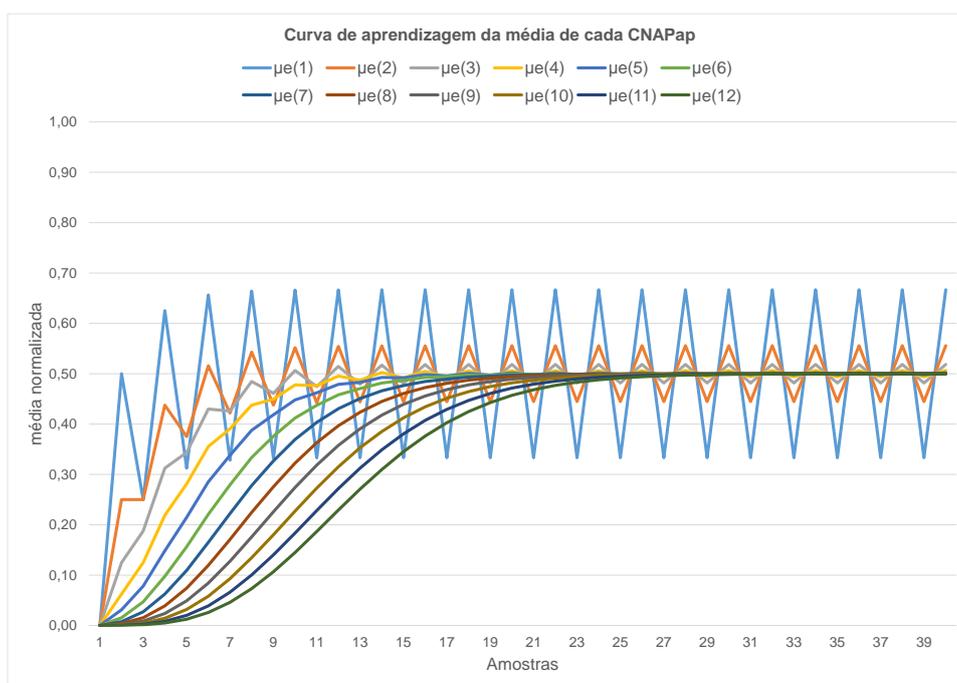
**Figura 17 – Variação da média amostra a amostra.**

Este resultado demonstra que o fato da CNAPap não fornecer o valor exato, apresenta a característica equivalente a uma distribuição normal. Outro fato que comprova isso, é que a média aritmética também não é matematicamente estável, quando consideramos a média calculada a cada amostra, levando em conta o valor da amostra atual e todos os valores anteriores (conforme gráfico da Figura 17).

Verificamos nos resultados da Figura 17 que há uma diferença a se considerar entre a média aritmética e a saída da CNAPap, pois o valor da média aritmética continua convergindo com o aumento do número de amostra, enquanto o valor da CNAPap para de convergir. Isto fica mais claro no gráfico da Figura 18 com os valores da saída  $\mu_e(1)$ .

Considerando os resultados da CNAPap como o resultado da média aritmética, fica perceptível que o que fez a média aritmética convergir, foi que em seus cálculos considerou os valores das amostras anteriores.

Aplicando esse conceito de se considerar as amostras remotas nas CNAPaps, podemos então interligá-las em um arranjo serial. Para simular o arranjo serial foram introduzidas na entrada da primeira CNAPap 40 amostras sequenciais em 0 e 1, em um arranjo com 12 CNAPaps. Os resultados desta simulação estão expostos no gráfico da Figura 18 e na Tabela 2.



**Figura 18 – Curva de aprendizagem da média das CNAPaps.**

Tabela 2 – Resultado da aprendizagem das 12 CNAPaps em série.

i	Saídas											
	$\mu\epsilon(1)$	$\mu\epsilon(2)$	$\mu\epsilon(3)$	$\mu\epsilon(4)$	$\mu\epsilon(5)$	$\mu\epsilon(6)$	$\mu\epsilon(7)$	$\mu\epsilon(8)$	$\mu\epsilon(9)$	$\mu\epsilon(10)$	$\mu\epsilon(11)$	$\mu\epsilon(12)$
1	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2	0,5000	0,2500	0,1250	0,0625	0,0313	0,0156	0,0078	0,0039	0,0020	0,0010	0,0005	0,0002
3	0,2500	0,2500	0,1875	0,1250	0,0781	0,0469	0,0273	0,0156	0,0088	0,0049	0,0027	0,0015
4	0,6250	0,4375	0,3125	0,2188	0,1484	0,0977	0,0625	0,0391	0,0239	0,0144	0,0085	0,0050
5	0,3125	0,3750	0,3438	0,2813	0,2148	0,1563	0,1094	0,0742	0,0491	0,0317	0,0201	0,0126
6	0,6563	0,5156	0,4297	0,3555	0,2852	0,2207	0,1650	0,1196	0,0844	0,0580	0,0391	0,0258
7	0,3281	0,4219	0,4258	0,3906	0,3379	0,2793	0,2222	0,1709	0,1276	0,0928	0,0660	0,0459
8	0,6641	0,5430	0,4844	0,4375	0,3877	0,3335	0,2778	0,2244	0,1760	0,1344	0,1002	0,0730
9	0,3320	0,4375	0,4609	0,4492	0,4185	0,3760	0,3269	0,2756	0,2258	0,1801	0,1402	0,1066
10	0,6660	0,5518	0,5063	0,4778	0,4481	0,4120	0,3695	0,3226	0,2742	0,2271	0,1837	0,1451
11	0,3330	0,4424	0,4744	0,4761	0,4621	0,4371	0,4033	0,3629	0,3186	0,2729	0,2283	0,1867
12	0,6665	0,5544	0,5144	0,4952	0,4787	0,4579	0,4306	0,3967	0,3576	0,3152	0,2717	0,2292
13	0,3333	0,4438	0,4791	0,4872	0,4829	0,4704	0,4505	0,4236	0,3906	0,3529	0,3123	0,2708
14	0,6666	0,5552	0,5172	0,5022	0,4926	0,4815	0,4660	0,4448	0,4177	0,3853	0,3488	0,3098
15	0,3333	0,4443	0,4807	0,4915	0,4920	0,4867	0,4764	0,4606	0,4391	0,4122	0,3805	0,3452
16	0,6667	0,5555	0,5181	0,5048	0,4984	0,4926	0,4845	0,4725	0,4558	0,4340	0,4073	0,3762
17	0,3333	0,4444	0,4812	0,4930	0,4957	0,4941	0,4893	0,4809	0,4684	0,4512	0,4292	0,4027
18	0,6667	0,5555	0,5184	0,5057	0,5007	0,4974	0,4934	0,4871	0,4778	0,4645	0,4469	0,4248
19	0,3333	0,4444	0,4814	0,4936	0,4971	0,4973	0,4953	0,4912	0,4845	0,4745	0,4607	0,4427
20	0,6667	0,5555	0,5185	0,5060	0,5016	0,4994	0,4974	0,4943	0,4894	0,4819	0,4713	0,4570
21	0,3333	0,4444	0,4815	0,4937	0,4977	0,4985	0,4980	0,4961	0,4928	0,4873	0,4793	0,4682
22	0,6667	0,5556	0,5185	0,5061	0,5019	0,5002	0,4991	0,4976	0,4952	0,4913	0,4853	0,4767
23	0,3333	0,4444	0,4815	0,4938	0,4978	0,4990	0,4991	0,4983	0,4968	0,4940	0,4897	0,4832
24	0,6667	0,5556	0,5185	0,5062	0,5020	0,5005	0,4998	0,4991	0,4979	0,4960	0,4928	0,4880
25	0,3333	0,4444	0,4815	0,4938	0,4979	0,4992	0,4995	0,4993	0,4986	0,4973	0,4950	0,4915
26	0,6667	0,5556	0,5185	0,5062	0,5020	0,5006	0,5001	0,4997	0,4991	0,4982	0,4966	0,4941
27	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4997	0,4997	0,4994	0,4988	0,4977	0,4959
28	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,4999	0,4997	0,4992	0,4985	0,4972
29	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4997	0,4998	0,4997	0,4995	0,4990	0,4981
30	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,5000	0,4999	0,4997	0,4993	0,4987
31	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4998	0,4999	0,4999	0,4998	0,4996	0,4991
32	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,5001	0,5000	0,4999	0,4997	0,4994
33	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4998	0,4999	0,4999	0,4999	0,4998	0,4996
34	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,5001	0,5000	0,5000	0,4999	0,4998
35	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4998	0,4999	0,5000	0,5000	0,4999	0,4998
36	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,5001	0,5000	0,5000	0,5000	0,4999
37	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4998	0,4999	0,5000	0,5000	0,5000	0,4999
38	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,5001	0,5000	0,5000	0,5000	0,5000
39	0,3333	0,4444	0,4815	0,4938	0,4979	0,4993	0,4998	0,4999	0,5000	0,5000	0,5000	0,5000
40	0,6667	0,5556	0,5185	0,5062	0,5021	0,5007	0,5002	0,5001	0,5000	0,5000	0,5000	0,5000

