

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA DE PRODUÇÃO

ESTUDO DOS MÉTODOS DE DETECÇÃO DE
MUDANÇAS EM MODELOS DE PREVISÃO DE
SÉRIES TEMPORAIS

DANIELLE MAYUMI CAMPOS TAMAKI

Itajubá, fevereiro de 2016

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA DE PRODUÇÃO

DANIELLE MAYUMI CAMPOS TAMAKI

ESTUDO DOS MÉTODOS DE DETECÇÃO DE
MUDANÇAS EM MODELOS DE PREVISÃO DE
SÉRIES TEMPORAIS

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do **Título de Mestre em Ciências em Engenharia de Produção.**

Área de Concentração: Qualidade e Produto

Orientador: Prof. Dr. Pedro Paulo Balestrassi

Itajubá, fevereiro de 2016

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA DE PRODUÇÃO

DANIELLE MAYUMI CAMPOS TAMAKI

ESTUDO DOS MÉTODOS DE DETECÇÃO DE
MUDANÇAS EM MODELOS DE PREVISÃO DE
SÉRIES TEMPORAIS

Dissertação aprovada por banca examinadora em 19 de fevereiro de 2016, conferindo ao autor o título de **Mestre em Ciências em Engenharia de Produção.**

Banca Examinadora:

Prof. Dr. Ronã Rinston Amaury Mendes
(IFSULDEMINAS)

Prof. Dr. Paulo Henrique da Silva Campos (UNIFEI)

Prof. Dr. Pedro Paulo Balestrassi (UNIFEI)

Itajubá, fevereiro de 2016

Dedico este trabalho...

A Deus, aos meus pais, Carlos Minoru e Ana Maria, aos meus irmãos e a toda minha família que sempre me apoiou. Dedico também em especial ao Danillo que foi essencial nesta minha trajetória.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me criado, me dado vida e sabedoria para seguir meus sonhos e ter tido a oportunidade de ingressar e concluir o Mestrado. Ao meu Senhor Jesus Cristo, que sendo meu Senhor, ordenou minha vida, brotando sempre em mim o desejo de santidade e de viver em seu amor. E por fim a Maria Santíssima, pelo exemplo e segurança em minha vida.

Agradeço aos meus pais, Carlos Minoru e Ana Maria, que através do exemplo e da educação que me deram, me proporcionaram chegar onde estou. A toda motivação que deram em todas as etapas de minha vida, me ensinando o caminho correto, me corrigindo quando era necessário e ajudando a suportar a todas as dificuldades.

Aos meus irmãos e cunhadas, por todo companheirismo, carinho, motivação e incentivo nesta minha jornada.

Agradeço ao Danillo, por estar sempre ao meu lado me apoiando e sendo essencial pelo início e pelo término desta etapa. Obrigada por toda força e incentivo em todos os momentos, suportando minhas dificuldades, me aconselhando e me dando o carinho necessário para continuar.

Ao meu orientador, Pedro Paulo Balestrassi, por ter acreditado em mim desde o início, sempre me inspirando e motivando. Obrigada por ser este grande mestre, que com humildade e sabedoria me guiou para o bom êxito deste trabalho.

Agradeço também a todos meus amigos e a todos os professores da Universidade Federal de Itajubá. E por fim, agradeço a CAPES, CNPq e a FAPEMIG pelo incentivo e apoio a pesquisa.

EPÍGRAFE

“Tudo quanto fizerdes, por palavra ou por obra, fazei-o em nome do Senhor Jesus, dando por ele graças a Deus Pai.”

Colossenses 3,23

“Todas as coisas concorrem para o bem daqueles que amam a Deus.” Romanos 8,28

RESUMO

Os modelos estatísticos de previsão são ferramentas importantes que ajudam a antecipar futuros cenários. Assim, estes contribuem para o planejamento, dimensionamento e alocação de recursos que permitem a redução de custos decorrentes de decisões equivocadas. Utilizar estes modelos tem como objetivo central prever acontecimentos futuros com o propósito de reduzir o risco na tomada de decisão. Entretanto, para utilizá-los é necessário que se faça um bom projeto de sistema de previsão. Aliado a este projeto, é essencial que existam procedimentos que ajudem na avaliação e no monitoramento de seu desempenho ao longo do tempo. Não importa quanto esforço foi realizado no desenvolvimento do modelo de previsão e o quão eficiente é o modelo inicialmente, com o tempo é provável que o desempenho deste modelo se deteriore. As previsões são realizadas com base em séries temporais e para monitorá-las é necessário utilizar os erros que essas previsões geram. Estes erros, que também geram séries temporais, são avaliados de acordo com diversos métodos. Portanto, para saber se uma previsão continua eficiente, é necessário monitorar os seus erros e, caso apresente mudanças, de acordo com os métodos de avaliação, será necessário refazer a previsão. Esta dissertação apresenta o estudo comparativo dos métodos que fazem o monitoramento dos modelos de previsão. Os métodos estudados são as cartas de controle de média móvel exponencialmente ponderada (EWMA), carta de controle de soma acumulada (CUSUM) e os Tracking Signals (TS). O objetivo deste estudo é identificar o melhor método para a detecção de séries lineares e analisar, através da simulação, qual o melhor método e também estabelecer regras e/ou padrões dessas detecções, fazendo a combinação do método com a carta farol. Para isso foram utilizadas e simuladas as séries temporais lineares e não lineares. As séries temporais lineares demonstram que a previsão está sob controle e as séries não lineares apresentam o pior cenário de uma previsão. Neste estudo foram realizados testes com a junção de séries lineares e não lineares no ponto determinado para verificar se os métodos eram capazes de detectar essa mudança. Foram realizadas quatro etapas para o estudo, sendo a última etapa a mais importante na combinação da carta farol com o TS. A conclusão presente na dissertação aponta que o Tracking Signal possui um desempenho superior quando combinado com a carta farol.

Palavras-chave: previsão de séries, *Tracking signal*, *Carta CUSUM*, *Carta EWMA*, *carta farol*

ABSTRACT

Statistical forecasting models are important tools that help anticipate future scenarios. Thus, they contribute to the planning, design and allocation of resources that enable the reduction of costs resulting from bad decisions. Using these models is mainly aimed to predict future events in order to reduce risk in decision making. However, to use it is necessary to make a good prediction system design. Allied to this project, it is essential that there are procedures to assist in the evaluation and monitoring of performance over time. No matter how much effort was made in the development of the forecasting model and how efficient is the model initially, over time it is likely that the performance of this model from deteriorating. Forecasts are made based on time series and to monitor them is necessary to use the errors that generate these predictions. These errors, which also generate time series, are evaluated according to several methods. Therefore, to know if a forecast remains effective, it is necessary to monitor their mistakes and, if present changes, according to the evaluation methods, you need to redo the forecast. This work presents a comparative study of the methods that make monitoring of predictive models. The methods studied are the exponentially weighted moving average control charts (EWMA), cumulative sum control chart (CUSUM) and the Tracking Signals (TS). The objective of this study is to identify the best method for detecting linear series and analyze, through simulation, the best method and also establish rules and/or standards of these detections, making the combination of the method with the pre-control chart. To this were used and the series simulated linear and nonlinear temporal. Linear time series show that the forecasting is under control and the non-linear series present the worst case scenario of a forecast. In this study tests were performed with a mixture of linear and non-linear series in the given point to check if the methods could detect this change. Four steps were taken for the study, the latter being the most important step in combining lighthouse letter with TS. The conclusion in this thesis points out that the Tracking Signal has superior performance when combined with the pre-control chart.

Keywords: forecasting series, *Tracking signal*, CUSUM Chart, EWMA Chart, pre-control chart

LISTA DE FIGURAS

Figura 1.1 - Resumo Gráfico do Problema de Pesquisa _____	17
Figura 2.1 - Processo de previsão _____	20
Figura 2.2 - Resultado de uma análise CUSUM realizada para uma série temporal ____	26
Figura 2.3 - Resultado de uma análise EWMA realizada para uma série temporal ____	28
Figura 2.4 - Versões do Tracking Signal _____	30
Figura 2.5 - Tolerância bilateral _____	40
Figura 2.6 - Tolerância unilateral _____	41
Figura 3.1 - Classificação do método de Pesquisa _____	42
Figura 4.1 - Etapas para o desenvolvimento da dissertação _____	44
Figura 4.2 - Passos para a realização da pesquisa em cada uma das etapas _____	44
Figura 4.3 - Série teste _____	45
Figura 4.4 - Série teste (série linear + série não linear) para o modelo não linear SAR	46
Figura 4.5 - Carta de Controle EWMA para a série teste do modelo não linear SAR _	47
Figura 4.6 - Carta de Controle CUSUM para a série teste do modelo não linear SAR	48
Figura 4.7 - BoxPlot da quantidade de pontos fora de controle encontrados _____	51
Figura 4.8 – Gráfico de probabilidades da quantidade de pontos fora de controle encontrados _____	52
Figura 4.9 - Dotplot dos primeiros pontos encontrados como fora de controle _____	53
Figura 4.10 - Gráficos dos valores individuais dos primeiros pontos encontrados como fora de controle _____	53
Figura 4.11 – Gráfico de probabilidades dos primeiros pontos fora de controle encontrados _____	54
Figura 4.12 - Teste de duas proporções para a quantidade de falsos alarmes _____	56
Figura 4.13 - Gráfico de pizza para a quantidade de falsos alarmes _____	57
Figura 4.14 - Gráfico de valores individuais para a quantidade de falsos alarmes ____	57
Figura 4.15 - Teste de duas proporções para a quantidade de falhas de detecção ____	58
Figura 4.16 - Gráfico dos valores individuais para a quantidade de falhas de detecção dos métodos _____	59
Figura 4.17 - Gráfico de probabilidades da quantidade de falhas de detecção _____	59
Figura 4.18 – Gráfico de Dispersão para os falsos alarmes e as falhas de detecção dos métodos _____	60

Figura 4.19 - Série teste (série linear + série não linear) para o modelo não linear SAR	61
Figura 4.20 – Gráfico de Dispersão para TS de Brown	63
Figura 4.21 – Gráfico de Dispersão para TS de Brown-Gardner	64
Figura 4.22 - BoxPlot de Falsos Alarmes para TS de Brown-Ravi	66
Figura 4.23 - BoxPlot de Falhas de Detecção para TS de Brown-Ravi	66
Figura 4.24 – Gráfico de Dispersão para TS de Brown-Ravi	67
Figura 4.25 – Gráfico de Dispersão para TS de Trigg	68
Figura 4.26 - Scatterplot para TS de Trigg-Gardner	69
Figura 4.27 – Gráfico de Dispersão da quantidade de falsos alarmes e falhas de detecção dos métodos	71
Figura 4.28 - Algoritmo da carta farol	73
Figura 4.29 – Gráfico de Dispersão de falsos alarmes e falhas de detecção	75
Figura 4.30 - Gráfico comparativo de falsos alarmes	76
Figura 4.31 - Gráfico comparativo de falhas de detecção	76
Figura 4.32 - Teste Paired-T para a quantidade de falsos alarmes	77
Figura 4.33 - Teste Paired-T para a quantidade de falhas de detecção	77
Figura 4.34 - Teste Two-Sample T para falsos alarmes	78
Figura 4.35 - Gráfico dos valores individuais dos falsos alarmes	78
Figura 4.36 - BoxPlot dos valores de falsos alarmes	79
Figura 4.37 - Teste Two-Sample T para falhas de detecção	79
Figura 4.38 - Gráfico dos valores individuais das falhas de detecção	80
Figura 4.39 - BoxPlot dos valores de falhas de detecção	80

LISTA DE TABELAS

Tabela 2.1 - Modelos não lineares – adaptado de Balestrassi et al.2009)	23
Tabela 2.2 - Carta Farol.....	40
Tabela 4.1 - Parte dos Resultados do teste TS para o modelo não linear SAR.....	49
Tabela 4.2 - Resultado do Teste do TS para o modelo não linear SAR	50
Tabela 4.3 - Resultado da porcentagem de pontos encontrados como fora de controle em cada método.....	50
Tabela 4.4 - Quantidade total de falsos alarmes encontrados nos métodos	55
Tabela 4.5 - Quantidade total de falhas de detecção dos métodos	58
Tabela 4.6 - Soma total dos valores para os testes de Brown-Ravi.....	65
Tabela 4.7 - Resultados dos testes	70
Tabela 4.8 - Sequência dos falsos alarmes	72
Tabela 4.9 - Resultado da aplicação da carta Farol no TS de Brown 0,2.....	74
Tabela 4.10 - Total de pontos	75

LISTA DE ABREVIATURAS E SIGLAS

EWMA	<i>(Exponentially Weighted Moving Average)</i> – Média Móvel Exponencialmente Ponderada
CUSUM	<i>(Cumulative Sum Control)</i> – Controle de Soma Acumulada
TS	<i>(Tracking Signal)</i> – Sinal de Rastreamento
CUSUMTS	<i>Tracking Signal</i> proposto por Brown
GTS	Modificação de Gardner do <i>Tracking Signal</i> proposto por Brown(1959)
SCALEDTS	<i>Tracking Signal</i> proposto por Ravi
TTS	<i>Tracking Signal</i> proposto por Trigg
GTTS	Modificação de Gardner do <i>Tracking Signal</i> proposto por Trigg(1964)

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Problema de pesquisa.....	16
1.2 Objetivos.....	17
1.2.1 Objetivo Geral	17
1.2.2 Objetivos Específicos	17
1.3 Estrutura da Dissertação	18
2. FUNDAMENTAÇÃO TEÓRICA.....	19
2.1 Considerações Iniciais	19
2.2 Previsão	19
2.2.1 Monitoramento de Previsão.....	21
2.2.2 Séries temporais.....	22
2.2.2.1 Séries temporais lineares e não lineares	22
2.3 Cartas de Controle	23
2.3.1 Carta de Controle CUSUM	24
2.3.1.1 Técnica de Soma Acumulada - CUSUM.....	24
2.3.1.2 Carta de Controle - CUSUM	25
2.3.2 Carta de Controle EWMA	27
2.4 Tracking Signal	29
2.4.1 Tracking Signal de Brown	31
2.4.2 Tracking Signal de Brown-Gardner	33
2.4.3 Tracking Signal de Brown-Ravi	33
2.4.4 Tracking Signal de Trigg	35
2.4.5 Tracking Signal de Trigg-Gardner	37
2.5 Falsos Alarmes e Falhas de Detecção.....	37
2.6 Carta Farol ou Pré-Controle	39
2.7 Considerações Finais	41
3. METODOLOGIA DE PESQUISA	42
3.1 Considerações Iniciais	42
3.2 Classificação da Pesquisa Científica	42
3.2.1 Método de Pesquisa: Simulação	43
3.3 Desenvolvimento da Análise da Pesquisa	43
3.4 Considerações Finais	43
4. APLICAÇÃO DO MÉTODO.....	44