Observando os resultados obtidos na simulação, vemos que o intervalo de saída das CNAPaps aproximam-se da média esperada conforme o número de CNAPap aumenta; porém, quanto maior o número de CNAPap, maior o número de amostras para que o valor de saída se estabilize em torno da média.

Como o valor sempre se estabiliza em uma variação conhecida, podemos, então, determinar o erro, e com isso, selecionar a precisão desejada.

A Tabela 3 relaciona as quantidades de CNAPaps, o número de amostras até o alcance da estabilização e o erro residual.

**Tabela 3 – Erro residual de até 12 CNAPaps em série.**

CNAPap	Amostras	Erro (±)	Erro (±) %
1	20	0,166667	33,3333%
2	26	0,055556	11,1111%
3	33	0,018519	3,7037%
4	30	0,006173	1,2346%
5	34	0,002058	0,4115%
6	34	0,000686	0,1372%
7	38	0,000229	0,0457%
8	40	0,000076	0,0152%
9	44	0,000025	0,0051%
10	48	0,000008	0,0017%
11	46	0,000003	0,0006%
12	48	0,000001	0,0002%

Analisando os resultados da Tabela 3 e Figura 19, foi possível estabelecer a relação entre o erro residual e o número de CNAPap, fazendo:

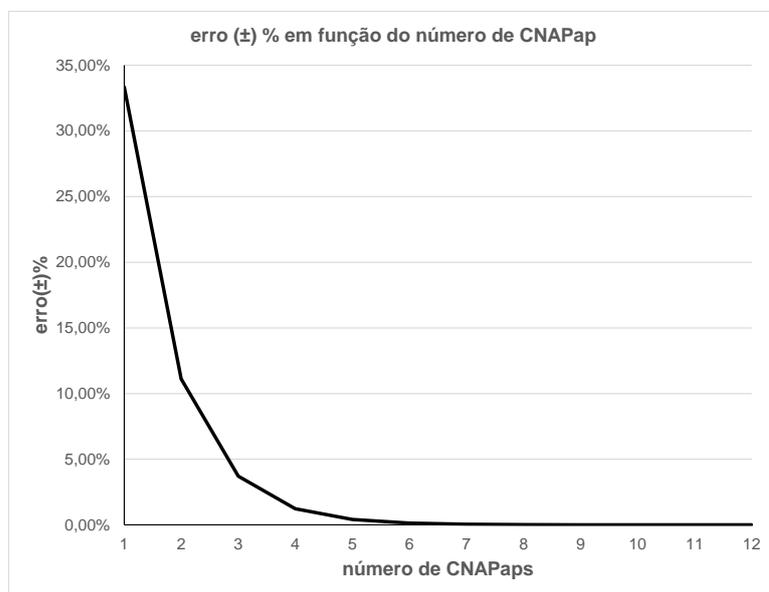
$$Erro = \pm \frac{3^{-n_{CNAPap}}}{2}$$

onde,  $n_{CNAPap}$  é o número de CNAPap utilizado.

Com base no estudo do erro residual, e considerando estes resultados em conjunto com o tempo de resposta da configuração das CNAPaps em série, um arranjo com 6 CNAPaps foi o que demonstrou um desempenho que atendeu a um baixo nível de erro residual, com um número aceitável de amostras.

É importante ressaltar que, apesar da resposta estabilizada acontecer na trigésima quarta amostra para 6 CNAPaps, o arranjo começou a fornecer valor em torno da média a partir da vigésima primeira amostra, e valores na casa de 0,49, a partir da décima sexta amostra.

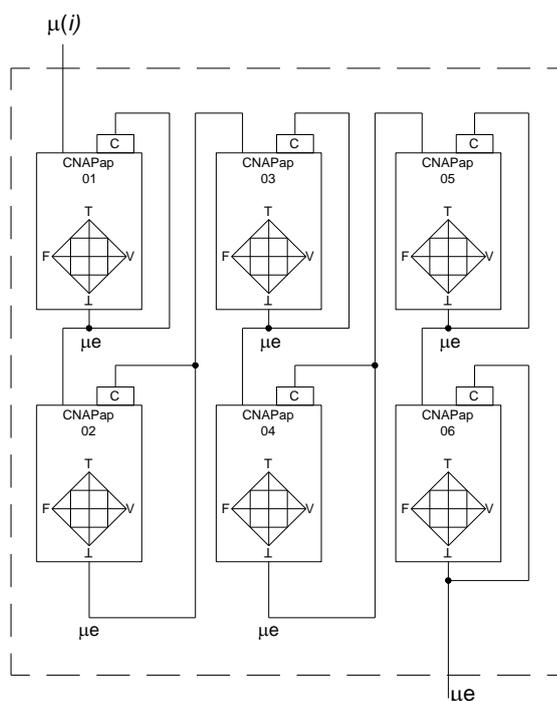
Este arranjo serial de CNAPaps com o intuito de se obter a média de uma variável foi denominada de Unidade Neural Artificial Paraconsistente de Extração de média móvel (UNAPEmm).



**Figura 19 – Percentual de erro residual em função do número de CNAPap.**

O CEP-LPA possui duas UNAPEmm com 6 CNAPaps cada, um no Módulo de Média e no Módulo de Dispersão.

O diagrama da UNAPEmm com 6 CNAPap está na Figura 20.



**Figura 20 – Unidade Neural Artificial Paraconsistente de Extração de média móvel- UNAPEmm.**

Verificamos, pelos ensaios, que a quantidade de CNAPap utilizada em uma UNAPEmm depende da aplicação, tendo como principais parâmetros a precisão e tempo de resposta.

Os arranjos com 2, 4 e 6 CNAPaps apresentaram as melhores relações entre precisão e tempo de resposta.

### **4.3. O MÓDULO DE MÉDIA**

O Módulo de Média recebe o sinal de evidência oriundo do Módulo Extrator de Evidência e fornece em sua saída a evidência resultante que representa algo semelhante à média móvel do processo, que é enviada para Módulo de Detecção.

O Módulo de Média é composto basicamente por uma Unidade Neural Artificial Paraconsistente de Extração de média móvel (UNAPEmm), detalhada no subcapítulo anterior.

A UNAPEmm do Módulo de Média é formada pelas CNAPaps de 1 a 6.

Essa UNAPEmm foi testada para dados normalmente distribuídos, tendo o grau de evidência de entrada sido obtido de maneira semelhante ao Módulo Extrator deste trabalho, e apresentou comportamento compatível com a média móvel dos dados de entrada.

### **4.4. O MÓDULO DE DISPERSÃO**

O Módulo de Dispersão foi o último módulo incorporado ao CEP-LPA, mas possui importância fundamental na detecção do aumento de dispersão antes que os valores ultrapassem os limites de controle.

Na entrada do Módulo de Dispersão foi instalada uma Célula Neural Artificial Paraconsistente analítica CNAPa que, recebe em uma de suas entradas a evidência oriunda do Módulo Extrator de Evidência. A outra entrada desta célula é fixa e tem seu valor parametrizado de forma que represente a evidência da média esperada para o processo, ou seja, meio (0,5).