4.1 Considerações Iniciais	44
4.2 Definição da Simulação e dos Testes.....	44
4.2.1 Objetivos dos testes	45
4.3 ETAPA 1 – Carta CUSUM X Carta EWMA X TS.....	45
4.3.1 PASSO 1: Criação das séries lineares e não lineares	45
4.3.1.1 Séries lineares	45
4.3.1.2 Séries não lineares	45
4.3.2 PASSO 2: Testes	46
4.3.2.1 Carta de Controle EWMA	46
4.3.2.2 Carta de Controle CUSUM	47
4.3.2.3 Tracking Signal	48
4.3.3 PASSO 3: Análise dos Resultados	50
4.3.3.1 Análise da Quantidade de Pontos Encontrados	50
4.3.3.2 Análise do Primeiro Ponto Fora de Controle Encontrado	52
4.3.4 Considerações Finais	54
4.4 ETAPA 2 – Carta CUSUM X TS	55
4.4.1 PASSO 1: Criação das séries lineares e não lineares	55
4.4.2 PASSO 2: Testes	55
4.4.3 PASSO 3: Análise dos Resultados	55
4.4.3.1 Análise de Falso Alarme	55
4.4.3.2 Análise das Falhas de Detecção.....	58
4.4.4 Considerações Finais	60
4.4 ETAPA 3 – Versões do <i>Tracking Signal</i>	61
4.4.1 PASSO 1: Criação das séries lineares e não lineares	61
4.4.1.1 Séries lineares	61
4.4.1.2 Séries não lineares	61
4.4.2 PASSO 2: Testes	62
4.4.2.1 TS de Brown.....	62
4.4.2.1.1 TS de Brown com Alpha 0,1	62
4.4.2.1.2 TS de Brown com Alpha 0,2	62
4.4.2.1.3 Comparação de Resultados.....	62
4.4.2.2 TS de Brown-Gardner	63
4.4.2.2.1 TS de Brown-Gardner com Alpha 0,1	63
4.4.2.2.2 TS de Brown-Gardner com Alpha 0,2.....	63
4.4.2.2.3 Comparação de Resultados.....	63

4.4.2.3 TS de Brown-Ravi	64
4.4.2.3.1 Comparação de Resultados.....	64
4.4.2.4 TS de Trigg.....	67
4.4.2.4.1 TS de Trigg com Alpha 0,1	67
4.4.2.4.2 TS de Trigg com Alpha 0,2	67
4.4.2.4.3 Comparação de Resultados.....	67
4.4.2.5 TS de Trigg-Gardner	68
4.4.2.5.1 TS de Trigg-Gardner com Alpha 0,1	68
4.4.2.5.2 TS de Trigg-Gardner com Alpha 0,2.....	68
4.4.2.4.3 Comparação de Resultados.....	69
4.4.3 PASSO 3: Análise dos Resultados	69
4.4.4 Considerações Finais	70
4.5 ETAPA 4 - Carta Farol e Aplicação no Método de Brown	71
4.5.1 PASSO 1: Análise das Séries Testadas	71
4.5.2 PASSO 2: Criação das Regras da Carta Farol.....	73
4.5.3 PASSO 3: Testes	73
4.5.4 PASSO 4: Análise dos Resultados	75
4.5.5 Considerações Finais	81
5. 5. CONCLUSÕES.....	82
5.1 Sugestões para Trabalhos Futuros.....	83
APÊNDICE A – RESULTADO TS PARA MODELO NÃO LINEAR SAR.....	84
APÊNDICE B – RESULTADOS DOS TESTES DA ETAPA 1 – CUSUM X	
EWMA X TS.....	87
APÊNDICE C – RESULTADO PARA FALSO ALARME E FALHAS DE	
DETEÇÃO: CUSUM X TS.....	91
APÊNDICE D – RESULTADO PARA TS DE BROWN (ALPHA = 0,1)	95
APÊNDICE E – RESULTADO PARA TS DE BROWN (ALPHA = 0,2).....	96
APÊNDICE F – RESULTADO PARA TS DE BROWN-GARDNER (ALPHA =	
0,1).....	97
APÊNDICE G – RESULTADO PARA TS DE BROWN-GARDNER (ALPHA =	
0,2).....	98
APÊNDICE H – RESULTADO PARA TS DE BROWN-RAVI.....	99
APÊNDICE I – RESULTADO PARA TS DE TRIGG (ALPHA = 0,1)	101
APÊNDICE J – RESULTADO PARA TS DE TRIGG (ALPHA = 0,2).....	102

APÊNDICE K – RESULTADO PARA TS DE TRIGG-GARDNER (ALPHA = 0,1)	
.....	103
APÊNDICE L – RESULTADO PARA TS DE TRIGG-GARDNER (ALPHA = 0,2)	
.....	104
APÊNDICE M – PONTOS DE FALSO ALARME	105
REFERÊNCIAS	107

1. INTRODUÇÃO

Os modelos estatísticos de previsão cada vez mais são utilizados por empresas, pois são ferramentas importantes na antecipação de cenários. Esta antecipação é essencial, pois contribui para o dimensionamento, planejamento e alocação de recursos que ajudam a reduzir os riscos de tomadas de decisões, ou até mesmo reduzir riscos de decisões que foram tomadas de forma errada.

De acordo com Veríssimo *et al.* (2012), os métodos estatísticos de previsão são utilizados com o objetivo central de prever futuros acontecimentos com o principal propósito de reduzir os riscos de tomadas de decisões. Ou seja, prever é uma das ações mais importantes no que se refere a decisões, e por este motivo, a qualidade das previsões é essencial dentro de uma organização.

Estes modelos estatísticos de previsão podem ser utilizados em diversas áreas dentro de uma organização e segundo Cruz *et al.* (2014), são as áreas de uma empresa como planejamento de produção, gestão de inventário, escalonamento de recursos humanos, controles de processos e outras. Ainda segundo os autores Montgomery, Jennings e Kulahci (2011) a previsão de eventos futuros também é aplicada em áreas como *Marketing*, gerenciamento de operações, demografia, finanças, gestão de riscos, controle de processos industriais e na economia.

Existem várias formas para controlar o desempenho de modelos de previsão. A maneira mais simples é aplicar gráficos de controle para monitorar os erros de previsão. Os gráficos de controle, também conhecidos como cartas de controle, estudados neste trabalho, são a carta de controle de média exponencialmente ponderada (EWMA) e a carta de controle de soma acumulada (CUSUM), que serão mais detalhadas ao longo do trabalho.

Muitos são os trabalhos que envolvem as análises sobre os gráficos de controle. Entretanto, outro método que vem ganhando destaque são os *Tracking Signals* (TS). A grande diferença entre as cartas de controle e os *Tracking Signals* é que estes não estão disponíveis em softwares e não utilizam gráficos para a visualização das anormalidades. Entretanto, Jardim (2013) realizou uma comparação entre estes métodos e apresentou que para as situações apresentadas em seu estudo, o método *Tracking Signal* apresentava ser mais eficiente na detecção de viés que os demais métodos.

O objetivo deste trabalho é realizar o comparativo dos métodos de monitoramento de um modelo de previsão, o EWMA, o CUSUM e o TS. Para realizar o monitoramento

em uma previsão, é necessário utilizar os erros de previsão. Portanto, este trabalho não tem como propósito realizar previsões, mas estudar os seus resultados. Por isso, os procedimentos adotados neste estudo foram as simulações de séries temporais. Quando um modelo de previsão está sob controle pode-se afirmar que os erros possuem um comportamento de uma série temporal linear. Já se o modelo não está sob controle ele possui o comportamento de uma série temporal não linear.

Assim, para realizar este trabalho, os procedimentos adotados iniciaram com a simulação de séries normais geradas aleatoriamente e séries não lineares que foram geradas de acordo com os modelos propostos. Estes modelos foram estudados e apresentados no trabalho de Balestrassi *et al.* (2009) e segundo os autores, modelos de séries temporais foram escolhidos porque representam uma variedade de problemas que possuem diferentes características. Foi realizada uma junção nestas séries em um ponto estratégico estabelecido para que fosse possível o seu estudo das mesmas com os métodos propostos. Além disso, neste trabalho também foi realizado uma simulação da combinação com o melhor método encontrado e com carta de controle farol com o objetivo de aprimorar ainda mais o método.

1.1 Problema de pesquisa

Para ilustrar o problema de pesquisa, a Figura 1.1, mostra o processo de um modelo de previsão. O primeiro quadrado da Figura 1.1 mostra os problemas de séries temporais que serão previstas através de um previsor, ou método de previsão. Entretanto, como mencionado anteriormente, é necessário verificar se a previsão está sob controle ou se ela precisa ser refeita para que não corram riscos em tomadas de decisões.

Para fazer o monitoramento de previsão, é necessário analisar os resíduos das previsões, que são os erros de previsão. Estes erros de previsão são utilizados na análise de cada método de detecção de mudanças.

Como mencionado anteriormente, serão utilizados os métodos escolhidos: carta de controle EWMA, a carta de controle CUSUM e o método do TS. Por essa variedade de métodos, o trabalho irá determinar qual dos três métodos possui o melhor desempenho para o problema levantado: as séries não lineares, que representam o pior cenário de uma previsão. Assim, caso o método detecte mudanças, ele irá sinalizar que o modelo de previsão precisa ser refeito.

Portanto, o problema a ser abordado por esta dissertação consiste em responder as questões:

- Qual método de previsão possui o melhor desempenho?
- Como aprimorar o desempenho dos métodos?

Resumo gráfico

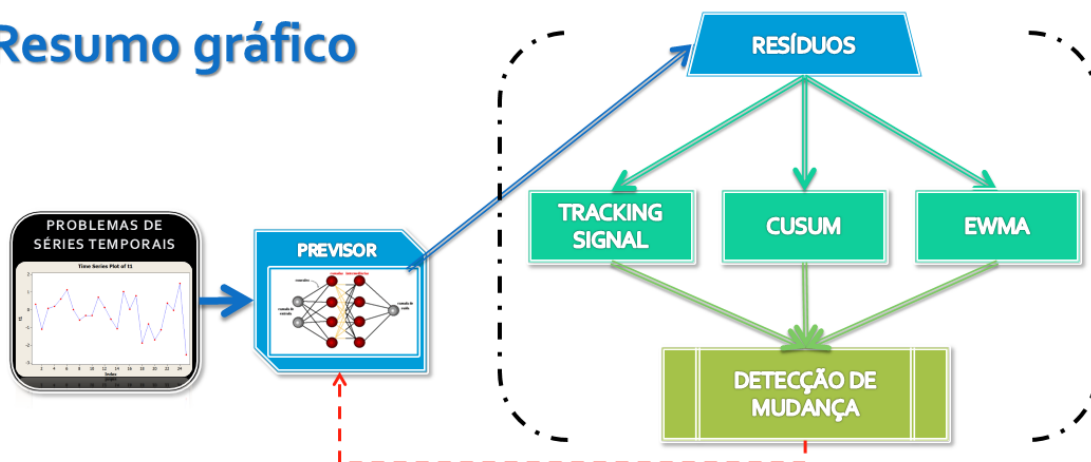


Figura 1.1 - Resumo Gráfico do Problema de Pesquisa

1.2 Objetivos

De acordo com Appolinário (2006), de uma maneira geral, o objetivo de uma pesquisa é responder a um problema formulado. O objetivo pode ser dividido em dois principais níveis: geral e específicos. Neste trabalho serão definidos um objetivo geral e três específicos.

1.2.1 Objetivo Geral

Este trabalho tem como objetivo geral estudar os métodos de detecção de mudanças em previsão de séries temporais, identificando e analisando, através da simulação, qual o melhor método e também estabelecer regras e/ou padrões dessas detecções.

1.2.2 Objetivos Específicos

Os objetivos específicos desta pesquisa são:

- Analisar quais os dois melhores métodos de detecção de mudanças em séries temporais entre os três métodos estudados: Carta de Controle EWMA, Carta de Controle CUSUM e TS.
- Analisar, entre os dois métodos escolhidos, qual o melhor método através da análise de falsos alarmes e falhas de detecção.

- Com o melhor método identificado, analisar e estudar as suas variações e verificar qual a melhor variação para as simulações realizadas.

1.3 Estrutura da Dissertação

A dissertação é estruturada em cinco capítulos.

O primeiro capítulo apresentou a introdução e a contextualização sobre o tema, juntamente com o problema de pesquisa e os objetivos da dissertação.

O capítulo 2 trata sobre a fundamentação teórica do trabalho. Este capítulo tem por embasamento estudos encontrados em livros, artigos de periódicos, artigos de congressos da área de pesquisa, dissertações de mestrado e teses de doutorado. A base teórica contempla conceitos importantes na área de previsão e toda a base dos métodos de detecção de mudanças em séries temporais, além de conceitos e a base utilizada no trabalho das séries temporais não lineares.

O capítulo 3 apresenta a metodologia de pesquisa utilizada, que é a simulação das séries temporais lineares e não lineares e os testes que serão realizados em cada um dos métodos de detecção de mudanças de séries temporais.

A aplicação do método é apresentada no quarto capítulo que está dividido em etapas. O primeiro item possui as considerações iniciais e o segundo a definição de como foram realizadas as simulações e quais são os objetivos dos testes realizados. Os itens seguintes detalham cada uma das quatro etapas realizadas no trabalho. A primeira etapa é a comparação dos três métodos apresentados: CUSUM, EWMA e TS. A segunda etapa possui o comparativo dos dois métodos que tiveram um desempenho superior: CUSUM e TS. A terceira etapa possui um comparativo das versões do método que obteve o melhor desempenho: o TS. E a quarta etapa possui o estudo da versão do método que obteve melhor desempenho, a análise e o desenvolvimento das regras da carta farol e a sua aplicação no método em questão. Por fim, são realizadas as devidas análises e conclusões dos testes aplicados.

O último capítulo, o capítulo 5, encerra a dissertação, com as conclusões e as sugestões para as pesquisas futuras.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Considerações Iniciais

O Capítulo 2 apresenta uma visão crítica das pesquisas que envolvem o objeto de estudo: previsão e os métodos de detecção de mudanças de séries lineares.

Inicialmente, a fundamentação teórica embasa o trabalho apresentando o conceito sobre previsão, o que é um sistema de previsão e porque a importância de se utilizar os métodos de detecção de mudanças neste sistema. Em seguida, são apresentadas as considerações sobre cada um dos métodos, quais são os principais trabalhos relacionados e suas principais versões.

2.2 Previsão

As previsões são, por definição, imperfeições do futuro (MCCLAIN e THOMAS, 1991).

Cada vez mais utilizados por empresas, os modelos estatísticos de previsão são importantes ferramentas que auxiliam na antecipação de situações e assim contribuem para o planejamento, dimensionamento e alocação de recursos que ajudam a reduzir os custos desnecessários que são decorrentes de decisões erradas. Segundo Cruz *et al.* (2014), estes modelos são utilizados em diversas áreas de uma empresa como planejamento de produção, gestão de inventário, escalonamento de recursos humanos, controles de processos e outras.

Montgomery, Jennings e Kulahci (2011) também revelam que a previsão de eventos futuros também é aplicada em áreas como *Marketing*, gerenciamento de operações, demografia, finanças, gestão de riscos, controle de processos industriais e na economia.

Segundo Veríssimo *et al.* (2012), a utilização dos métodos de previsão tem como objetivo central prever acontecimentos futuros com o propósito de reduzir o risco na tomada de decisão. Prever constituiu-se em uma importante ação no que se refere a tomadas de decisões dentro de uma empresa e por isso a qualidade das previsões é essencial.

Nos últimos anos foram desenvolvidos diversos métodos de previsão. De acordo com Gooijer e Hyndman (2006), uma variedade de métodos como Redes Neurais, modelos de regressão, sistemas especialistas, lógica *fuzzy*, e algoritmos de aprendizagem estatísticas são usados, normalmente, para previsões de curto-prazo. Segundo Campos

(2008), o desenvolvimento, as melhorias e as investigações de ferramentas que auxiliem os métodos, tem levado ao aprimoramento das técnicas de previsão, fazendo com que sejam cada vez mais precisas.

Os modelos de previsão são divididos em médio e longo-prazos e de curto prazo. Para os modelos de médio e longo-prazo, são utilizados com mais frequência, segundo Gooijer e Hyndnman (2006), os modelos econométricos e os modelos de aprendizagem estatística. Para os métodos de curto prazo são utilizados, segundo Campos (2008) os métodos de regressão, séries temporais, redes neurais, sistemas especialistas, lógica *fuzzy* e máquinas de vetores de suporte (SVM).

A pesquisa não tem como objetivo estudar os métodos de previsão, mas analisar a etapa final do processo. Portanto, o processo de previsão constituiu-se em uma série de atividades relacionadas que são ilustradas na Figura 2.1.

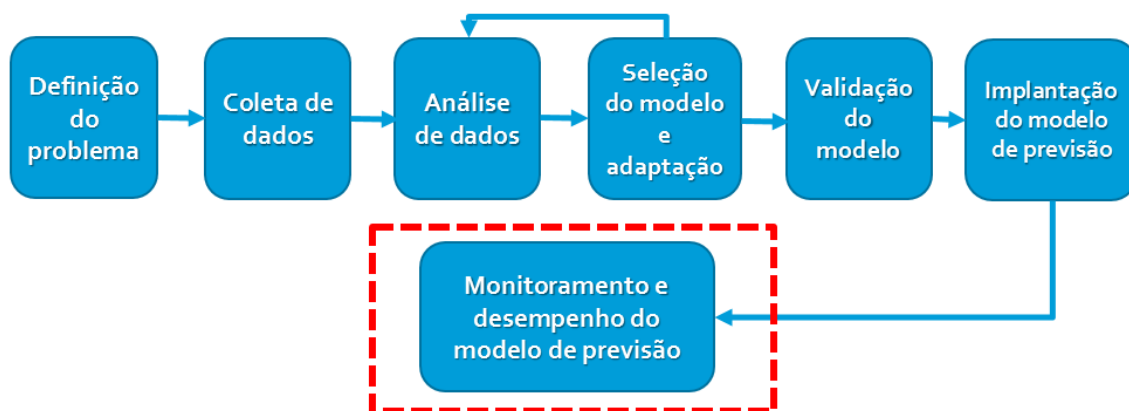


Figura 2.1 - Processo de previsão

Fonte: Adaptado de Montgomery, Jennings e Kulahci (2011).

Existem diversas atividades, com ilustra a figura acima, para realizar uma previsão. Entretanto, o foco deste trabalho é a última etapa do processo, o monitoramento e desempenho do modelo. Como mostrado acima, para um bom projeto de sistema de previsão é necessário que existam procedimentos que ajudem na avaliação e o monitoramento de seu desempenho ao longo do tempo.

Segundo Montgomery, Jennings e Kulahci (2011), o desenvolvimento e a programação de procedimentos que monitorem o desempenho de um modelo de previsão é um dos componentes essenciais para que se tenha um sistema de previsão satisfatório. Os autores ainda afirmam que não importa o quanto esforço foi realizado no desenvolvimento do modelo de previsão e o quão eficiente é o modelo inicialmente, com o tempo é provável que o desempenho deste modelo se deteriore, pois, os padrões das séries temporais podem variar. Estes padrões podem mudar por diversos motivos, como

forças internas que evoluem ao longo do tempo ou eventos externos que ocorrem e modificam os padrões iniciais da série.

2.2.1 Monitoramento de Previsão

De acordo com Gardner (1985), o objetivo do monitoramento de previsão é detectar os erros tendenciosos o mais rápido possível. Gardner (1983) também afirma que na maioria dos sistemas de monitoramento, os erros de previsão devem ser detectados automaticamente para garantir que o sistema permaneça sobre controle. Ele afirma que mudanças nas médias, ou as tendências e sazonalidades devem ser detectadas rapidamente para garantir que o modelo de previsão readapte aos novos dados ou que ele seja alterado para um novo modelo.

Trigg (1964) afirma que é importante incorporar alguma forma de monitoramento automático de controle de previsão para garantir que o sistema permaneça em controle. Segundo o exemplo do autor, se um simples sistema de suavização exponencial de primeira ordem for aplicado a uma série temporal com uma tendência, a previsão terá consistentemente uma *lag*, ou também a existência de insuspeitas variações sazonais podem causar erros tendenciosos. É desejável sentir, ou seja, detectar estas situações o mais rápido possível para que um melhor e mais apropriado sistema de previsão seja introduzido.

Segundo Deng, Jaraiedi e Iskander (2004), monitoramento é um aspecto essencial em qualquer sistema de previsão e é especialmente importante para sistemas de previsão de séries temporais desde que tenha a garantia de que os comportamentos anteriores e as características do sistema se manterão no futuro.

As técnicas de monitoramento estatístico são utilizadas em diversas áreas de conhecimento. Segundo Avent *et al.* (1987), essas técnicas como o CUSUM e o TS, e outras, possuem vantagens em relação à simplicidade. Em muitas aplicações de biomedicina, como implantação de dispositivos eletrônicos, essas técnicas simples ganham bastante utilidade porque reduzem a necessidade de energia, complexidade lógica e velocidade. Os autores também revisam estas técnicas e comparam também com um método baseado em Monte Carlo.

Sastri, Flores e Valdés (1989) afirmam que observações típicas da economia e negócios, na forma de séries temporais, frequentemente apresentam mudanças bruscas em seus dados. Para prever estas variáveis dinâmicas, sem utilizar informações sobre uma mudança significativa nos procedimentos de previsão, logo depois do tempo de mudanças, isto pode produzir um resultado inaceitável. Além disso, a estimação do ponto

de mudança também é uma variável de análise. Muitos métodos de mudanças em séries temporais são utilizados e o trabalho de Sastri, Flores e Valdés (1989) traz um comparativo de seis destes métodos.

No trabalho de Lewis (1971), ele discute qual é o significado de monitoramento em termos estatísticos e descreve as mais usadas técnicas de monitoramento que estavam disponíveis no período atual, o CUSUM e o TS. Além disso, em seu artigo ele discute a possibilidade de monitoramento desses métodos no ramo médico.

2.2.2 Séries temporais

De acordo com Montgomery, Jennings e Kulahci (2011), as previsões são baseadas em observações ou dados coletados sobre a variável de interesse. Esta informação é geralmente sob a forma de uma série de tempo ou séries temporais. Também segundo Morettin e Toloí (1985), uma série temporal é uma sequência de dados que são obtidos em intervalos regulares de tempo durante um período específico. Estes dados surgem de diversos campos do conhecimento como medicina, economia, epidemiologia, meteorologia, engenharia, entre outros. Portanto, a partir destas observações é que são realizadas as previsões.

Os métodos de previsão que utilizam séries temporais têm sido aplicados por décadas nas áreas de processamento digital de sinais, economia e previsão de cargas elétricas (Campos (2008); Morettin e Toloí (2006); Box, Jenkins e Reinsel (1994)). Ainda segundo Campos (2008), os métodos mais clássicos que são utilizados em previsão de séries temporais são ARMA, ARIMA, ARMAX E ARIMAX.

2.2.2.1 Séries temporais lineares e não lineares

Uma série temporal linear, segundo Morettin e Toloí (2006), é uma série que possui a média e variância constantes ao longo do tempo. Portanto, séries não lineares são o oposto de séries lineares, pois podem variar com relação à média ou com relação a variância. Os erros de previsão que são estudados no monitoramento dos modelos geram as séries temporais. Segundo Cruz *et al.* (2014), para que os erros de previsão possam ser considerados sob controle é necessário que os erros estejam dentro dos limites de controle estabelecidos pelos métodos de monitoramento e que nenhum padrão (como ciclos, tendências, dados não centrados) esteja presente. Por este motivo neste trabalho são consideradas séries lineares quando o modelo está sob controle e não lineares quando o modelo não está sob controle.

Foram selecionadas séries não lineares já implementadas e estudadas por Balestrassi *et al.* (2009). Segundo os autores, os oito modelos de séries temporais foram escolhidos porque representam uma variedade de problemas que possuem diferentes características. A Tabela 2.1 apresenta os oito modelos não lineares e suas respectivas equações.

Tabela 2.1 - Modelos não lineares
Fonte: Adaptado de Balestrassi *et al* (2009)

Modelo não linear	Equação
Sinal autor regressivo (SAR)	$y_t = \text{sinal}(y_{t-12}) + \varepsilon_t$, onde $\text{sinal}(x) = 1, 0, -1$ se $x > 0, x = 0, x < 0$, respectivamente
Bilinear (BI)	$y_t = 0.7y_{t-1}\varepsilon_{t-2} + \varepsilon_t$
Bilinear (B)	$y_t = 0.4y_{t-1} - 0.3y_{t-2} + 0.5y_{t-1}\varepsilon_{t-1} + \varepsilon_t$
Limiar autor regressivo (TAR)	$y_t = 0.9y_{t-1} + \varepsilon_t$ para $ y_{t-1} \leq 1$ e $y_t = -0.3y_{t-1} - \varepsilon_t$ para $ y_{t-1} > 1$
Não linear auto regressivo (NAR)	$y_t = \frac{0.7 y_{t-1} }{ y_{t-1} + 2} + \varepsilon_t$
Não linear média móvel (NMA)	$y_t = \varepsilon_t - 0.3\varepsilon_{t-1} + 0.2\varepsilon_{t-2} + 0.4\varepsilon_{t-1}\varepsilon_{t-2} - 0.25\varepsilon_{t-2}^2$
Transição suave autor regressiva (ST)	$y_t = 0.8y_{t-1} - 0.8y_{t-1}[1 + \exp(-10y_{t-1})]^{-1} + \varepsilon_t$
Transição suave autor regressiva (S)	$y_t = 0.3y_{t-1} + 0.6y_{t-2} + (0.1 - 0.9y_{t-1} + 0.8y_{t-2})[1 + \exp(-10y_{t-1})]^{-1} + \varepsilon_t$

2.3 Cartas de Controle

As Cartas de Controle são muito utilizadas em Controle Estatístico de Processos (CEP). Estas cartas são técnicas de monitoramento que facilitam a observação de processos e a verificação de possíveis anomalias que possam existir nestes mesmos processos. O objetivo é identificar anormalidades no processo de maneira rápida e poder analisar qual foi a causa da mudança para poder corrigi-la (MAGALHÃES e CYMROT, 2006).

Segundo Montgomery, Jennings e Kulahci (2011), as cartas de controle são aplicadas no monitoramento de modelos de previsão. A utilização destas cartas de controle em previsão ocorre com os erros de previsão, que são calculados segundo a fórmula abaixo:

$$e = d - f \quad (1)$$

Onde d é o valor atual da série e o f é a previsão realizada.

Existem outras cartas de controle, como a de Shewart, que somente consideram a informação que é relativa ao último ponto coletado. Entretanto, para o presente trabalho serão estudadas as cartas de controle CUSUM e EWMA.

2.3.1 Carta de Controle CUSUM

Antes de falar sobre a carta de controle CUSUM, é necessário analisar a técnica de Soma Acumulada - CUSUM.

2.3.1.1 Técnica de Soma Acumulada - CUSUM

De acordo com o trabalho de Harrison e Davies (1964), a técnica CUSUM possui como principais propósitos:

- Revelar mudanças na performance de um processo e particularmente detectar mudanças na média do processo;
- Determinar quando tais mudanças aconteceram e
- Acompanhar a atual estimativa da média.

A técnica CUSUM não apenas possui estes propósitos em controle de processos e análise da retrospectiva, mas também pode ser incorporado em sistemas de previsão. O trabalho de Harrison e Davies (1964) está focado na incorporação desta técnica em um sistema de previsão de curto-prazo da demanda de produtos para o uso de controle de estoque e na programação da produção.

Ainda de acordo com os autores, sistemas de previsão de curto-prazo compreendem três passos distintos:

1. A previsão, que é chamado de previsão de tendência, solidamente baseado nos dados históricos do produto que são representados por ordens antigas ou vendas;
2. O esquema de controle CUSUM que revela mudanças não detectadas no padrão da demanda do cliente e informa a adequada previsão de tendências para que ela seja alterada.
3. Esquema de predição – para permitir o uso de informações do mercado que surgem com o propósito de modificar a previsão de tendência quando necessário e a antecipação da mudança do padrão de demanda do cliente.

O sistema completo usualmente opera de acordo com o princípio de “gerenciamento por exceção”: a previsão de tendência é aceita a menos que a técnica de CUSUM e o esquema de predição indiquem o contrário.

Ainda em seu trabalho, eles demonstram como calcular o CUSUM quando aplicado a previsão de vendas que possui dois estágios distintos que são:

- A acumulação sucessiva de erros de previsão
- Teste para encontrar uma mudança significativa.

O CUSUM para o período determinado é então calculado pela adição deste erro com o CUSUM do período anterior. Seguindo a equação:

$$C_1 = d_1 - f_1 = e_1 \quad (2)$$

$$C_2 = (d_1 - f_1) + (d_2 - f_2) = e_1 + e_2 \quad (3)$$

$$C_3 = C_2 + e_3 \quad (4)$$

$$C_n = C_{n-1} + e_n \quad (5)$$

Também apresentam o princípio de teste do CUSUM que é basicamente teste sequencial para trás que opera da seguinte forma:

Tomando como base S_i como a soma de i mais recentes erros de previsão, então no tempo t :

$$S_1 = e_t = C_t - C_{t-1}, \quad (6)$$

$$S_2 = e_t + e_{t-1} = C_t - C_{t-2}, \quad (7)$$

$$S_i = e_t + e_{t-1} + \dots + e_{t-i+1} = C_t - C_{t-i} \quad (8)$$

Assim como surgem novas observações, um novo S_i é calculado e testado com o correspondente limite ($\pm L_i$). Se o limite é quebrado pela soma cumulativa, então a falta de controle é sinalizada. Segundo os autores, estes limites muitas vezes podem ser escolhidos, como em testes sequenciais, para controlar a frequência de decisões erradas, ou para otimizar certas características de um sistema de previsão particular.

2.3.1.2 Carta de Controle - CUSUM

Muito utilizadas e estudadas por diversos autores, as cartas de controle de soma acumulada (CUSUM), foram, no início, propostas por Page (1954) na Inglaterra. Este trabalho se baseia na definição dada por Montgomery (1996) e Montgomery, Jennings e Kulahci (2011). Em seu trabalho, Montgomery (1996) apresenta as cartas CUSUM aplicadas à média e à variabilidade do processo, além disso, apresenta a possibilidade de projetar procedimentos da carta para outras variáveis estatísticas, como desvio padrão e amplitude de subgrupos, variáveis de Poisson e binomial em modelos e processos contínuos.

Segundo Montgomery, Jennings e Kulahci (2011) a carta de controle de soma acumulada é muito eficaz na detecção de mudanças da variável que é monitorada. Seu funcionamento se dá através da acumulação de desvios dos erros de previsão que estão

acima do valor alvo T desejado ou abaixo. Este valor alvo desejado possui estatísticas C+ e C- que são os chamados CUSUM's superior e inferior. Ainda segundo os autores, estes valores são calculados seguindo as equações (9) e (10).

$$C_t^+ = \max[0, e_t(1) - (T + K) + C_{t-1}^+] \quad (9)$$

$$C_t^- = \min[0, e_t(1) - (T + K) + C_{t-1}^-] \quad (10)$$

De acordo com estas equações a constante K é chamado de valor de referência. Segundo os autores ela é normalmente escolhida como $k = 0.5\sigma_{e(1)}$ e $\sigma_{e(1)}$. É o desvio padrão dos erros.

A lógica segundo Montgomery, Jennings e Kulahci (2011) é que se os erros começam a cair de um lado do valor alvo, um dos CUSUM's aumenta em magnitude gerando um sinal de falta de controle. A regra de decisão é para sinalizar se a estatística C+ excede um intervalo de decisão $H = 5\sigma_{e(1)}$ ou se C- excede -H. Este sinal indica que a série possui anormalidades e não está satisfatória.

A Figura 2.2 traz um exemplo da análise CUSUM realizada em uma das séries temporais que serão estudadas neste trabalho.




Figura 2.2 - Resultado de uma análise CUSUM realizada para uma série temporal

De acordo com a Figura 2.2, o teste realizado mostra que a série possui anormalidades a partir do ponto 34. Todos os pontos em vermelho revelam que estão fora do padrão da série. O valor alvo T é igual a zero e os valores UCL e LCL são os chamados CUSUMs superior e inferior.