No Módulo de Dispersão foi utilizado o intervalo de evidência resultante  $\varphi_e$  da CNAPa como evidência de saída.

O intervalo de evidência resultante  $\varphi_e$  é utilizado no algoritmo da Célula Neural Artificial Paraconsistente analítica, visto no Capítulo 2, e é calculado por:

$$\varphi_E = 1 - |2\mu_{ctr} - 1|$$

onde  $\mu_{ctr}$  é o Grau de Contradição normalizado, calculado por:

$$\mu_{ctr} = \frac{\mu_1 + \lambda_2}{2}$$

Verificamos que o intervalo de certeza  $\varphi$ , é um retrato do grau de contradição  $G_{ct}$ . Portanto, considerando um aumento na dispersão, as evidências de entrada ficam mais distantes da média, causando um aumento do grau de contradição na CNAPa. Este aumento da contradição causa a queda do intervalo de evidência resultante  $\varphi_e$ . Dessa forma, o intervalo de evidência resultante  $\varphi_e$  da saída da CNAPa retrata fielmente a dispersão dos dados.

A UNAPEmm do Módulo de Dispersão é formada pelas CNAPaps de 7 a 12 e recebe em sua entrada o intervalo de evidência resultante  $\varphi_e$ , que passa a ser o grau de evidência aprendido pela UNAPEmm.

De forma geral, a saída final do Módulo de Dispersão retrata a evidência média do intervalo de evidência resultante, que é inversamente proporcional à dispersão dos dados.

#### 4.5. MÓDULO DE DETECÇÃO

A Unidade de Detecção é formada por Células Neurais Artificial Paraconsistente de detecção de igualdade (CNAPdi) e tem a função de fornecer alarmes que detectem comportamento não aleatório da variável do processo, com base nos valores obtidos pelos módulos Extrator de Evidência, Média e Dispersão.

As CNAPdis fornecem seus alarmes com base em uma evidência compatível com aspectos abordados na estatística e no Controle Estatístico de Processo.

O Alarme Rápido é obtido através da avaliação da evidência da saída do Módulo Extrator de Evidência. Este é compatível com o gráfico de controle para valores individuais, conforme Montgomery (2012).

Ao todo, além do Alarme rápido que é comum em controle estatístico, o Controlador CEP-LPA apresenta mais dois tipos de alarme:

1. O Alarme de Média, que é obtido através da avaliação da evidência da saída do Módulo de Média. Este é compatível com o gráfico de controle de média móvel de acordo com Montgomery (2012).

2. O Alarme de Dispersão que é compatível com o gráfico de controle de amplitude móvel. Este tipo de alarme está exposto conforme Montgomery (2012).

Quanto à sensibilidade a CNAPdi possui o parâmetro de Fator de Tolerância à Contradição ( $F_{tct}$ ) que serve de comparação com o Grau de Contradição normalizado  $\mu_{ctr}$ , e através dessa comparação, gera sua saída  $S_1$  a qual assume valor um, quando o grau de contradição normalizado está dentro dos limites de controle de contradição, e zero quando está fora.

Por meio da parametrização do Fator de Tolerância à Contradição ( $F_{tct}$ ) de cada Alarme que se determina o ajuste a sensibilidade de disparo.

No Alarme Rápido e de Média a CNAPdi recebe, em uma das entradas, a evidência do respectivo Módulo e a outra é configurada em meio (0.5).

No Alarme de Dispersão a CNAPdi recebe, em uma das entradas, a evidência do Módulo de Dispersão e a outra é colocada em zero (0).

Neste trabalho o CEP-LPA foi implementado para que cada alarme seja considerado como ativo quando assume o valor zero (0) para os Alarmes Rápido e Média, e um (1) para Alarme de Dispersão.

O Alarme de Dispersão ainda apresenta um tempo morto na sua atuação, que será detalhado no próximo capítulo que trata das simulações.

## 5. SIMULAÇÕES

Apresentamos neste capítulo os principais detalhes e resultados obtidos nas simulações. Para isto, nesta pesquisa, foram criados como, padrões de testes, dois conjuntos de dados para simular e validar os resultados do CEP-LPA.

O primeiro Conjunto de Dados chamado de *Padrões* apresentou a distribuição normal com média zero e desvio padrão igual. Nestas simulações iniciais consideramos que estes *Padrões* também teriam que possuir características de um processo sob controle estatístico, e para testar essa condição, foram utilizados os Gráficos de Controle Individual e CUSUM tubular através do *software* Minitab.

O segundo conjunto de dados foi criado tomando como referência os dados existentes no primeiro, que, conforme descrito anteriormente, foi denominado *Padrões*. Os testes foram elaborados por meio de alterações desejadas na média e no desvio padrão de forma a criar dados que seriam detectados pelo CEP-LPA. O armazenamento dos dois conjuntos de dados foi feito em uma planilha eletrônica *Excel*.

Para formar a sua estrutura computacional o CEP-LPA foi construído e simulado no Matlab com programação que elabora a leitura dos dados no *Excel* e fornece gráficos com as informações de entrada e saída. Os valores das variáveis de entrada e saída foram verificados e extraídos para análises nas matrizes do Matlab.

### 5.1. GERAÇÃO DOS PADRÕES

A geração dos Padrões seguiu parcialmente a orientação do trabalho de Belastrassi (2000), no que tange à quantidade de amostra e os testes utilizando gráfico de controle para valores individuais e gráfico CUSUM.

Por meio do programa Minitab foram gerados vários padrões aleatórios contendo 60 amostras com distribuição normal com média igual a zero e desvio padrão igual a um.

Embora tenham sido gerados pelo Minitab, nesta primeira simulação, não existia a garantia que os dados atenderiam os critérios de um processo sob controle estatístico. Dessa forma, para aumentar a confiabilidade de que os Padrões

estariam sob controle estatístico, foram aplicados os testes de gráfico de controle para valores individuais e CUSUM Tubular, através do próprio Minitab. Exemplos com resultados desses testes estão listados nos gráficos das Figura 21 e 22.

Nesta simulação foram selecionados 10 Padrões que passaram nos testes e, em seguida, foram salvos em um arquivo Excel, formando assim, um banco de dados padronizados que passou a ser chamado de **Padrões**.

As informações gerais sobre cada Padrão utilizado nos Testes estão na Tabela 4.

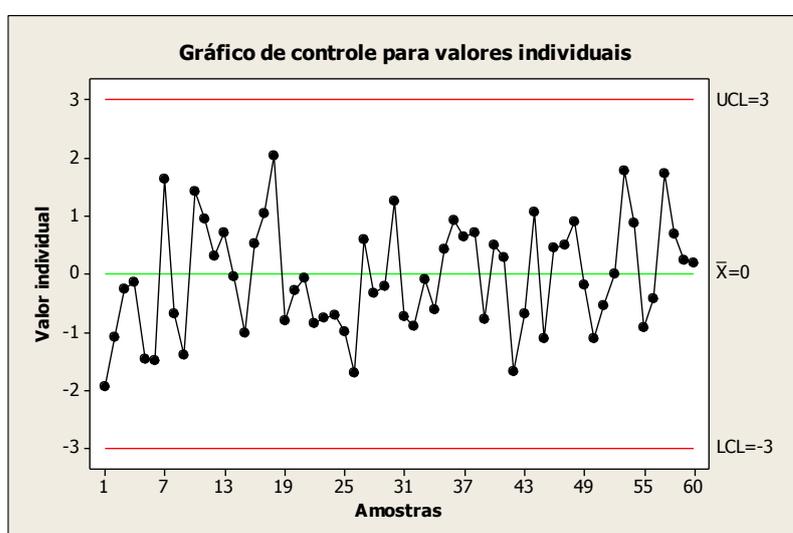


Figura 21 – Gráfico de controle para valores individuais.