Entre outros autores que estudaram as cartas de controle CUSUM, destacam-se Bissel (1969) que considerou o método e sua relevância em controle de qualidade

propondo técnicas que facilitassem sua aplicação em situações mais práticas. Conforme Johnson e Bagshaw (1974), para observações não independentes o teste CUSUM não é apropriado. Hawkins e Olwell (1998) propuseram os gráficos como ferramentas que são essenciais para os profissionais de qualidade para descobrir e diagnosticar as trocas persistentes em processos. Já Hawkins (1981) propõe uma nova técnica que emprega o mesmo procedimento do gráfico CUSUM para controlar a variabilidade.

O trabalho de Chen e Chen (2013) aplica as cartas de controle CUSUM em problemas de saúde, como o problema de vigilância do *enterovirus* (EV). O objetivo é detectar um anormal crescimento de casos de EV na cidade de Taiwan. Em seu trabalho é utilizado o método de previsão (ARIMA) para modelar uma base não estacionária de dados. Também Woodall (2006) afirmam que muitas cartas de controle têm sido aplicadas em cuidados com a saúde e vigilância da saúde pública, e também que cartas CUSUM são mais frequentemente utilizadas para monitoramento do que as demais cartas.

De acordo com Montgomery (2007), os métodos de controle estatístico de processos (CEP) foram primeiramente aplicados na área de controle estatístico industrial. Porém, estes métodos são muito utilizados em outras áreas como o trabalho de Hutwagner *et al* (1997) que desenvolveu um algoritmo baseado na carta CUSUM para detectar surtos de salmonela utilizando dados de laboratório. Já Morton *et al* (2001) aplicaram as cartas de controle como Shewart, CUSUM e EWMA para detectar e monitorar infecções hospitalares. O trabalho de Rogerson e Yamada (2004) também utilizou a aplicação da carta de Poisson CUSUM para detectar infecções do trato respiratório interior. Cowling *et al* (2006) adaptaram a carta CUSUM para monitorar a influenza com dados de Hong Kong e Estados Unidos e compararam com séries temporais e modelos de regressão. Woodall *et al* (2008) demonstraram que a carta de CUSUM é superior ao outro método estudado em seu trabalho.

2.3.2 Carta de Controle EWMA

Tendo um desempenho aproximadamente equivalente a carta CUSUM, a carta de controle exponencialmente ponderada (EWMA) é usada, tipicamente, em observações individuais. Montgomery (2007) apresentou as cartas EWMA como alternativa para as cartas de controle de Shewart, na detecção de pequenas mudanças. A média móvel ponderada é definida como na equação (11):

$$Z_i = \lambda x_i + (1 - \lambda)Z_{i-1} \quad (11)$$

Onde $0 < \lambda \leq 1$ é uma constante e o valor inicial (para primeira amostra $i = 1$) é que se pretende para o processo, tal que $Z_0 = \mu_0$. Segundo Montgomery (1996), a carta EWMA é eficiente em situações de pequenas mudanças no processo.

Esta carta de controle foi introduzida inicialmente por Roberts (1959), porém, muitos outros autores apresentaram suas contribuições para esta carta. Hunter (1986) apresenta a diferença entre as três cartas de controle: Shewhart, CUSUM e EWMA. Segundo o autor a carta de Shewhart depende inteiramente do ponto demarcado por último, já a CUSUM atribui peso praticamente igual para toda a sequência de dados e a carta EWMA concede o maior peso para as mais atuais informações e menor para as mais longínquas.

Outro estudo comparativo das cartas de controle CUSUM e EWMA foi realizado por Lucas e Saccucci (1990) que concluíram que ambos os métodos possuíam resultados similares, porém a carta de EWMA possuíam ARL (cumprimento médio da série) menor que a CUSUM algorítmica.

A Figura 2.3 mostra a análise EWMA realizada em uma das séries temporais que serão apresentadas nesta pesquisa.




Figura 2.3 - Resultado de uma análise EWMA realizada para uma série temporal

Conforme a Figura 2.3, o teste realizado mostra que a série possui anormalidades a partir do ponto 10. Todos os pontos em vermelho revelam que estão fora do padrão da série.

O trabalho de Vargas e Lopes (2001) apresenta um estudo comparativo do desempenho da carta de controle CUSUM e EWMA. O objetivo do estudo era verificar

as diferenças entre estas cartas na detecção de pequenas mudanças na média dos processos. Foi comparado o ARL encontrado em cada um dos métodos. A conclusão do trabalho é que a carta de controle CUSUM é mais eficiente para detectar mudanças acima de um desvio padrão, enquanto a carta de controle EWMA detecta melhor mudanças menores que um desvio padrão.

No trabalho de Mingoti e Yassukawa (2008), foram comparadas as cartas de controle Shewart, CUSUM e EWMA em monitoramento da média de processos autocorrelacionados. A comparação foi realizada por simulação de Monte Carlo e os resultados mostraram que a autocorrelação possui grande impacto no comportamento das cartas de controle estudadas e que o impacto depende do modelo que gerou os dados amostrais. Além disso, o trabalho concluiu que as cartas CUSUM e EWMA não são adequadas para processos autocorrelacionados, pois apresentam grande valor de falsos alarmes.

2.4 Tracking Signal

Segundo McClain (1988), *Tracking Signal* (TS) promove um controle de qualidade para a previsão. Seu propósito é detectar automaticamente quando a previsão é inadequada. Ainda segundo o autor, um perfeito TS irá detectar uma previsão fora de controle imediatamente, e nunca dará um falso alarme. Entretanto, este ideal não é possível. Na realidade, os falsos alarmes vão ocorrer e eles terão um tempo antes que uma previsão imprecisa seja detectada.

De acordo com McClain e Thomas (1991), os TS são medidas de erros de previsão acumulados que são desenhados para sinalizar quando um modelo de previsão se tornou inadequado. E existem dois tipos de sinalização do TS: os verdadeiros e os falsos alarmes. Um verdadeiro alarme sinaliza quando uma mudança real ocorre no padrão dos dados. Já um falso alarme ocorre quando um padrão randômico nos dados causa uma sinalização. Este assunto será tratado no item 2.5.

O trabalho de Ristroph (1990) afirma que sistemas automatizados de previsão são essenciais para o sucesso da produção integrada por computador (CIM – *Computer integrated manufacturing*), ou seja, as previsões servem como entradas para o estoque e o planejamento de produção que são componentes integrados da CIM. E o TS pode ser usado para determinar automaticamente quando um processo está fora de controle ou para adaptar as previsões para as mudanças em demanda, características que são importantes em um bom sistema de previsão.

De acordo com Alstrom e Madsen (1996), o desenvolvimento de diferentes versões TS recebeu uma grande atenção na literatura e pelos pesquisadores a partir do desenvolvimento do primeiro TS por Page (1955). Outros dois grandes pesquisadores propuseram novas versões, como Brown (1959) que propôs o uso de simples CUSUM como a TS em um controle de estoque, visto no item 2.4.1. E também Trigg (1964) que desenvolveu o TS de erro suavizado, como visto no item 2.4.4. Trigg e Leach (1967) propuseram uma modificação com a variação de *alpha* de acordo com a previsão tendenciosa que se é obtida, que de acordo com Alstrom e Madsen (1996), significa colocar o TS diretamente igual ao parâmetro de suavização. Entretanto a estabilidade deste método foi criticada e não entrará neste estudo. Outras modificações foram propostas Gardner (1983) serão tratadas nos itens 2.4.2 e 2.4.5.

A Figura 2.4 resume as versões do TS que serão estudadas neste trabalho.

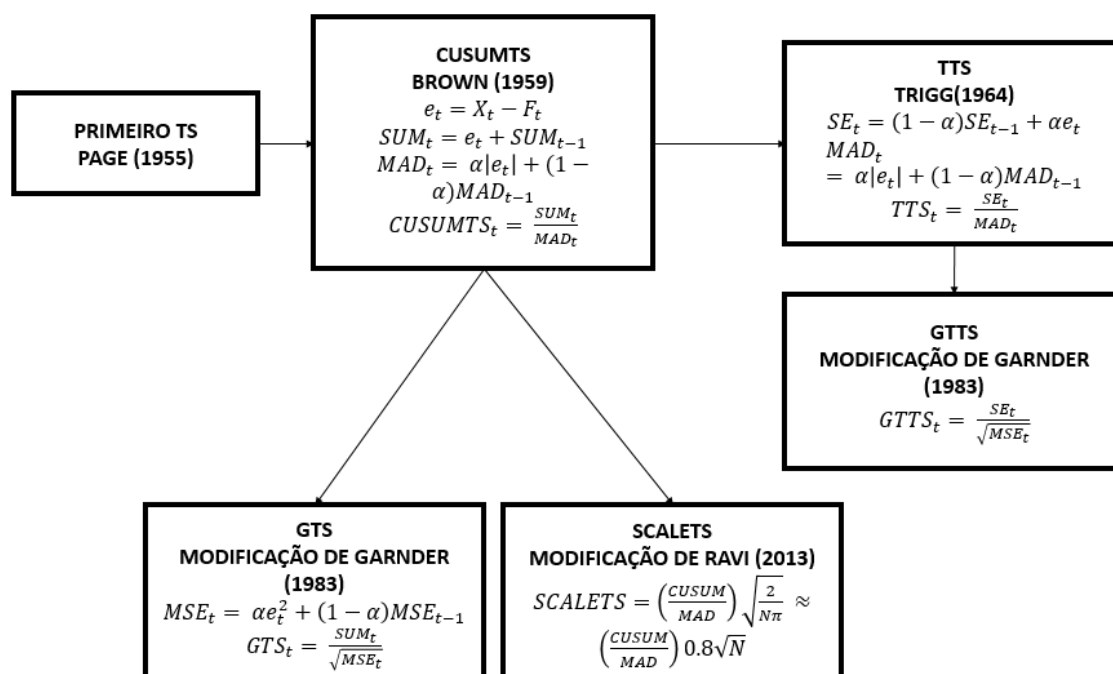


Figura 2.4 - Versões do *Tracking Signal*

Segundo Ravi (2013), medidas similares ao TS vem sendo utilizadas para monitorar e controlar diversos outros segmentos como cirurgia (Biau *et al*, 2011), educação médica (Dalal *et al*, 2011), o estudo da mudança de clima (Fisher *et al*, 2012), hidrologia (Yang *et al*, 2012) e a economia do turismo (Onafowora e Owoye, 2012).

O trabalho de Jardim (2013) faz uma comparação de desempenhos por simulação das principais técnicas de detecção de mudanças, que são as versões do TS de Brown, Gardner, Trigg com duas outras técnicas do Controle Estatístico de Processos, as cartas EWMA e CUSUM. Em seu trabalho, avaliou três tipos de alterações que acarretam em viés nas séries. Os resultados mostraram que, para a maioria das situações que foram

estudadas, as técnicas que são baseadas em TS possuem um desempenho superior, em relação à eficiência na detecção de mudanças, que as demais técnicas.

Gorr e Mckay (2003) apresentaram uma aplicação de TS no uso de mapeamento de crimes, para identificar padrões de crimes nas áreas e auxiliar em tomadas de decisões da intervenção policial. Com os resultados obtidos no trabalho, foi possível concluir que o TS é uma ferramenta promissora em análise criminalística.

O trabalho de Shu *et al.* (2013) emprega o TS com um monitoramento dinâmico da eficiência devido a habilidade de alertar para sinais fora de controle. Já o trabalho de Superville (1995) compara os resultados do TS de Brown e de Trigg e demonstra que a presença de dados autocorrelacionados aumenta a ocorrência de sinais fora de controle que são detectados pelos TS.

Brence e Mastrangelo (2006) focaram, em seu trabalho, a aplicação de TS e a escolha de constantes de suavização. Nas análises realizadas, o TS de Brown não teve um bom desempenho quanto o TS de Trigg. A maior desvantagem do TS de Brown é a alta taxa de falsos alarmes e baixo ARL e o TS de Trigg fornece múltiplas escolhas de combinações de parâmetros o que fornece um robusto TS capaz de ajustar as necessidades de quem o utiliza.

2.4.1 Tracking Signal de Brown

O primeiro TS para controle de previsão foi proposto por Brown (1959). O nome do método é CUSUMTS e será tratado assim neste presente trabalho. O CUSUMTS compara a soma cumulativa de erros a cada final de período do MAD (desvio médio absoluto) suavizado. As atualizações das equações a cada novo erro observado são dadas pelas fórmulas:

$$e_t = X_t - F_t \quad (12)$$

$$SUM_t = e_t + SUM_{t-1} \quad (13)$$

$$MAD_t = \alpha|e_t| + (1 - \alpha)MAD_{t-1} \quad (14)$$

$$CUSUMTS_t = \frac{SUM_t}{MAD_t} \quad (15)$$

Onde o erro de previsão, e_t , é o valor atual da série temporal, X_t , menos a previsão, F_t . Como usual, o parâmetro de suavização é restrito a $0 \leq \alpha \leq 1$. Se $CUSUMTS_t$ excede um significativo múltiplo do alisamento do MAD, a previsão pode ser tendenciosa. De acordo com Gardner (1985), o CUSUMTS deve flutuar em torno e zero se as previsões são imparciais. De acordo com McClain (1988), o propósito do denominador MAD é

medir a variabilidade da média de longo prazo dos erros de previsão em ordem de padronizar o numerador.

De acordo com Gardner (1983), a versão do CUSUMTS de Brown (1959) possui duas vantagens. A mais importante vantagem é que sua performance é independente do parâmetro de alisamento usado. Além disso, ele é também independente da variância da série temporal. A versão simples de CUSUMTS também possui desvantagens, assim como outros autores e Trigg (1964) apontaram, o método nunca esquece grandes erros, ou seja, possui uma grande memória. De acordo com Trigg (1964), uma vez que o CUSUMTS está fora dos limites ele não necessariamente retorna ao normal mesmo que a previsão volte a estar sobre controle. Outra desvantagem é que se o sistema de previsão está excepcionalmente acertando suas previsões, o sinal pode trocar, assim o $CUSUMTS_t$ tende ao infinito.

Segundo Jardim (2013), os limites de controle para o CUSUMTS são independentes do período de tempo.

De acordo com Batty (1969), a fórmula dos limites de controle proposto por Brown (2004), estão incorretas. Brown (2004), em seu trabalho afirma que os limites de confiança podem ser colocados no valor do sinal, assim que se excederem poderia indicar que o modelo de previsão é inadequado. Para computar o valor destes limites, Brown avalia a variância da soma dos erros para único, dupla ou tripla suavização exponencial, e assim propõem a relação geral para o modelo com N degraus de liberdade:

$$\text{Variância da soma dos erros} = \frac{\sigma^2}{1-(1-\alpha)^{2N}} \quad (16)$$

Onde σ^2 é a variância do ruído do dado e α é a constante de alisamento.

Assumindo que os erros são normalmente distribuídos e que a amostra dos ruídos é serialmente independente, a MAD é dada por:

$$MAD = \frac{2\sigma}{\sqrt{[\pi(2-\alpha)]}} \quad (17)$$

Assim, os limites de controle são:

$$\pm \sqrt{\frac{\pi(2-\alpha)}{1-(1-\alpha)^{2N}}} \quad (18)$$

Como citado anteriormente, de acordo com Batty (1969), um número de simulações suporta esta fórmula geral. Entretanto, em seu artigo, aparentemente a confirmação dessa expressão está incorreta. Para valores menores da constante de alisamento, porém, as discrepâncias são pequenas.

No trabalho de Ristroph (1990) traz uma importante afirmação de Brown (2004) que demonstrou que os erros de previsão de uma suavização exponencial são

normalmente distribuídos se o ruído de entrada também é normalmente distribuído, então isto parece razoável para gerar termos de erros de uma distribuição normal.