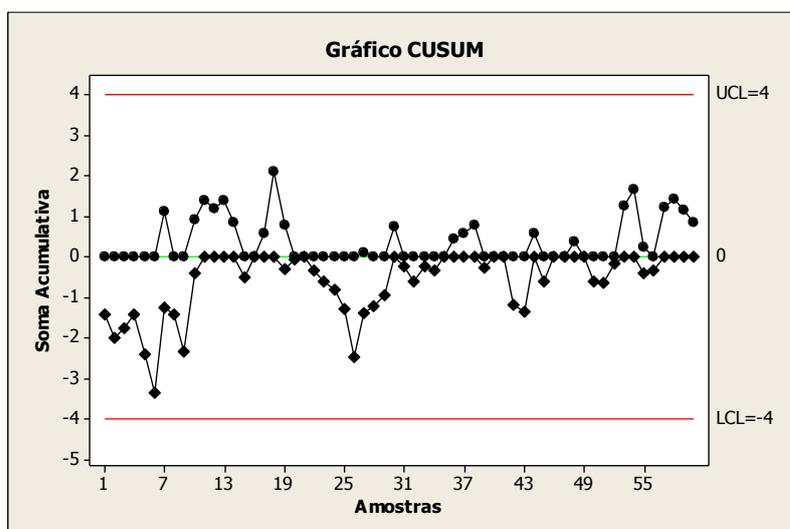


Figura 22 – Gráfico CUSUM Tubular.

Tabela 4 – 10 Padrões sob controle estatístico.

Padrão	N	Média	Desvio Padrão	Erro Padrão da Média
1	60	0,048	1,062	0,137
2	60	-0,036	0,939	0,121
3	60	0,186	0,940	0,121
4	60	-0,059	0,945	0,122
5	60	-0,062	0,959	0,124
6	60	-0,095	1,081	0,140
7	60	0,026	1,039	0,134
8	60	0,018	1,050	0,136
9	60	-0,075	1,029	0,133
10	60	0,029	0,933	0,120

## 5.2. GERAÇÃO DOS PADRÕES MODIFICADOS

Para aumentar a confiabilidade nos testes e testar a robustez do Controlador CEP-LPA foi gerado um Banco de dados com padrões modificados. Dessa forma, os padrões não aleatórios foram gerados a partir da modificação no valor da média ou desvio padrão dos 10 Padrões sob controle estatístico, anteriormente gerados. Para isso, foi utilizada a expressão abaixo:

$$f(t) = \mu * e + x(t) * \sigma$$

Onde:

$x(t)$  são os valores das amostras com média 0 e desvio padrão igual a 1

$\mu$  é o valor que corresponde ao desvio da média

$\sigma$  é o valor que aumenta o desvio padrão

$e$  é o incremento da média a cada amostra

$f(t)$  são os valores após as modificações

Expressão semelhante foi encontrada em Belastrassi (2000) e SHABAN *et al.* (2010).

Neste teste, o valor  $e$  utilizado nos padrões rampa da tabela X foi escolhido de forma a criar uma rampa de média 0 até o acréscimo de  $\mu$  após 60 iterações, logo, o valor de  $e$  é dado por:

$$e = t * \frac{1}{60} \text{ ou } e = t * 0,0167$$

Na sequência das simulações a amostra de cada Padrão foi concatenada com seu respectivo Padrão modificado, formando uma sequência de 120 amostras, sendo as 60 primeiras sob controle estatístico e as 60 últimas alteradas.

As alterações propostas geraram alterações importantes a serem investigadas, pois tratam das mais comuns alterações que podem acontecer em um sistema real. Um dos principais aspectos que foram investigados é relacionado à eficiência na detecção de pequenos desvios de média, tanto no tipo Degrau quanto no tipo Rampa. Outro desafio na identificação da eficiência do sistema foi o encontro de uma forma de detecção do aumento da dispersão antes que os dados atinjam valores superiores aos limites de controle.

As implementações por meio das RNAPs permitem que estes valores sejam encontrados e validados devido à simplicidade da sua estrutura computacional em relação aos projetos que utilizam as RNA clássicas.

Na Tabela 5 constam todos os Tipos de Desvios e os parâmetros das alterações que foram detectados nestes testes.

**Tabela 5 – Tipos de alterações aplicadas aos 10 Padrões.**

Tipo de Desvio	Parâmetros das amostras de		
	$\mu$	$\sigma$	e
Degrau positivo de Média	0,2500	1,0000	1,0000
Degrau positivo de Média	0,5000	1,0000	1,0000
Degrau positivo de Média	0,7500	1,0000	1,0000
Degrau positivo de Média	1,0000	1,0000	1,0000
Degrau positivo de Média	1,2500	1,0000	1,0000
Degrau positivo de Média	1,5000	1,0000	1,0000
Degrau positivo de Média	1,7500	1,0000	1,0000
Degrau positivo de Média	2,0000	1,0000	1,0000
Degrau negativo de Média	-0,2500	1,0000	1,0000
Degrau negativo de Média	-0,5000	1,0000	1,0000
Degrau negativo de Média	-0,7500	1,0000	1,0000
Degrau negativo de Média	-1,0000	1,0000	1,0000
Degrau negativo de Média	-1,2500	1,0000	1,0000
Degrau negativo de Média	-1,5000	1,0000	1,0000
Degrau negativo de Média	-1,7500	1,0000	1,0000
Degrau negativo de Média	-2,0000	1,0000	1,0000
Dispersão	0,0000	1,2500	1,0000
Dispersão	0,0000	1,5000	1,0000
Dispersão	0,0000	1,7500	1,0000
Dispersão	0,0000	2,0000	1,0000
Rampa positiva	0,5000	1,0000	0,0167
Rampa positiva	1,0000	1,0000	0,0167
Rampa positiva	1,5000	1,0000	0,0167
Rampa positiva	2,0000	1,0000	0,0167
Rampa negativa	-0,5000	1,0000	0,0167
Rampa negativa	-1,0000	1,0000	0,0167
Rampa negativa	-1,5000	1,0000	0,0167
Rampa negativa	-2,0000	1,0000	0,0167

### 5.3. CONFIGURAÇÃO DO CEP-LPA

Os ajustes de parâmetros de configuração do CEP-LPA são basicamente aqueles relacionados aos Fatores de Tolerância à Contradição ( $F_{tct}$ ) de cada CNAPdi de cada alarme.

Neste trabalho as calibrações dos três  $F_{tct}$  foram executadas seguindo o princípio de que os dados sob controle estatístico, chamados de Padrões, não geram nenhum tipo de alarme. Dessa forma, os 10 Padrões foram concatenados com eles mesmos formando uma série com 120 amostras por Padrão.

Estas 120 amostras selecionadas foram aplicadas ao CEP-LPA e ajustados os  $F_{tct}$  até que nenhum alarme fosse detectado. Com o CEP-LPA devidamente configurado foram então aplicados os Padrões modificados e obtidos os resultados que serão discutidos a seguir.



Com base nos padrões simulados foram obtidos 262 em 280 cenários alarmados, o que mostra uma eficiência de 93,57% de padrões devidamente detectados.

Das 18 amostras não alarmadas foram 9 que estavam classificadas para degrau  $\pm 0,25$ , 6 para rampa  $\pm 0,50$ , 2 para dispersão 1,25 e 1 para degrau  $-0,50$ . Todas as amostras não alarmadas estavam previstas devido à magnitude das alterações e que dificilmente seriam detectados por sistemas puramente estatísticos.

Ainda analisando a Tabela 6, verificamos que há uma predominância de alarmes de Média, mais especificamente 66,43% de todos os padrões e 70,99% dos padrões alarmados.

Já o alarme Rápido representa 23,21% do total e 24,81% dos padrões alarmados, restando 3,93% total e 4,20% para os alarmes de Dispersão.

Como o foco desta pesquisa é a detecção de pequenos desvios, são listadas a seguir, algumas análises segmentadas.

Para o caso de Degrado menor ou igual a  $\pm 1,5$  foram 95 alarmes de Média em 120 casos possíveis ou 110 alarmados, representando, respectivamente, 79,17% e 86,36%.

O restante foi 13 de alarmes Rápidos e 2 de Dispersão, correspondente a 11,83% e 1,87% dos eventos alarmados.