Ravi (2013) analisou a versão do CUSUMTS de Brown (1959) que é baseada na média não suavizada dos erros de previsão. No trabalho o autor fez suposição que os valores da demanda em diferentes períodos eram independentes, identicamente e normalmente distribuídos (i.d.d.). Assim, mostrou que quando os erros de previsão em diferentes períodos são normais i.d.d., essa versão de Brown consegue indicar que a sequência não é imparcial mesmo quando é imparcial. Assim, foi sugerido uma modificação no CUSUMTS que elimina essa falha e está no item 2.4.3. Outra afirmação importante segundo Ravi (2013) é que uma série de previsão é sinalizada se o seu resultado do TS está entre mais ou menos 4.

2.4.2 Tracking Signal de Brown-Gardner

Gardner (1983), propôs a modificação no modelo proposto por Brown (1959). O GTS pode ser utilizado com a estimativa suavizada do desvio padrão dos erros de previsão no denominador ao invés do MAD. Segundo o autor, Brown (1982) recomendou este procedimento, desde que o desvio padrão dos erros fosse necessário para computar seguramente os estoques em aplicações de controle de estoques. O desvio padrão é sempre estimado por $1.25MAD$, mas isto só está correto para erros normalmente distribuídos, como o caso do trabalho de Gardner (1983). Nas aplicações onde uma estimativa do desvio padrão de erros é necessária, é seguro trocar a equação (14) por:

$$MSE_t = \alpha e_t^2 + (1 - \alpha)MSE_{t-1} \quad (19)$$

A raiz do MSE (erro quadrático) pode ser usado no lugar da MAD_t na equação (15), resultando na equação (20):

$$GTS_t = \frac{SUM_t}{\sqrt{MSE_t}} \quad (20)$$

Para séries temporais com uma longa história, ou seja, muitos dados, a variância dos erros de previsão pode ser estimada e usada com uma quantidade fixa no denominador do GTS. Se a variância permanece sem mudanças, este procedimento melhora a performance do GTS. Assim como no item anterior, segundo Jardim (2013), os limites de controle para essa versão do GTS são independentes do período de tempo.

2.4.3 Tracking Signal de Brown-Ravi

De acordo com Ravi (2013), uma comum modificação do CUSUMTS é usar a média não suavizada de MAD em vez de média suavizada de MAD. Tomando AD_i como

desvio absoluto no período i . Levando MAD_i como desvio médio absoluto não suavizado dos erros de previsão no período 1 até t . O novo TS não suavizado será AVGTS e terá as equações abaixo:

$$AD_i = |e_t| \quad (21)$$

$$MAD_t = \frac{\sum_{i=1}^t AD_i}{t} \quad (22)$$

$$CUSUM_t = \sum_{i=1}^t e_i \quad (23)$$

$$AVGTS_t = \frac{CUSUM_t}{MAD_t} \quad (24)$$

Esta modificação está presente em muitos outros textos como Martinich (2008), Russel e Taylor (2011) e Stevenson (2011) e também é a versão recomendada pela Associação para Gerenciamento Operacional.

O TS precisa distinguir um viés de previsão de uma variação normal para determinar se a previsão é ou não tendenciosa. Sinalizar previsões tendenciosas é parte disso, porém também é importante não sinalizar previsões que não são tendenciosas. No trabalho de Ravi (2013), ele faz a análise do AVGTS para grandes e pequenos números de N , onde N denota o número de períodos. Utilizando pequeno número de N , ele demonstra que o AVGTS consegue rapidamente classificar uma não tendenciosa previsão como uma previsão tendenciosa. Para grandes números de N ele utiliza o Teorema de Slutsky (Slutsky, 1925), que mostra que para grandes valores de N , o valor do TS segue a distribuição normal com média 0 e desvio padrão de $\sqrt{N\pi/2}$. Assim, é muito provável que quando N cresce, o AVGTS irá cair para fora de ± 3 ou ± 4 mesmo quando a previsão é imparcial. Portanto, Ravi (2013), propôs uma modificação no AVGTS.

De acordo com a modificação de Ravi (2013), escalonando o AVGTS usando o fator de $\sqrt{2/N\pi}$. Então,

$$SCALETS = \left(\frac{CUSUM}{MAD}\right) \sqrt{\frac{2}{N\pi}} \approx \left(\frac{CUSUM}{MAD}\right) 0.8\sqrt{N} \quad (25)$$

onde SCALETS denota a versão escalada de AVGTS. Como foi mostrado que o AVGTS converge para a distribuição normal com média 0 e desvio padrão de $\sqrt{N\pi/2}$. Multiplicando AVGTS por $\sqrt{N\pi/2}$ garante que o resultado modificado do TS $SCALETS \sim N(0,1)$. A probabilidade da variável normal padrão alcança valores maiores que +3 ou menores que -3 é muito pouco. Entretanto, com os limites de controle de ± 3 ou ± 4 , a medida de SCALETS permitiria poucas falsas indicações de viés.

2.4.4 Tracking Signal de Trigg

Para que as desvantagens do modelo de CUSUMTS proposto por Brown (1959) não ocorram mais, Trigg (1964) propôs alterações no CUSUMTS. De acordo com sua versão, ao invés de utilizar a soma de erros, utilizaria os erros suavizados para computar o TS, atualizando as equações:

$$SE_t = (1 - \alpha)SE_{t-1} + \alpha e_t \quad (26)$$

$$MAD_t = \alpha |e_t| + (1 - \alpha)MAD_{t-1} \quad (27)$$

$$TTS_t = \frac{SE_t}{MAD_t} \quad (28)$$

Se o sistema de previsão está tão fora de controle que todos os seus erros possuem o mesmo sinal, então este TTS vai se aproximar de mais ou menos um. Isto não pode sair destes extremos.

Para o cálculo dos limites, segundo Trigg (1964), deriva-se a expressão da variância do erro suavizados. Para uma ampla variedade de distribuições o desvio padrão pode ser estimado através da relação $\sigma = 1.2 MAD$, e os limites de controle são:

$$\pm 2.4 \sqrt{\frac{\alpha}{2-\alpha}} \quad (29)$$

De acordo com Batty (1969), a estimativa usual disponível de MAD para calcular o TTS é o erro absoluto suavizado. Isso se torna ainda mais complicado o cálculo dos limites de confiança e para o reconhecimento deste fato, Trigg apresenta a tabela das probabilidades cumulativas, obtidas por simulação para $\alpha = 0.1$ e $\alpha = 0.2$. Ele então afirma que estas tabelas não são estritamente aplicáveis quando o sistema de previsão que dá origem aos erros é um sistema adaptativo desde que estes sistemas introduzam uma correlação serial para estes erros. Mesmo assim, para praticamente a maioria dos sistemas com uma baixa taxa de respostas a modificação necessária para os limites de confiança decorrente desta causa não é tão grande. Entretanto, como afirma Batty (1969), de acordo com a experiência de Trigg estas modificações são significantes, na ordem de 20% para $\alpha = 0.1$ e 25% para $\alpha = 0.2$. A primeira indicação disto é dada pela evolução da variância do erro alisado para uma única suavização exponencial que levou a derivação da expressão geral para esta variância para a suavização exponencial de ordem N.

Para calcular os limites, Trigg, segundo Gardner (1983), devido ao processo de amortecimento exponencial, a auto correlação dos erros de previsão é ignorada. Também segundo Jardim (2013), os limites de controle para o TST de Trigg são independentes do período de tempo. Ainda de acordo com Gardner (1983), o modelo proposto por Trigg

não é recomendado para altos valores de α . Embora o modelo trabalhe bem com erros independentes, a auto correlação é a melhor escolha.

No trabalho de Lewis (1971) é encontrado a interpretação dos valores do TTS. Os valores do TTS podem variar entre mais ou menos um e as vezes podem ser utilizadas as seguintes interpretações para estes valores:

TTS_t Interpretação

- +1 → pode ser 100% de confiança que houve um aumento significativo no valor do parâmetro a ser monitorado;
- -1 → pode ser 100% de confiança que houve uma diminuição significativa no valor do parâmetro a ser monitorado.

Entretanto, no presente trabalho não serão utilizadas estas interpretações.

Segundo Chernick (1972), o TS desenvolvido por Trigg é útil no monitoramento de previsão de suavização exponencial simples. Em seu trabalho, dois métodos são estudados na aplicação de TS para o monitoramento de previsões suavizadas exponenciais. O objetivo de seu trabalho foi ilustrar como o TS pode ser usado para monitorar previsões exponenciais suavizadas e como determina os limites de confiança quando se tem apenas 10 a 20 períodos de dados.

O trabalho de Deng, Jaraiedi e Iskander (2004) propõem a incorporação do TTS em um modelo de rede neural *fuzzy* para monitorar um processo de previsão como uma medida estatística para manter o modelo de previsão sempre atualizado. Os resultados do trabalho mostrado que o TTS é uma forma efetiva de detectar mudanças no padrão de séries temporais e serve como um mecanismo de controle de qualidade para sistemas de previsão.

De acordo com Li, Lange e Stocks (2012) se o sistema de previsão começa a dar previsões excepcionalmente precisas, o TS não continuará a degradar e Trigg afirmou que não era necessário zerar o TS para evitar os falsos alarmes. Entretanto, os autores encontraram que o TS de Trigg pode ter deficiências em alguns casos. Portanto, eles propuseram um novo TS – Complementar TS (CTS) – que supera as deficiências do TS de Trigg. Este novo método também prova que quando valor do erro relativo é menor que o anterior do CTS, então o CTS melhora ao longo do tempo. Mesmo com esta nova versão de TS proposta por Li, Lange e Stocks, ela não será analisada neste trabalho.

2.4.5 Tracking Signal de Trigg-Gardner

Assim como feito no modelo CUSUMTS de Brown, Gardner (1983), propõem a substituição do MAD pelo MSE, surgindo uma nova variante para o TTS de Trigg. As equações (19) e (26) já foram descritas anteriormente e são utilizadas nesta nova versão de GTTS, conforme a equação a seguir:

$$GTTS_t = \frac{SE_t}{\sqrt{MSE_t}} \quad (30)$$

De acordo com Jardim (2013), os limites de controle para o GTTS também são independentes do período de tempo.

2.5 Falsos Alarmes e Falhas de Detecção

De acordo com McClain (1988), a cada alarme do TS é necessário encontrar qual o erro e corrigi-lo. Entretanto, se a investigação revela que não existe razão para o alarme, então, isto é considerado um falso alarme causado por uma variação estatística normal. O custo anual de falsos alarmes é inversamente proporcional ao intervalo médio entre eles. Por exemplo, em um sistema de estoque, se 50.000 itens estão no sistema e falsos alarmes ocorrem a cada 100 períodos para cada um dos itens, o gerente pode esperar uma média de $50.000/100 = 500$ falsos alarmes para cada período. Portanto, especificar o intervalo médio dos falsos alarmes é uma forma apropriada de controlar estes custos. Limites de controle baseados na distribuição de probabilidade do TS não devem ser usados, uma vez que a distribuição não é adequada para representar a medida de falsos alarmes que são relevantes para o gerente.

Infelizmente, em acordo com o uso do ARL (comprimento médio da série) entre os falsos alarmes não resolve a questão porque a definição de ARL é ambígua. Para Gardner (1983), ARL é definido por convenção como o número de período requeridos para detectar a mudança no processo que está sendo monitorada. De acordo com McClain (1988), em seu artigo são utilizadas duas definições de ARL:

Definição 1. ARL é o tempo médio entre falsos alarmes em um sistema de previsão operacional. Chamado de ARL1.

Definição 2. ARL é o tempo médio até que um falso alarme ocorra, a partir de um ponto no tempo selecionado arbitrariamente Chamado de ARL2.

O trabalho de McClain (1988) sugere que as diferenças entre ARL1 e ARL2 para o CUSUMTS de Brown (1959) são surpreendentemente grandes. E a diferenças entre os ARL no TTS de Trigg (1964) seriam menores. Esta informação é importante porque implica que a mudança para ARL1 como uma medida do intervalo de falso alarme terá um efeito maior em ambas versões de TS. Como conclusão, o autor diz que ARL é uma

medida apropriada para o intervalo de falsos alarmes. Entretanto, para medir ARL, a simulação precisa combinar com o sistema de operação em prática. ARL2 falha neste critério, e como resultado, subestima consideravelmente as taxas de falso alarme.

No trabalho McClain e Thomas (1991), os autores afirmam que é possível melhorar o desempenho do TS tirando vantagem dos falsos alarmes. Eles mostram que falsos alarmes são causas de preocupação e indicam que a previsão está tendenciosa. Ainda mais, se não for corrigido, a tendência pode persistir por um tempo. Como afirmado no trabalho anterior, os falsos alarmes são causados por padrões não usuais estatísticos, como uma série de não usual de altas demandas, ou ‘*outliers*’. Assim, é necessário um método de correção que contenha informações do passado. Entretanto, neste trabalho, McClain e Thomas (1991), desenvolveram um método de melhora na previsão que demonstrou, por simulações, que a tendência de previsão, variância e a taxa de falsos alarmes foram reduzidas. Eles afirmam que o método é facilmente implementado e não necessita de novas informações porque é baseado em um termo que já é utilizado para calcular o TS.

Ainda sobre o trabalho de McClain e Thomas (1991), eles investigam uma outra visão sobre os falsos alarmes. Normalmente, quando se encontra um falso alarme, o mais comum a se fazer é ignorá-lo. Entretanto, eles afirmam o contrário, pois se os dados causam falsos alarmes, irão causar também erros de previsão. Por isso, o trabalho destes autores demonstra que a primeira vez que um falso alarme é capturado alguma informação pode ser utilizada para melhorar a previsão e prover um fator de correção para um simples modelo de previsão. Eles afirmam que falsos alarmes em TS indicam um problema fundamental com a previsão em si, não apenas com uma estatística ‘*outlier*’ e isto abre uma nova linha de pesquisa para métodos que é melhorar a previsão por redução ou eliminação de tendências. As tendências são sempre resultadas de desvios estatísticos em muitos períodos recentes. Entretanto, métodos simples de filtros de dados não tiram vantagens da informação disponível quando um alarme ocorre.

Para esta dissertação, as medidas de desempenho para os métodos de detecção de variação em séries temporais serão as taxas de falsos alarmes e falhas de detecção. De acordo com Navidi (2012), os falsos alarmes e as falhas de detecção podem ser definidos como:

- **Falsos alarmes:** um ponto que é apresentado fora dos limites de controle quando o processo apresenta sob controle;
- **Falhas de detecção:** pontos que são apresentados dentro dos limites de controle quando o processo não está sob controle.

2.6 Carta Farol ou Pré-Controle

De acordo com Mathias e Rebelato (2004), a carta Farol ou Pré-Controle é uma ferramenta estatística da qualidade que possui a vantagem de ser simplificada, de fácil preenchimento e interpretação e mais simples que as cartas clássicas do Controle Estatístico de Processos.

Segundo Schroeder (2003), a carta Farol apresenta um algoritmo que é baseado nas tolerâncias que são estabelecidas do processo. Normalmente, a carta é utilizada para novos processos, por este motivo que possui o nome de pré-controle, pois quando implementada ela apresenta o comportamento total do processo, o que possibilita o estudo e um controle estatístico do mesmo.

Mathias e Rebelato (2004) afirmam que o principal objetivo da carta farol é prevenir as ocorrências de não conformidades. Para este trabalho, estas não conformidades podem ser entendidas como falsos alarmes ou falhas de detecção vistas no item anterior. Os autores também afirmam que esta carta possui a vantagem de não exigir cálculos complexos.

A carta de farol se baseia na hipótese da curva normal, ou seja, de que a tolerância se distribui como uma curva normal. Este comportamento normal é importante devido ao fato que se pode prever qual a probabilidade dos dados coletados estarem dentro das frequências, assim são utilizados os parâmetros de centro de distribuição e dispersão da distribuição (SOARES, 2001). Portanto, é possível determinar se o processo se encontra em controle estatístico ou não de acordo com as probabilidades da curva normal.

De acordo com Schroeder (2003), a carta farol é dividida em três áreas que são descritas de acordo com a Tabela 2.2:

Tabela 2.2 - Carta Farol

ÁREA	SIGNIFICADO	EXPLICAÇÃO	CONDIÇÃO
VERDE	Adequado.	Os pontos plotados denotam que o processo está sob controle estatístico.	Condição ideal de trabalho.
AMARELO	Atenção.	Os pontos plotados mostram que o processo está sob controle mas muito próximos dos limites estabelecidos.	Requer acompanhamento rígido e uma possível intervenção no processo.
VERMELHO	Inadequado.	Os pontos plotados mostram que o processo não está sob controle estatístico.	Interromper o processo e tomar as medidas necessárias.

A carta Farol também pode ser dividida em dois tipos de tolerância.

- **Bilateral:** As partições das zonas verdes, ou seja, que estão dentro dos limites, possuem valores de + ou - 25% em torno do valor nominal. Para os 50% restantes até os limites são as zonas amarelas e as zonas fora dos limites são as vermelhas.




Figura 2.5 - Tolerância bilateral

Fonte: SCHROEDER (2003)

- **Unilateral:** As partições das zonas vermelhas estão fora de especificações, as amarelas são determinadas como 25% a partir do limite e o restante (75%) está dentro da zona verde.




Figura 2.6 - Tolerância unilateral

Fonte: SCHROEDER (2003)

De acordo com Mathias e Rebelato (2004) devem ser desenvolvidas matematicamente e com experiências práticas todas as regras de preparação, frequência de amostragem e tamanhos de amostra.

Para este trabalho será considerada a carta com tolerância unilateral.

2.7 Considerações Finais

Este capítulo teve como objetivo apresentar todo o suporte teórico que foi utilizado para o entendimento, desenvolvimento e análise deste trabalho. Foi realizada uma revisão abrangente dos assuntos estudados, destacando os principais autores, suas pesquisas e conclusões para chegar ao objetivo central da pesquisa. O desenvolvimento e as conclusões deste trabalho serão detalhados nos próximos capítulos.

3. METODOLOGIA DE PESQUISA

3.1 Considerações Iniciais

Este capítulo apresenta a metodologia de pesquisa utilizada neste trabalho. A primeira parte apresenta a classificação da mesma e a segunda apresenta qual a definição do método de pesquisa e como será desenvolvida.

3.2 Classificação da Pesquisa Científica

De acordo com Miguel *et al.* (2010), a pesquisa pode ser classificada e dividida quanto à natureza, aos objetivos, abordagem do problema e o método de pesquisa. A Figura 3.1 ilustra as etapas que embasam a pesquisa e permitem a sua classificação.

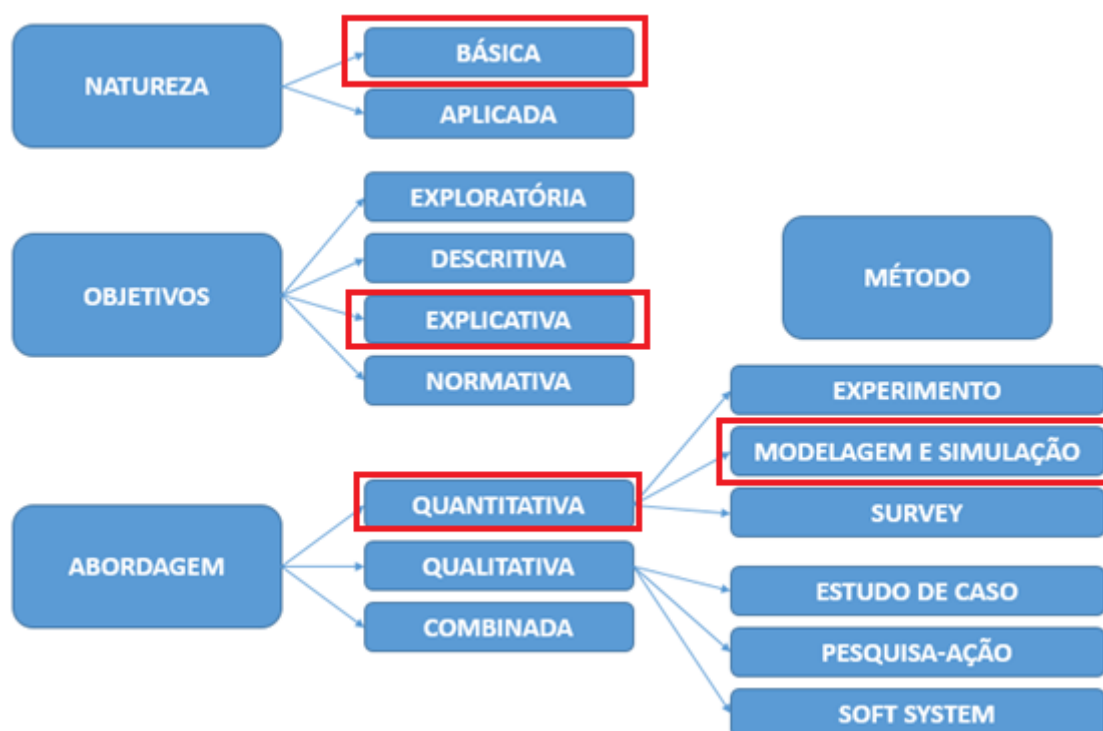


Figura 3.1 - Classificação do método de Pesquisa

Fonte: Miguel *et al.* (2010)

Para o presente trabalho é considerado como natureza **básica**, com objetivos **explicativos**, com abordagem **quantitativa** e utiliza o método de pesquisa **simulação**. A pesquisa é básica pois não possui interesses econômicos, apenas para agregar material científico à literatura. Ela possui objetivos explicativos, pois, visa discutir os diferentes desempenhos de cada um dos métodos de TS. E é uma abordagem quantitativa pois os modelos quantitativos são aqueles que são baseados em conjuntos de variáveis que se alteram sobre um domínio específico. (BERTRAND E FRANSOO, 2002)

3.2.1 Método de Pesquisa: Simulação

De acordo com Martins, Mello e Turrioni (2014), a evolução da simulação relacionada com a evolução das inovações em *hardware* e *software*, ainda que o método tenha sido proposto através da simulação de Monte Carlo. A simulação de Monte Carlo envolve o uso de números aleatórios e probabilidades para resolver problemas.

Ainda de acordo com os autores, nas décadas de 1960 e 1970, a simulação era cara e não possuía muitas ferramentas. Apenas com os atuais *softwares* que o tempo e esforço da simulação se concentram mais na atividade de análise de resultados.

Para Bertrand e Fransoo (2002), a simulação deve ser usada quando se deseja prever o efeito de mudanças no sistema ou ainda poder avaliar seu comportamento ou desempenho. Ainda de acordo com os autores, a simulação pode ser utilizada na resolução de problemas reais, durante o gerenciamento de operações.

Para Chung (2004), a simulação tem como principais vantagens a facilidade de demonstração dos modelos e menos necessidade de análise, em virtude da alta capacidade dos *softwares*. Também a experimentação pode ocorrer em um curto período de tempo e em níveis que não são permitidos nos experimentos físicos. Já para Robinson (2004), entre as suas desvantagens se destaca que consome muito tempo, pode possuir um custo elevado dependendo dos *softwares* existentes no mercado, e requer habilidade dos pesquisadores e analistas.

3.3 Desenvolvimento da Análise da Pesquisa

O desenvolvimento da análise deste trabalho está dividido em três etapas apresentadas no capítulo 4. A primeira etapa é a análise do desempenho das cartas de controle EWMA e CUSUM e o TS. A segunda etapa exclui o método que possui um desempenho inferior aos outros. A terceira contém a análise das versões do melhor método e a última etapa analisa a versão de melhor desempenho e aplica a lógica da carta Farol para o método estudado.

O último capítulo do trabalho contém todo o desenvolvimento da conclusão do estudo que foi proposto, bem como trabalhos futuros que podem ser desenvolvidos com o tema.

3.4 Considerações Finais

O presente capítulo apresentou o método de pesquisa quantitativo a ser utilizado neste trabalho. Pode-se verificar que as características apresentadas verificam a escolha do método de pesquisa: Simulação.

4. APLICAÇÃO DO MÉTODO

4.1 Considerações Iniciais

Este capítulo contém todos os passos que foram realizados para o desenvolvimento desta pesquisa. Serão apresentados todos os dados que foram definidos para a análise dos métodos, como foram realizadas as simulações e quais são os resultados parciais de cada uma das etapas desta pesquisa.

Como citado anteriormente, este trabalho é dividido em três etapas que serão apresentadas neste capítulo, bem como o desenvolvimento de cada uma delas.

4.2 Definição da Simulação e dos Testes

Para poder avaliar o desempenho de cada um dos métodos, era preciso simular séries de uma previsão que está sobre controle e de uma previsão que está fora do controle.

Conforme apresentado no Capítulo 2, as séries lineares são aquelas que possuem média e variância constantes, o que podem simular resíduos de uma previsão sobre controle. Já as séries não lineares podem ser consideradas como o pior cenário para os resíduos de uma previsão.

De acordo com o Tabela 2.1, foram apresentados os modelos de séries não lineares que são simulados nos presentes testes.

Para o trabalho, como citado anteriormente, foram realizadas quatro etapas conforme a Figura 4.1.




Figura 4.1 - Etapas para o desenvolvimento da dissertação

Para cada uma das etapas do trabalho foram realizados os passos de acordo com a Figura 4.2.




Figura 4.2 - Passos para a realização da pesquisa em cada uma das etapas

4.2.1 Objetivos dos testes

Para poder avaliar o desempenho dos métodos, é necessário verificar se eles conseguem detectar as mudanças nas séries. Sabendo que as séries lineares são séries que traduzem um estado bom do processo de previsão e as séries não lineares apresentam o pior cenário de uma previsão, foi estabelecido que as séries testes para os métodos seriam a junção das séries lineares com as séries não lineares em um ponto estabelecido, conforme a Figura 4.3.




Figura 4.3 - Série teste

Portanto, os métodos deveriam identificar a mudança a partir do ponto de junção das séries lineares com as séries não lineares.

4.3 ETAPA 1 – Carta CUSUM X Carta EWMA X TS

Nesta primeira etapa, foram analisadas as cartas CUSUM, carta EWMA e a versão simples do TS.

4.3.1 PASSO 1: Criação das séries lineares e não lineares

Para o primeiro passo, foi utilizado o *software* “Minitab® *Statistical Software*” (versão 16.1.0, Copyright © 2010, Minitab Inc., USA) para a criação das séries lineares e não lineares.

4.3.1.1 Séries lineares

Foram criadas 160 séries lineares com 25 pontos cada uma. Elas foram criadas com distribuição normal de média 0,0 e desvio padrão 1,0, através de dados aleatórios fornecidos pelo Minitab®.

As 160 séries foram divididas em 8 grupos, de acordo com a quantidade de modelos não lineares. Portanto, cada grupo continha 20 séries lineares para análise.

4.3.1.2 Séries não lineares

Para as séries não lineares foi preciso primeiro criá-las no Minitab® da mesma forma como as séries lineares. Foram criadas 160 séries de 100 pontos cada uma, com média 0,0 e desvio padrão 1,0. Depois de criadas, elas foram divididas nos 8 grupos

correspondentes das séries não lineares e submetidas cada qual nas suas respectivas equações não lineares.

Depois de criadas as séries não lineares, foi realizada a junção das séries lineares com as séries não lineares para os devidos testes.

A Figura 4.4 possui um exemplo da série SAR plotado no gráfico do Minitab®.




Figura 4.4 - Série teste (série linear + série não linear) para o modelo não linear SAR

4.3.2 PASSO 2: Testes

Ao todo foram criadas 320 séries que se juntaram em 160 séries de 125 pontos (25 lineares + 100 não lineares). Estas séries foram divididas nos grupos correspondentes dos modelos não lineares, que são: SAR, TAR NMA, NAR, STAR1, STAR2, BI1, BI2.

Em cada uma das séries foi aplicado os métodos da carta de controle EWMA, carta de controle CUSUM e TS.


4.3.2.1 Carta de Controle EWMA

O teste para a carta de controle EWMA, foi aplicado através do Minitab®. Para a variável de Peso do EWMA foi utilizado o valor de 0,2, pois são utilizados valores pequenos para detectar desvios menores dentro de uma série.

Através da carta de controle EWMA, foi possível verificar quais foram os pontos encontrados pela carta que estavam fora dos limites de controle e se o método estava identificando corretamente os pontos não lineares.

A Figura 4.5 ilustra uma carta de controle EWMA aplicada a uma das séries teste do modelo não linear SAR.

Carta de Controle EWMA para SAR1



Resultados da Carta de Controle EWMA para SAR1

O teste falhou nos pontos: 42; 43; 44; 45; 46; 68; 70; 71; 72; 73; 74; 92

Figura 4.5 - Carta de Controle EWMA para a série teste do modelo não linear SAR

Através da carta de controle EWMA, pode-se concluir que, para esta série analisada, foram encontrados apenas 12 pontos fora de controle dos 100 pontos que eram para serem identificados. Além disso, o primeiro ponto encontrado fora de controle foi o 42, ou seja, o método detectou tardiamente que a série não estava mais sob controle.

Assim, foi realizado este mesmo procedimento para as 159 séries dos oito modelos não lineares.

4.3.2.2 Carta de Controle CUSUM

O teste para a carta de controle CUSUM, foi aplicado através do Minitab®. Para a variável de *Target* ou valor alvo do CUSUM foi utilizado o valor de 0,0, pois o padrão é acumular os desvios a partir de um objetivo zero.

Através da carta de controle CUSUM, foi possível verificar quais foram os pontos encontrados pela carta que estavam fora dos limites de controle e se o método estava identificando corretamente os pontos não lineares.

A Figura 4.6 ilustra uma carta de controle CUSUM aplicada a uma das séries teste do modelo não linear SAR.




Figura 4.6 - Carta de Controle CUSUM para a série teste do modelo não linear SAR

Através da carta de controle CUSUM, pode-se concluir que, para esta série analisada, foram encontrados apenas 34 pontos fora de controle dos 100 pontos que eram para serem identificados. Além disso, o primeiro ponto encontrado fora de controle foi o 43, ou seja, o método não conseguiu identificar a mudança a partir do ponto 26.

Assim, foi realizado este mesmo procedimento para as 159 séries dos oito modelos não lineares.

4.3.2.3 Tracking Signal

O teste para o método do TS foi realizado com a fórmula baseada em Brown (1963). Ela foi definida como sendo o coeficiente entre a soma cumulativa do erro (EAC) e o desvio absoluto médio do erro (DAM), que é calculada a cada período, segundo a equação (24):

$$TS_t = \frac{EAC_t}{DAM_t} \quad (24)$$

Além disso, a soma cumulativa de erros é atualizada a cada período pela expressão (25).

$$EAC_t = e_t + EAC_{t-1} \quad (25)$$

Onde e é o erro do período t . O valor inicial de EAC é definido como zero. O cálculo do valor inicial de DAM, assim como Brown (1963) e Gardner (1983 e 1985) é realizado com o valor esperado em função do valor real do desvio padrão da componente aleatória

da série temporal. Este cálculo não utiliza os dados históricos. Os limites de controle para TS são independentes do período de tempo. Segundo Corrêa *et al.* (1997) os valores devem se distribuir em torno de zero, não ultrapassando o intervalo de ± 3 e ± 4 . Neste trabalho foi selecionado o limite de ± 4 .