Para o caso de Dispersão menor ou igual a  $\pm 1,5$  foram 9 alarmes Rápidos em 20 casos possíveis ou 18 alarmados, representando, respectivamente, 45,00% e 50,00%.

O restante foi 6 de alarmes de Dispersão e 3 de Média.

Para o caso de Rampa foi, na maioria, alarme de Média, mais, especificamente, 68 do total de 80 casos, 85,00%, ou 68 de 72 alarmados, 94,44%.

Tabela 7 – Resultados dos alarmes – Tempo dos alarmes.

i	Padrões (Número da amostra do alarme a partir da amostra 61)																														
	1			2			3			4			5			6			7			8			9			10			
	M	D	R	M	D	R	M	D	R	M	D	R	M	D	R	M	D	R	M	D	R	M	D	R	M	D	R	M	D	R	
1	-	-	-	-	-	-	27	-	-	-	-	-	-	-	-	-	-	30	-	-	37	-	-	30	-	-	-	-	-		
2	10	-	-	22	-	-	11	-	24	24	-	-	18	-	-	21	-	18	26	-	-	24	-	-	28	-	-	23	-	-	
3	8	-	-	19	25	-	10	12	24	8	43	-	14	-	-	5	-	18	7	27	-	22	-	43	24	31	-	18	-	-	
4	7	5	-	12	23	-	9	10	24	7	38	-	13	19	-	4	50	18	7	26	-	9	36	43	16	29	47	8	30	-	
5	7	4	-	10	21	-	7	9	7	6	6	36	11	15	18	4	20	18	6	24	23	8	22	30	7	26	47	7	17	22	
6	6	4	3	8	11	-	6	8	7	6	4	2	9	14	18	4	7	18	6	8	5	7	9	6	6	22	47	6	8	22	
7	6	4	3	7	9	21	5	7	7	5	4	2	8	12	7	3	6	3	5	7	5	7	8	6	5	14	42	6	8	4	
8	5	3	3	7	7	18	4	7	7	5	4	2	6	11	7	3	5	3	5	6	5	6	7	6	5	6	2	6	7	4	
9	-	-	39	38	-	-	-	-	-	51	-	-	9	-	-	-	-	-	47	48	-	15	-	-	11	-	-	-	-	-	
10	41	43	39	7	-	-	-	-	-	14	-	-	7	11	-	36	-	-	45	47	-	13	-	-	9	-	-	13	-	-	
11	16	42	39	5	39	-	18	-	-	12	52	-	6	8	-	14	-	-	12	45	-	10	15	-	8	10	-	11	14	-	
12	14	41	39	5	37	-	7	-	3	10	15	-	6	6	-	11	24	-	10	44	-	5	12	-	7	8	-	8	12	11	
13	7	18	39	4	8	-	7	7	3	8	13	56	6	6	-	9	15	-	9	12	45	5	10	51	7	7	37	6	11	3	
14	6	15	39	4	6	6	6	6	3	7	11	13	5	5	1	8	10	-	7	11	41	5	6	11	6	7	6	6	10	3	
15	5	7	35	4	6	6	6	6	3	6	9	13	5	5	1	7	8	22	6	10	16	4	5	1	6	6	3	5	8	3	
16	5	5	14	4	5	6	5	5	3	5	7	13	5	4	1	7	6	22	5	8	16	4	4	1	5	6	3	5	7	3	
17	-	40	39	39	-	-	29	-	24	52	-	-	-	12	-	-	-	18	-	45	-	-	-	43	-	-	-	-	-	-	
18	-	36	39	38	25	-	27	10	3	51	39	36	7	9	-	-	25	18	47	26	23	17	8	43	11	10	47	-	41	3	
19	-	4	3	38	22	6	13	8	3	51	5	36	6	8	1	39	21	18	29	24	23	15	6	6	10	7	37	32	8	3	
20	11	4	3	37	21	6	13	7	3	15	4	2	6	6	1	38	19	2	28	22	5	14	5	1	9	6	3	31	7	3	
21	-	-	-	49	-	-	42	-	-	41	-	-	59	-	-	51	-	-	-	-	-	-	-	37	-	-	50	-	-	-	-
22	33	-	-	46	-	-	27	-	24	37	-	-	41	-	-	47	60	-	28	52	-	35	-	43	29	50	-	30	-	-	
23	27	43	-	23	47	-	25	51	24	25	39	-	21	56	-	42	49	18	26	50	-	33	38	43	27	48	47	27	-	-	
24	25	35	39	22	26	50	24	28	24	23	38	36	19	41	53	21	47	18	25	27	45	23	36	43	26	46	47	22	51	50	
25	-	-	39	38	-	-	-	-	-	50	-	-	29	-	-	39	-	-	46	47	-	-	-	-	41	-	-	-	-	-	
26	41	42	39	36	-	-	45	-	-	46	52	-	27	-	-	36	-	-	44	46	-	16	-	-	39	56	-	46	-	-	
27	39	42	39	34	38	-	41	-	-	44	48	56	26	-	-	34	-	-	42	44	-	15	52	51	37	41	-	39	47	-	
28	33	40	39	30	37	58	34	44	-	16	44	56	25	28	-	27	37	-	35	44	41	15	50	51	18	39	47	36	44	-	

Analisando cada método de alarme separadamente, com base na Tabela 7, temos os resultados a seguir.

Para o Alarme de Média tivemos 251 em 280 possíveis, representando uma eficiência de 89,64%.

Para o Alarme de Dispersão tivemos 193 em 280 possíveis, representando uma eficiência de 68,92%.

Para o Alarme Rápido tivemos 147 em 280 possíveis, representando uma eficiência de 52,50%.

Focando a análise na Tabela 7, destacamos um caso de sucesso na detecção de pequenos desvios, ocorrido com o Padrão 7. Neste caso, para o desvio tipo

degrau de 0,25 (item1), o Alarme de Média disparou na amostra 30, enquanto os demais alarmes permaneceram não acionados.

Evoluindo para o desvio tipo degrau de 0,50 (item2), o Alarme de Média atuou na amostra 26 com os outros alarmes não acionados.

Passando para o item 3, que tem desvio de 0,75, o Alarme de Média atuou rapidamente na amostra 7 e o Alarme de Dispersão na amostra 27 e o Alarme Rápido não foi acionado. Somente com o desvio de 1,5 o Alarme Rápido atuou, mesmo assim, o primeiro alarme foi o de Média na amostra 6, o Alarme Rápido atuou na amostra 23.

Este exemplo demonstra a eficiência na detecção de pequenos desvios de média pelo Alarme de Média, que é o principal objetivo deste alarme.

Nos desvios tipo Rampa, onde o crescimento se dá de maneira lenta, o Alarme de Média apresentou desempenho superior aos demais alarmes. Este tipo de desvio dificilmente seria percebido no gráfico de Shewhart.

Como exemplo, destacamos o Padrão 6 para os itens de Rampa descendente. Neste, podemos ver que os Alarmes de Média ocorreram de maneira eficiente, enquanto o Alarme Rápido não chegou a ser acionado em nenhuma rampa.

Para o Alarme de Dispersão, destacamos o exemplo do Padrão 5, itens 17, 18, 19 e 20, que são itens nos quais a dispersão foi alterada.

O Alarme de Dispersão atuou em todos os casos, sendo o primeiro a ser disparado quando a alteração de dispersão não causou dados acima dos limites de controle tradicionais.

Verificamos que nos resultados obtidos, o Alarme Rápido segue basicamente o gráfico de Shewhart para medidas individuais, e detecta dados acima dos limites de controle tradicionais, sendo o mais eficiente para esse tipo de caso. Para esta comparação verificamos que as técnicas utilizadas no CEP-LPA, considera os dados históricos nos Alarmes de Média e de Dispersão, como em técnicas estatísticas do tipo CUSUM e EWMA. Esta é uma significativa vantagem do CEP-LPA em relação aos gráficos Shewhart, que podem gerar alarmes falsos, por não ter esta característica.

Avaliando o Alarme Rápido através das Tabela 6 e 7, vemos que ele foi de suma importância na detecção de grandes desvios, como também, nos casos de aumento de dispersão.

Para uma abordagem gráfica dos acionamentos dos alarmes verificamos a eficiência do CEP-LPA através da análise de algumas sequências de alarmes. Estes resultados estão exemplificados a seguir com alguns gráficos destacados nas sequências das simulações.

Considerando a forma que os alarmes atuam que são um (1) para zero (0) na ação de Alarme de Média e Rápido, e de zero (0) para um (1) na ação do Alarme de Dispersão. Podemos, então, analisar os gráficos das figuras a seguir.

Com relação ao Alarme de Dispersão observamos que este possui um tempo morto, no qual embora alarmado, não deve ser considerado. Portanto, o Alarme de Dispersão só pode ser considerado após fazer a primeira transição para o zero (0).

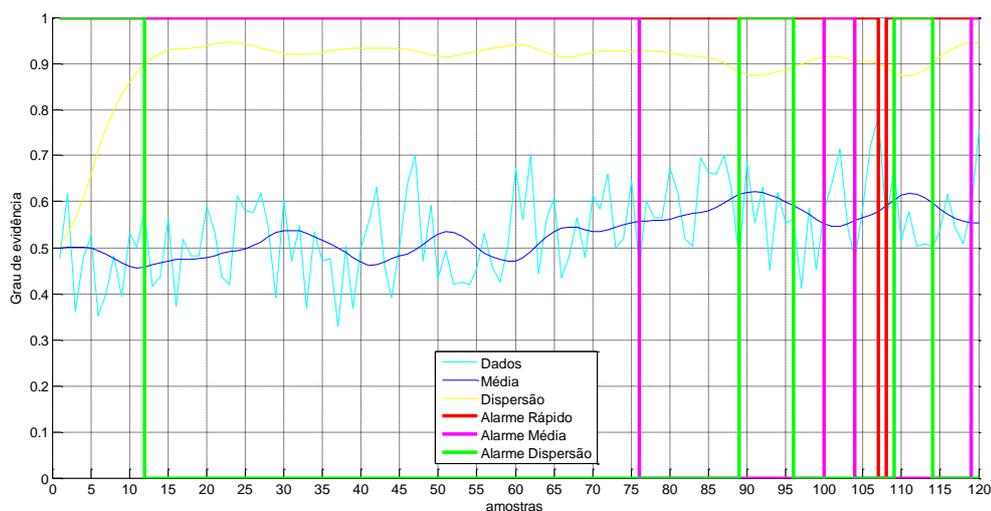
Para demonstrar a relevância dos alarmes em um padrão de Degrau de Média, foi utilizado o Padrão 9 item 4; neste exemplo, temos um desvio de média de  $1,0\sigma$ . A representação gráfica deste exemplo está na Figura 23.

Neste exemplo da Figura 23, todos os alarmes atuaram, porém, o Alarme de Média foi o mais sensível, gerando seu primeiro alarme a partir da amostra 16 e permanecendo alarmado até a amostra 39; um segundo Alarme de Média aconteceu na amostra 43 até amostra 57.

O segundo alarme a atuar foi o Alarme de Dispersão. O alarme aconteceu na amostra 29 até a amostra 35; um segundo alarme aconteceu na amostra 49 até a amostra 53.

O Alarme Rápido disparou na amostra 47 uma única vez.

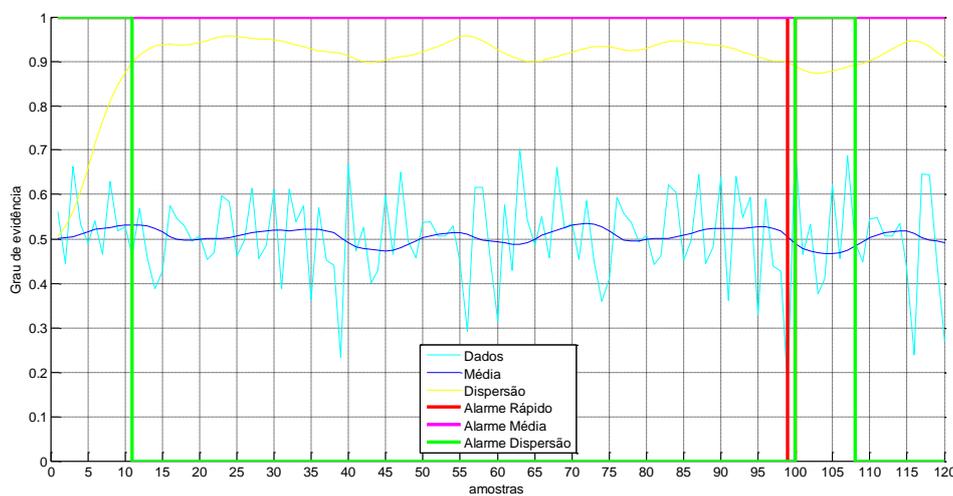
Foi possível evidenciar que o Alarme de Média possui uma sensibilidade maior para a detecção de pequenos desvios de média, pois além de gerar o alarme, este permaneceu alarmado por um número maior de amostras, fornecendo informação ao analista de que o problema detectado não foi pontual, e que é necessário a avaliar o que fez o sistema sair de seu funcionamento normal.



**Figura 23 – Exemplo gráfico para o Padrão 9, item 4.**

Como o Alarme de Média atuou antes do Alarme Rápido podemos, neste caso, afirmar que se o sistema fosse real, o analista poderia interromper a operação antes que o sistema produzisse produtos fora da especificação.

O exemplo da Figura 24 tem o objetivo de demonstrar a atuação do Alarme Rápido e do Alarme de Dispersão. Ele foi construído com os dados do Padrão 1 item 17, que é um caso de aumento de dispersão em 25%.

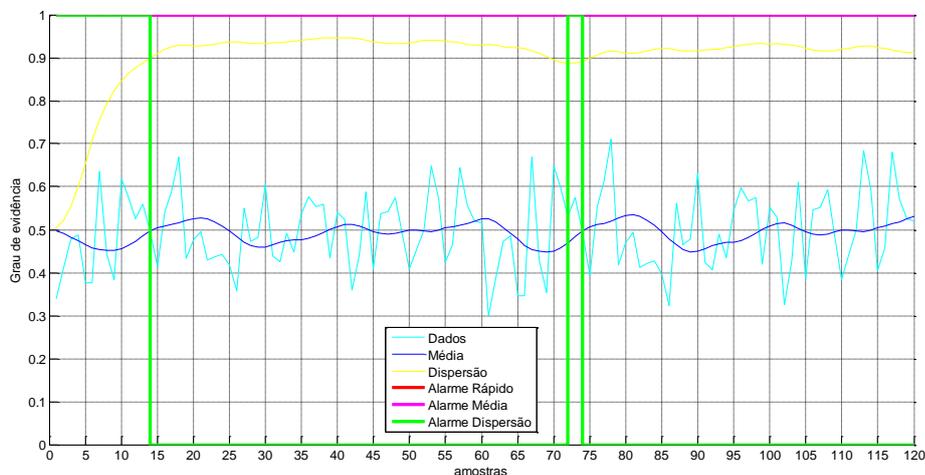


**Figura 24 – Exemplo gráfico para o Padrão 1 item 17.**

Neste caso, o primeiro alarme foi o Alarme Rápido que aconteceu na amostra 39, mas, logo em seguida na amostra 40, o Alarme de Dispersão foi acionado e permaneceu assim até a amostra 47.

Com a informação de que o Alarme de Dispersão também foi acionado, o analista tomaria sua decisão de parar a produção com mais segurança.

Outro exemplo a se destacar para o Alarme de Dispersão é o Padrão 5, item 17, no qual somente o Alarme de Dispersão atuou no período analisado, como pode ser visto na Figura 25.