Tabela 4.1 - Parte dos Resultados do teste TS para o modelo não linear SAR

Período, t	SAR1	Acumulado	Absoluto	DAM	Tracking Signal
1	-2,11	-2,11	2,11	-	-
2	0,83	-1,28	0,83	1,47	-0,87
3	-0,66	-1,95	0,66	1,20	-1,62
4	1,16	-0,78	1,16	1,19	-0,66
5	0,97	0,18	0,97	1,15	0,16
6	-0,77	-0,59	0,77	1,08	-0,54
7	-0,13	-0,72	0,13	0,95	-0,76
8	-0,63	-1,34	0,63	0,91	-1,48
9	-0,29	-1,63	0,29	0,84	-1,95
10	-0,63	-2,26	0,63	0,82	-2,77
11	0,36	-1,91	0,36	0,78	-2,46
12	1,58	-0,33	1,58	0,84	-0,39
13	0,31	-0,02	0,31	0,80	-0,03
14	-2,32	-2,34	2,32	0,91	-2,58
15	0,51	-1,84	0,51	0,88	-2,08
16	-0,09	-1,93	0,09	0,83	-2,32
17	-0,97	-2,90	0,97	0,84	-3,44
18	0,16	-2,74	0,16	0,80	-3,41
19	-0,06	-2,79	0,06	0,76	-3,66
20	0,18	-2,61	0,18	0,74	-3,55
21	-0,69	-3,30	0,69	0,73	-4,50
22	-0,29	-3,59	0,29	0,71	-5,03
23	-0,07	-3,66	0,07	0,69	-5,35
24	-0,96	-4,62	0,96	0,70	-6,64
25	0,73	-3,90	0,73	0,70	-5,59
26	1,20	-2,70	1,20	0,72	-3,77
27	-0,33	-3,03	0,33	0,70	-4,31
28	-2,84	-5,87	2,84	0,78	-7,54
29	0,00	-5,88	0,00	0,75	-7,81
30	-1,01	-6,89	1,01	0,76	-9,05
31	-0,96	-7,85	0,96	0,77	-10,23
32	-0,38	-8,23	0,38	0,76	-10,90
33	-0,61	-8,84	0,61	0,75	-11,78
34	1,56	-7,28	1,56	0,77	-9,39

A Tabela 4.1 contém uma parte dos resultados do teste de TS para o modelo não linear SAR. A Tabela completa está no Apêndice A.

Tabela 4.2 - Resultado do Teste do TS para o modelo não linear SAR

Tracking Signal	
Primeiro Ponto	21
Total de Pontos encontrados	84

A Tabela 4.2 apresenta a simulação. Foram encontrados 84 pontos que estavam fora dos limites estabelecidos para o método e o primeiro ponto foi o 21, ou seja, o método identificou que a série estava fora de controle antes do esperado.

Assim, foi realizado este mesmo procedimento para as 159 séries dos oito modelos não lineares.

4.3.3 PASSO 3: Análise dos Resultados

Depois de ter realizado os testes nas 160 séries dos 8 modelos não lineares, foi analisado quais eram os resultados e armazenado na Tabela em Apêndice B. Foi coletado os dados de quantos pontos os métodos identificaram como fora de controle e qual era o primeiro ponto encontrado.

4.3.3.1 Análise da Quantidade de Pontos Encontrados

A primeira análise é verificar quantos pontos cada método encontrou como fora de controle. Como foram simuladas séries que continham 25 pontos de séries lineares e 100 pontos de séries não-lineares, os métodos deveriam identificar que 100 estariam fora de controle.

A Tabela 4.3 apresenta a porcentagem de pontos encontrados como fora de controle em cada método.

Tabela 4.3 - Resultado da porcentagem de pontos encontrados como fora de controle em cada método

PORCENTAGEM DE PONTOS DETECTADOS	EWMA	CUSUM	TS
0%	31,25%	18,75%	0,63%
1% - 20%	43,75%	25,00%	0,00%
21% - 40%	17,50%	10,63%	1,25%
41% - 60%	6,25%	6,88%	6,88%
61% - 80%	1,25%	13,75%	21,25%
81% - 100%	0,00%	25,00%	55,63%
101% - 120%	0,00%	0,00%	14,38%

Pela Tabela 4.3 nota-se que a carta de controle EWMA, não conseguiu identificar todos os pontos que estavam fora de controle das séries analisadas. Em sua grande quantidade se concentram nas porcentagens de 0% de pontos encontrados e até 20% de

pontos, o que demonstra um desempenho fraco na detecção de mudanças das séries. A carta de controle CUSUM obteve um desempenho mediano, com porcentagens iguais nas faixas de detecção com 21%-40% e 81-100%. Já o método TS obteve melhor porcentagem de pontos encontrados na faixa de 81%-100% dos pontos fora de controle, o que significa que o TS apresenta um desempenho superior aos outros métodos, conseguindo identificar a maioria dos pontos que se encontravam fora de controle.

A Figura 4.7 apresenta o BoxPlot da quantidade de pontos fora de controle que foram encontrados. Nota-se que a carta de controle EWMA possui poucos pontos encontrados e concentrados em pequena quantidade na região de 0-20, enquanto o TS possui uma quantidade superior de pontos concentrados de 80-100. Já a carta de controle CUSUM possui quantidade de pontos mais espaçados, que vão de 0-80.




Figura 4.7 - BoxPlot da quantidade de pontos fora de controle encontrados

A Figura 4.8 apresenta o Gráfico de Probabilidade dos métodos. Verifica-se que a média de pontos encontrados do método EWMA é inferior aos demais, 12,27. Já a média do TS, 85,87, apresenta um desempenho superior aos demais.

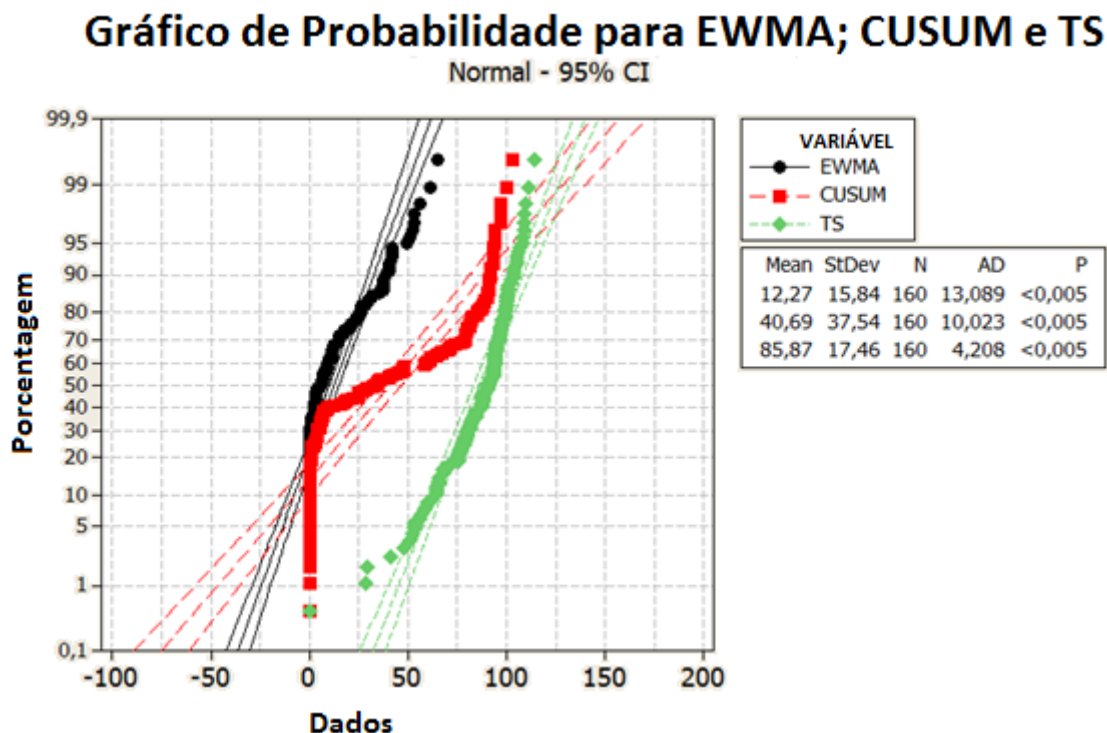


Figura 4.8 – Gráfico de probabilidades da quantidade de pontos fora de controle encontrados

Com as análises das quantidades de pontos encontrados, verifica-se que o método da carta de controle EWMA possui um desempenho inferior e fraco se comparado com os outros métodos analisados.

4.3.3.2 Análise do Primeiro Ponto Fora de Controle Encontrado

A segunda análise é verificar qual foi o primeiro ponto encontrado fora de controle.

As séries teste possuíam 25 pontos lineares unidos a 100 pontos não lineares. Ou seja, a junção da série linear com a série não linear se encontrava a partir do 25º ponto. Portanto, o primeiro ponto que deveria ser encontrado como fora de controle era o 26º ponto.

A Figura 4.9 apresenta o Gráfico Dotplot dos primeiros pontos encontrados em cada uma das 160 séries analisadas. O gráfico DotPlot compara as distribuições plotando os valores ao longo da linha. Através da Figura 4.8 pode-se concluir que o método da carta de controle EWMA possui os primeiros pontos espaçados, que variam ao longo da linha, o que significa que o desempenho do método não é considerado como bom, pois ou ele não detecta quando aconteceu a mudança da série ou ele detecta erroneamente. Já para o método da carta de controle CUSUM, pelo Dotplot conclui-se que apresenta um desempenho mediano, com concentração de pontos mais perto do desejado. Já para o

método TS, sua maior concentração se dá em torno do ponto que se desejava encontrar, assim, pode-se concluir que o TS possui um desempenho superior aos demais.




Figura 4.9 - Dotplot dos primeiros pontos encontrados como fora de controle

A Figura 4.10 apresenta o gráfico de valores individuais para os primeiros pontos encontrados como fora de controle pelos métodos. Assim como o gráfico Dotplot, o método TS apresenta um desempenho superior aos demais, pois os valores se concentram em torno do ponto desejado.




Figura 4.10 - Gráficos dos valores individuais dos primeiros pontos encontrados como fora de controle

A Figura 4.11 apresenta o gráfico das probabilidades dos primeiros valores encontrados como fora de controle. Através do gráfico, pode-se concluir, assim como nos gráficos anteriores, que o método TS possui um desempenho superior aos demais.

Gráfico de Probabilidade para EWMA; CUSUM e TS

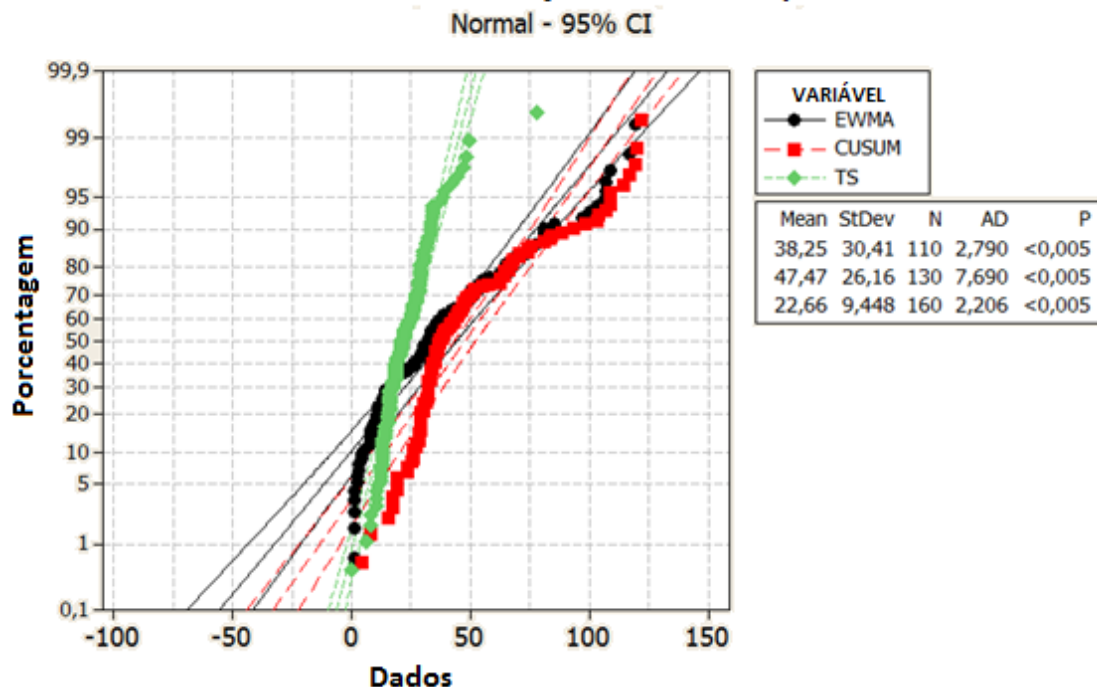


Figura 4.11 – Gráfico de probabilidades dos primeiros pontos fora de controle encontrados

4.3.4 Considerações Finais

De acordo com os resultados apresentados, conclui-se que os métodos das cartas de controle EWMA e CUSUM, possuem desempenhos diferentes do método TS. O método da carta de controle EWMA apresentou o pior desempenho dos métodos pelas séries que foram simuladas e estudadas nesta pesquisa. Pelos resultados foi observado que o método não encontra rapidamente o ponto fora de controle, apresentando um alto índice de falhas de detecção e também não conseguiu identificar todos os pontos que estavam fora de controle.

Já o método da carta de controle CUSUM, permaneceu com um desempenho mediano, que necessita de mais algumas análises para chegar em uma conclusão mais satisfatória.

O método do TS, em sua forma mais simplista, apresentou um desempenho superior aos demais métodos, pois conseguiu identificar a maioria dos pontos que estavam fora de controle e de uma forma mais rápida que os demais métodos. Entretanto, o primeiro ponto, apesar de ter sido encontrado perto do desejado, era encontrado muitas vezes antes do necessário, assumindo a condição de falso alarme.

Como conclusão desta primeira etapa, o método da carta de controle EWMA, por possuir um desempenho inferior aos demais, foi desconsiderado das futuras análises, permanecendo apenas o método da carta de controle CUSUM e TS para as próximas análises de falsos alarmes e falhas de detecção.

4.4 ETAPA 2 – Carta CUSUM X TS

Levando em consideração os resultados da Etapa 1, descrita anteriormente, o objetivo da Etapa 2 é analisar as taxas de falsos alarmes e de falhas de detecção dos principais métodos que obtiveram melhores resultados na primeira etapa: CUSUM e TS.

Para esta etapa não foram realizados novos testes, apenas foram feitas novas análises e coletados novos dados.

4.4.1 PASSO 1: Criação das séries lineares e não lineares

Como mencionado anteriormente, não foram necessárias criar novas séries, apenas coletar novos dados das séries já criadas na Etapa 1.

4.4.2 PASSO 2: Testes

Os testes coletados foram dos métodos da carta de controle CUSUM e do TS de acordo a Etapa 1.

4.4.3 PASSO 3: Análise dos Resultados

Os testes nas 160 séries dos 8 modelos não lineares foram realizados na Etapa 1, e novos dados foram coletados na Etapa 2 e estão no Apêndice C. Foram coletados a quantidade de falsos alarmes e de falhas de detecção dos métodos da carta de controle CUSUM e TS para os testes que foram realizados.

4.4.3.1 Análise de Falso Alarme

A primeira análise é verificar quantos pontos foram encontrados fora de controle quando na verdade a série estava sob controle, o que caracteriza o falso alarme. Ou seja, o método encontrou um ponto e o sinalizou como fora dos limites quando na verdade ele estava dentro dos limites estabelecidos.

A Tabela 4.4 apresenta o total de falsos alarmes encontrados em cada método em todas as 160 séries analisadas.

Tabela 4.4 - Quantidade total de falsos alarmes encontrados nos métodos

FALSO ALARME	
CUSUM	27
TS	549

Pela Tabela 4.4, pode-se perceber que a quantidade total de falsos alarmes encontrados no método da carta de controle CUSUM é menor que a quantidade de falsos alarmes encontrados no método de TS. Entretanto, McClain e Thomas (1991), investigam uma outra visão sobre os falsos alarmes. Como citado anteriormente, quando se encontra um falso alarme, o mais comum a se fazer é ignorá-lo. Entretanto, eles afirmam o contrário, pois se os dados causam falsos alarmes, irão causar também erros de previsão. Portanto, não se pode afirmar que quando o método encontra uma quantidade grande de falsos alarmes, o método possui um desempenho ruim. Mais análises devem ser realizadas para comprovar as altas quantidades de falsos alarmes.