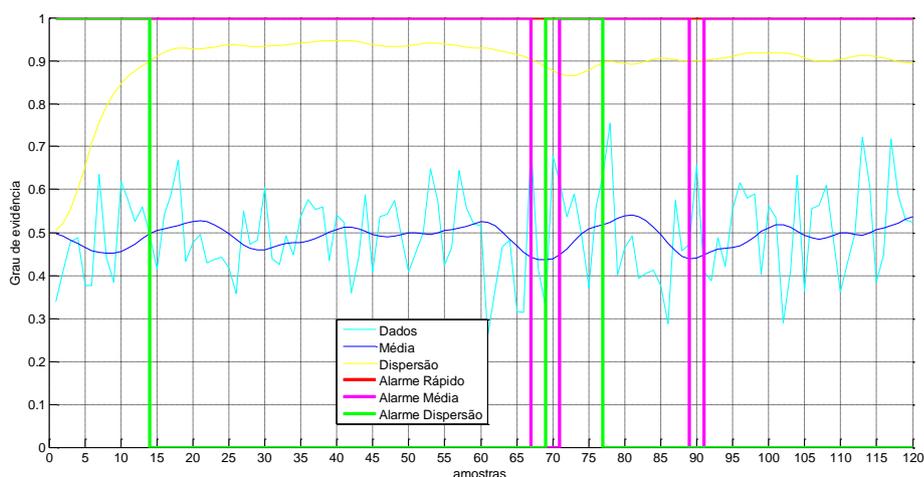


**Figura 25 – Exemplo gráfico para o Padrão 5 item 17.**

Este exemplo se destaca porque houve um aumento da dispersão sem que os pontos ultrapassem o limiar do Alarme Rápido.

Podemos analisar agora o Padrão 5, no item 18, que possui um desvio 50% superior ao normal, conforme a Figura 26. Neste caso, os dados de Média e Dispersão apresentam alterações que tiveram magnitude suficiente para ser detectado pelos Alarmes de Média ou Dispersão. Isto acontece, porque os dados tendem a fazer com que a evidência da Média apresente uma maior amplitude. Fazendo um paralelo com a estatística clássica, como o desvio padrão aumentou, o erro padrão da média aumenta também, fato que é sinalizado pela variação da linha Média.

A exposição anterior justifica porque mesmo quando somente a dispersão é alterada (itens: 17, 18, 19 e 20), o Alarme de Média consegue detectar as alterações, colaborando também na detecção deste tipo de alteração.

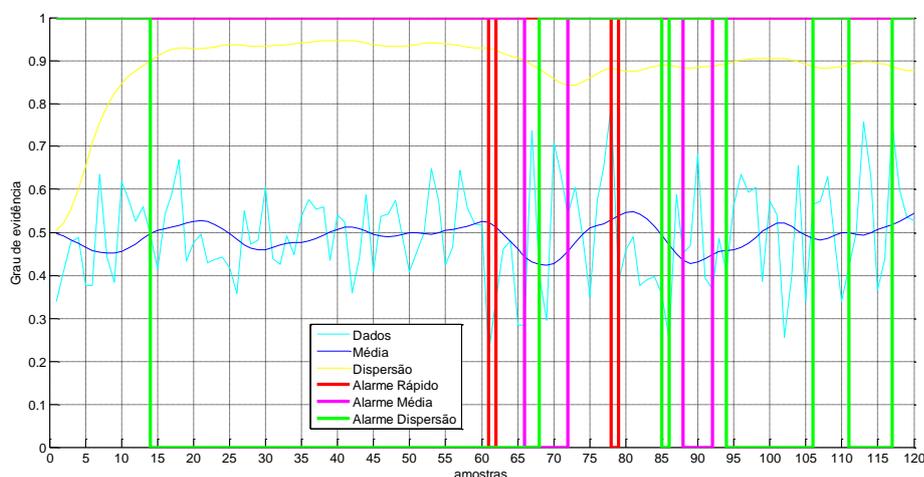


**Figura 26 – Exemplo gráfico para Padrão 5 item 18.**

Seguindo a análise utilizamos ainda o Padrão 5, porém com o item 19, que tem desvio padrão 75% maior que o normal, conforme visto na Figura 27.

Verificamos que surgiu, logo na primeira amostra, um dado que disparou o Alarme Rápido; em seguida dispararam os Alarmes de Média e Dispersão.

Neste exemplo, é possível ver, de maneira mais clara, a queda do indicador de dispersão abaixo do valor 0,9 e o aumento da amplitude da média.



**Figura 27 – Exemplo: gráfico para o Padrão 5, item 19.**

## 6.1. DISCUSSÕES – ASPECTOS GERAIS DAS SIMULAÇÕES

Verificamos que as simulações efetivadas no CEP-LPA demonstraram uma eficiência 93,57% na detecção de padrões não aleatórios, sendo que os dados não detectados possuem pequena magnitude, logo, previsto a uma não detecção até pelos sistemas estatísticos atuais. Os tempos na detecção também ficaram dentro de valores aceitáveis, para os casos apresentados, pois aconteceram ainda dentro do intervalo de 60 amostras.

Os resultados destes testes demonstram a notável propriedade de utilização da Lógica Paraconsistente através dos módulos compostos por Células Neurais Artificiais Paraconsistentes.

Destacamos neste trabalho a Unidade Neural Paraconsistente de Extração de Média Móvel (UNAPEmm) que foi aplicada em dois módulos principais do CEP-LPA; no Módulo de Média e no Módulo de Dispersão.

Verificamos que durante os testes e simulações em estruturas implementadas com estes módulos na forma do controlador CEP-LPA, tanto a eficiência de detecção, quanto o tempo, tiveram aspectos positivos. E, além disso, estas configurações permitiram o uso combinado de Alarme de Média, Dispersão e Rápido o que, pelo que sabemos, é inédito em aplicações nas quais são implementados os Controladores Estatísticos.

Como exemplo da eficiência do CEP-LPA, podemos citar que quando a variação era uma rampa que alterava o valor da média, o principal alarme a disparar foi o Alarme de **Média**, capaz de detectar pequenas variações na média mesmo que ela ocorra de forma gradativa. Já quando o problema foi a dispersão dos dados, os alarmes **Rápido** e de **Dispersão** foram os primeiros a atuar, sendo mais importante o Alarme de Dispersão.

Outro fato importante, que convém destacar na elaboração deste trabalho, é o uso do intervalo de evidência resultante  $\varphi_E$  no Módulo de Dispersão. Esta forma de implementação torna-se importante quando observamos a dispersão que pode não causar a ultrapassagem dos valores máximo e mínimo aceitáveis, e, neste caso, o Alarme Rápido atua de forma imediata causando problemas para a tomada de decisão.

A utilização do intervalo de evidência resultante  $\varphi_E$  foi executada por meio de uma Célula Neural Artificial Paraconsistente analítica (CNAPa), que tem em suas

entradas, o grau de evidência da média prevista e os dados normalizados pelo Módulo Extrator de Evidência. No decorrer das pesquisas verificamos que com a inclusão deste Módulo de análise Paraconsistente podemos obter na sua saída outro valor de intervalo de evidência resultante  $\varphi_E$  que sinaliza para o sistema como um fator de dispersão dos dados que estão em análise.

Verificamos com os resultados das simulações, que esta condição do intervalo de evidência resultante  $\varphi_E$  atuar como Fator de Dispersão, promove alto fator de eficiência; isto porque o grau de contradição ( $G_{ct}$ ) aumenta com o afastamento dos valores em análise com relação à média; e este fato deve ser sinalizado.

Com esta topologia o CEP-*LPA* torna-se robusto em suas análises, e esta técnica, utilizando o valor de intervalo de evidência resultante  $\varphi_E$ , será de extrema importância para futuros projetos de CEP- Controle Estatístico de Processos.

## 7. CONCLUSÕES

Este trabalho, que teve como objetivo principal aplicar os fundamentos da Lógica Paraconsistente Anotada em Controle Estatístico de Processo, alcançou essa meta com a elaboração de um sistema computacional denominado de Controlador Paraconsistente Estatístico de Processos – CEP-LPA. Segundo os testes elaborados, este sistema apresentou bom desempenho e traz uma topologia inovadora, pois foi totalmente construído com algoritmos que fazem os processamentos dos sinais utilizando os conceitos de Redes Neurais Artificiais Paraconsistente (RNAP).

Na sua estrutura, o CEP-LPA tem como elemento central um arranjo inédito de Células Neurais Artificiais Paraconsistentes de Aprendizagem (CNAPaps). Este arranjo foi denominado Unidade Neural Paraconsistente de Extração de Média Móvel (UNAPEmm) e mostra-se capaz de, através de um processo de aprendizagem, obter um valor de evidência que representa a média prevista dos sinais em análise, fato fundamental para o funcionamento do CEP-LPA com a eficiência apresentada.

A Lógica Paraconsistente Anotada, que possui a capacidade de tratar dados incertos ou paracompletos, foi aderente à criação desta aplicação que será muito útil em Controles Estatísticos de Processos. Um fato que devemos destacar é que a estrutura utilizada demonstra que com poucas CNAPs é possível criar um sistema robusto e eficiente. Este fato é importante para obtenção de um Controlador estatístico capaz de ser construído com baixos custos computacionais.

Os testes e resultados obtidos permite-nos afirmar que o CEP-LPA pode ser aplicado em um sistema supervisorio de qualquer natureza e é capaz de auxiliar, de maneira significativa, a tomada de decisão sobre a operação de controle estatístico de processo, evitando perdas de produção e aprimorando tomadas de decisões.

Destacamos, finalmente, que o desenvolvimento do CEP-LPA sinaliza um futuro promissor para as Lógicas não clássicas em aplicações na área de Controle Estatísticos de Processos, principalmente em sistemas *online*.

## 7.1. TRABALHOS FUTUROS

Apesar dos testes e validações do CEP-LPA feitos neste trabalho apresentarem bons resultados, para os futuros, serão necessários outros procedimentos para o aprimoramento do projeto. Portanto, seguem algumas sugestões para trabalhos futuros:

1. Estudo comparativo entre o CEP-LPA e outros Controles Estatísticos de Processo;
2. Aplicação em processos reais;
3. Criação de métodos para determinar os limiares ótimos dos alarmes para maximizar a detecção e minimizar os erros tipo I e II;
4. Melhorias na visualização gráfica dos resultados obtidos pelo CEP-LPA.

## REFERÊNCIAS BIBLIOGRÁFICAS

ABE, J. M. **Fundamentos da Lógica Anotada**. 1992. 135f. Tese (Doutorado em Filosofia) - Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 1992.

ABE, J. M. Lógica Paraconsistente. **Revista Seleção Documental**, n.1, a.1, p.5-10, 2006.

ALVES, C. C. **Gráficos de Controle CUSUM: um enfoque dinâmico para a análise estatística de processos**. 2003. 119f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2003.

BALESTRASSI, P. P. **Identificação de padrões em gráficos de controle estatístico de processos, em tempo real, utilizando séries temporais e redes neurais artificiais**. 2000. 170f. Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 2000.

BISHOP, C.M. **Neural Networks for Pattern Recognition**. 1. ed. Oxford University Press, 1995.

CAMPOS, V. F., **TQC: Controle da Qualidade Total**. 2 ed. Belo Horizonte: Fundação Christiano Ottoni, Escola de Engenharia da UFMG, 1992.

COSTA, A. F. B.; EPPRECHT, E. K.; CARPINETTI, L. C. R. **Controle estatístico de qualidade**. 2. ed. São Paulo: Atlas, 2012.

DA SILVA FILHO, J. I. **Métodos De Aplicações da Lógica Paraconsistente Anotada com anotação com dois valores (LPA2v) com construção de algoritmo e implementação de circuitos eletrônicos**. 1999. 226f. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais, São Paulo, 1999.

DA SILVA FILHO, J. I. Lógica Paraconsistente e Probabilidade Pragmática no Tratamento de Incertezas. **Revista Seleção Documental**, n.9, a.3, p.16-27, 2008.

DA SILVA FILHO, J. I.; ABE, J. M. **Fundamentos das redes neurais artificiais paraconsistentes – Destacando Aplicações em Neurocomputação**. São Paulo: Editora Arte & Ciência, 2001.

DA SILVA FILHO, J. I.; ABE, J. M.; LAMBERT-TORRES, G. **Inteligência artificial com as redes de análises paraconsistentes: teoria e aplicações**. 1. ed. Rio de Janeiro: LTC, 2008.

DA SILVA FILHO, J. I. et al. Estatística Descritiva Paraconsistente Aplicada ao Estudo de Poluição de Resíduos Sólidos em Ambiente Costeiro Marinho. **Revista Seleção Documental**, n.26, a.7, p.3-12, 2012.

DAMIN, O. C. B.; DA SILVA FILHO, J. I. Utilização da Distribuição de Frequência Estatística Associada à Lógica Paraconsistente Anotada de 2 valores: o Modelo de dois Peritos em Vistorias de Engenharia. **Revista Seleção Documental**, n.26, a.7, p.13-20, 2012.

FABER, B.; LARSON, R., **Estatística Aplicada**. 4. ed. São Paulo: Pearson Prentice Hall, 2010.

FACCIO, K.; WERNER, L. Comparando gráfico CUSUM e Redes Neurais Artificiais no contexto do Controle Estatístico de Qualidade. **INGEPRO – Inovação, Gestão e Produção**, 2010, vol. 20, nº. 11.

HENNING, E.; FERNANDES, E. S.; KONRATH, A. C.; et al, **Gráficos de Controle Shewhart, CUSUM, EWMA e combinado Shewhart-CUSUM: uma proposta de monitoramento para implantação do Controle Estatístico do Processo**. Ponta Grossa, III Congresso Brasileiro de Engenharia de Produção, 27 a 29 de novembro de 2013.

LOPES, H. F. S. **Aplicação de redes neurais artificiais paraconsistentes como método de auxílio no diagnóstico de doença de Alzheimer**. 2009. 73f. Dissertação (Mestrado) – Faculdade de Medicina da Universidade de São Paulo. Departamento de Neurologia, São Paulo, 2009.

MENDES, F. C. T. **Gráfico de controle EWMA para não-conformidades com intervalo de tempo entre amostras variável**. 2004. 137f. Tese (Doutorado Engenharia de Produção) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, Rio de Janeiro, 2004,

MONTGOMERY, D. C. **Introdução ao controle estatístico da qualidade**. 4. ed. Rio de Janeiro: LTC, 2012.

RIBEIRO, J. L. D.; CATEN, C. S. T. **Série monográfica Qualidade Controle Estatístico do Processo Cartas de Controle para Variáveis, Cartas de Controle para Atributos, Função de Perda Quadrática, Análise de Sistemas de Medição.** FEENG/UFRGS – Fundação Empresa Escola de Engenharia da UFRGS Universidade Federal do Rio Grande do Sul Escola de Engenharia Programa de Pós Graduação em Engenharia de Produção, Porto Alegre, RS, 2012.

SHABAN, A.; et al. *Automated Identification of Basic Control Charts Patterns Using Neural Networks*, **J. Software Engineering & Applications**, 2010, 3: p.208-220. 2010

SHEWHART, W. A. **Quality Control**. Bell System Technical Journal, p.722-735, 1926.

SOUZA, P. R. S. **Métodos de apoio a decisão médica para análise em diabetes Mellitus gestacional utilizando a probabilidade pragmática na lógica paraconsistente anotada de dois valores para melhor precisão de resposta.** 2009. 153f. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Telecomunicações e Controle, São Paulo, 2009.

SOUZA, S. **Sistema de reconhecimento de caracteres numéricos manuscritos baseado nas redes neurais artificiais paraconsistentes.** 2013. 71f. Dissertação (Mestrado) – Faculdade de Medicina da Universidade de São Paulo. Programa de Fisiopatologia Experimental, São Paulo, 2013.

SUBRAHMANIAN, V.S. **On the semantics of quantitative Logic programs.** *Proc. 4 th. IEEE Symposium on Logic Programming*, computer Society Press, Washington D.C., 1987.

WESTERN ELECTRIC. **Statistical Quality Control Handbook.** 2nd. Indianapolis: Western Electric Company, 1958.