Para comprovar que os valores são diferentes, realizou-se o teste de duas proporções no Minitab®. Do total de pontos que poderiam ser considerados como falsos alarmes, são os 25 pontos da série linear das 160 séries criadas, ou seja, 4000 pontos. De acordo com a Figura 4.12, o teste de duas proporções, atestou que ambos valores são diferentes, pois o *p-value* é menor que 0,05.

Teste e CI Duas Proporções

Amostra	X	N	Amostra p
1	27	4000	0,006750
2	549	4000	0,137250

Diferença = p (1) - p (2)

Estimativa para diferença: -0,1305

95% CI para diferença (-0,141462; -0,119538)

Teste para diferença = 0 (vs not = 0): Z = -23,33 P-Value = 0,000

Teste exato de Fisher: P-Value = 0,000

Figura 4.12 - Teste de duas proporções para a quantidade de falsos alarmes

Para verificar a distribuição das quantidades de falsos alarmes em cada uma das 160 séries, foram plotados os gráficos de pizza e de valores individuais, Figura 4.12 e 4.13, respectivamente.

Pela Figura 4.13, o gráfico de pizza, nota-se que para o método da carta de controle CUSUM, na maioria dos testes nas séries o método não detectou falsos alarmes. Em sua maioria o método encontrou no máximo sete falsos alarmes na série. Já para o método TS, 36,9% das séries analisadas, o método também não detectou falsos alarmes. Porém, a quantidade máxima encontrada foi de 14 falsos alarmes em série.




Figura 4.13 - Gráfico de pizza para a quantidade de falsos alarmes

Também pela Figura 4.14, o gráfico de valores individuais, demonstra que a grande concentração de valores para o método da carta de controle CUSUM está a baixo do valor 2. Já para o método TS, ele se mantém distribuído ao longo do gráfico atingindo o valor máximo de 14.




Figura 4.14 - Gráfico de valores individuais para a quantidade de falsos alarmes

4.4.3.2 Análise das Falhas de Detecção

A segunda análise é verificar a quantidade de falhas de detecção, ou seja, o método não conseguiu identificar os pontos que realmente estavam fora de controle.

A Tabela 4.5 apresenta a quantidade total de falhas de detecção encontrada em cada um dos métodos. Pela Tabela, pode-se concluir que o método da carta de controle CUSUM possui uma quantidade superior de falhas de detecção do que o método TS. Essa quantidade de falhas de detecção é importante analisar, pois significa que o método não conseguiu identificar que a previsão já estava fora de controle e precisa ser refeita, o que pode gerar ainda mais erros.

Tabela 4.5 - Quantidade total de falhas de detecção dos métodos

FALHA DE DETECÇÃO	
CUSUM	9515
TS	2719

Para comprovar que os valores são diferentes, realizou-se o teste de duas proporções no Minitab®. Do total de pontos que deveriam ser identificados como fora de controle, são os 100 pontos da série não linear das 160 séries criadas, ou seja, 16000 pontos. De acordo com a Figura 4.15, o teste de duas proporções, atestou que ambos valores são diferentes, pois o valor de probabilidade (*p_value*) é menor que 0,05.

Teste e CI Duas Proporções

Amostra	X	N	Amostra p
1	9515	16000	0,594688
2	2719	16000	0,169937

Diferença = $p(1) - p(2)$

Estimativa para diferença: 0,42475

95% CI para diferença: (0,415172; 0,434328)

Teste para diferença = 0 (vs not = 0): $Z = 86,92$ P-Value = 0,000

Teste exato de Fisher: P-Value = 0,000

Figura 4.15 - Teste de duas proporções para a quantidade de falhas de detecção

Através da Figura 4.16, o gráfico de valores individuais de cada uma das quantidades de falhas de detecção dos métodos, pode-se perceber que para o método da carta de controle CUSUM, os valores estão mais distribuídos, porém, em sua maior quantidade na parte superior do gráfico, em valores de 80-100. Isso quer dizer que o método da carta de controle CUSUM não conseguiu identificar, na maioria das séries, todos os pontos que estavam fora de controle. Já para o método do TS, os valores estão

mais concentrados em 0-20, o que quer dizer que, na maioria das séries, o máximo de pontos que o método não conseguiu identificar como fora de controle foi 20 pontos.

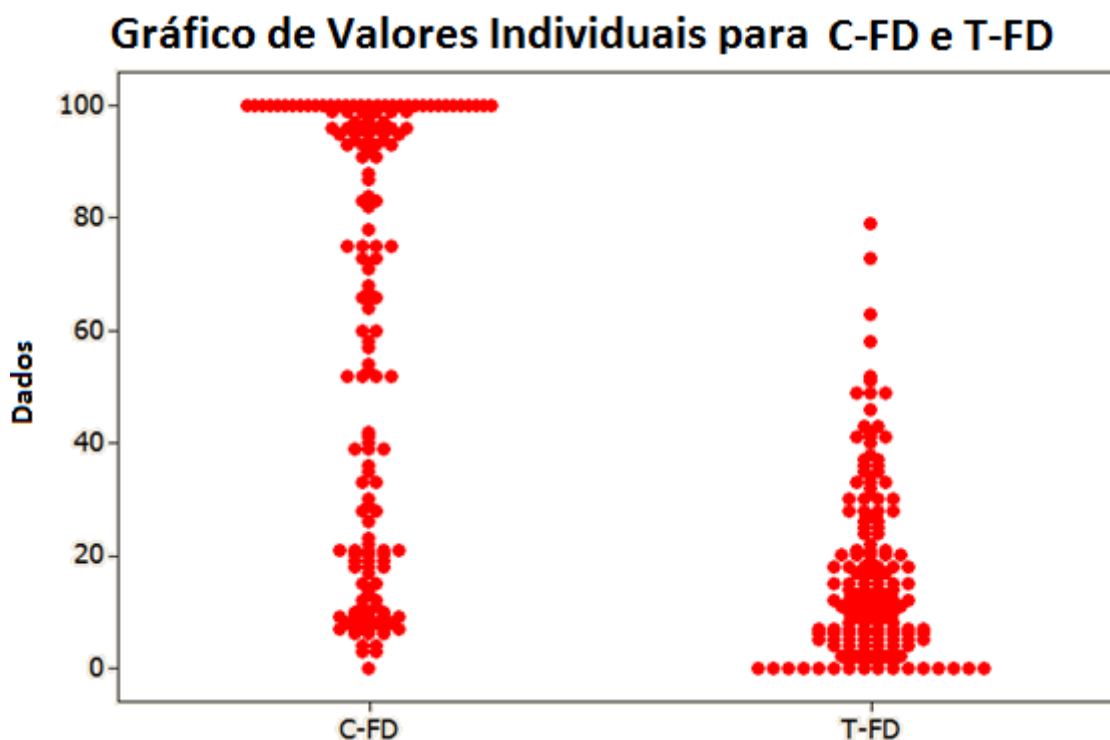


Figura 4.16 - Gráfico dos valores individuais para a quantidade de falhas de detecção dos métodos

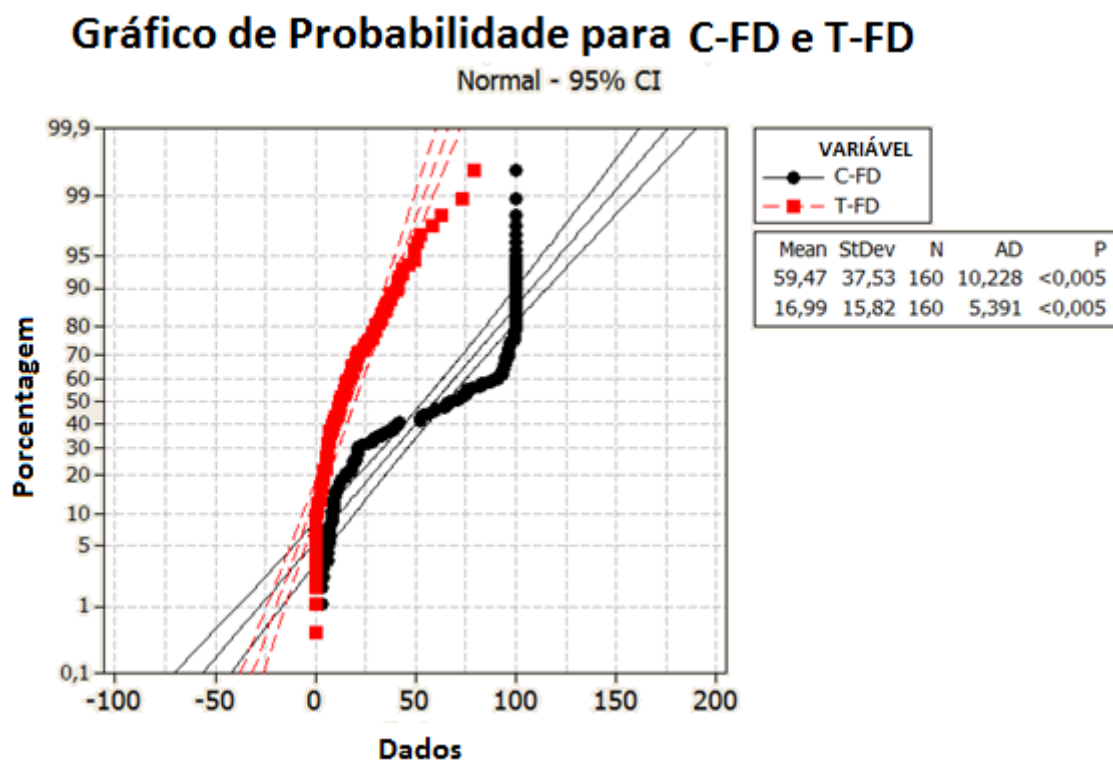


Figura 4.17 - Gráfico de probabilidades da quantidade de falhas de detecção

Através da Figura 4.17, o gráfico de probabilidade, pode-se notar que a média da quantidade de falhas de detecção do método da carta de controle CUSUM é maior (59,47) do que do método TS (16,99).

4.4.4 Considerações Finais

De acordo com os resultados apresentados, pode-se concluir que o método da carta de controle CUSUM possui baixas taxas de falsos alarmes, porém, altas taxas de falhas de detecção. Já o método de TS, possui uma quantidade um pouco maior de falsos alarmes e uma taxa menor de falhas de detecção.

Através da Figura 4.18, pode-se perceber a distribuição dos valores de falso alarme e falhas de detecção dos métodos analisados. O ideal é que a concentração dos pontos esteja próximo do 0,0, ou seja, nenhum falso alarme e nenhuma falha de detecção. Entretanto, os métodos não apresentam o estado ideal, mas pode-se perceber que o método TS possui uma melhor distribuição dos pontos perto de 0 em X (falhas de detecção) e no máximo até o valor 14 (falsos alarmes), caracterizando-o como superior que o método da carta de controle CUSUM.

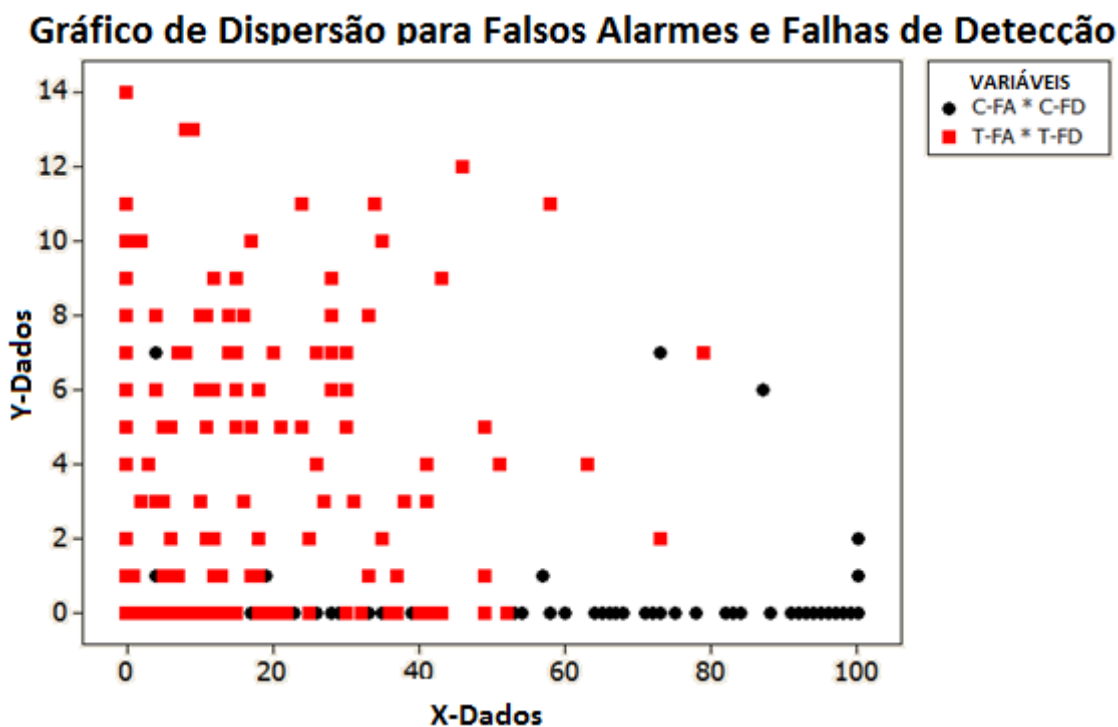


Figura 4.18 – Gráfico de Dispersão para os falsos alarmes e as falhas de detecção dos métodos

4.4 ETAPA 3 – Versões do *Tracking Signal*

Para esta etapa, foi necessário criar novas séries lineares e não lineares para poderem ser testadas pelas diferentes versões do TS.

4.4.1 PASSO 1: Criação das séries lineares e não lineares

Para o primeiro passo, foi utilizado o *software* “Minitab® *Statistical Software*” (versão 16.1.0, Copyright © 2010, Minitab Inc., USA) para a criação das séries lineares e não lineares.

4.4.1.1 Séries lineares

Nesta etapa, foram criadas 40 séries lineares para análise. Por serem 5 versões do método TS, foram criadas 5 séries lineares de 100 pontos cada uma delas para cada um dos métodos.

4.4.1.2 Séries não lineares

Para as séries não lineares foi preciso primeiro criá-las no Minitab® da mesma forma como as séries lineares. Foram criadas 40 séries de 100 pontos cada uma, com média 0,0 e desvio padrão 1,0. Depois de criadas, elas foram divididas nos 8 grupos correspondentes das séries não lineares e submetidas cada qual nas suas respectivas equações não lineares.

Depois de criadas as séries não lineares, foi realizada a junção das séries lineares com as séries não lineares para os devidos testes.

A Figura 4.19 possui um exemplo da série STAR 1 plotado no gráfico do Minitab®.




Figura 4.19 - Série teste (série linear + série não linear) para o modelo não linear SAR

4.4.2 PASSO 2: Testes

Ao todo foram criadas 80 séries que se juntaram em 40 séries de 200 pontos (100 lineares + 100 não lineares). Estas séries foram divididas nos grupos correspondentes dos modelos não lineares, que são: SAR, TAR NMA, NAR, STAR1, STAR2, BI1, BI2.

Em cada uma das séries foi aplicado as versões do método do TS. Foram coletados os dados como o **total** de pontos que o método identificou como fora de controle, quantidade de **falso alarme**, quantidade de **acerto** de pontos fora de controle e a quantidade de **falhas de detecção**.

4.4.2.1 TS de Brown

Conforme mencionado na seção 2.4.1, a versão de Brown (1959) foi a primeira a ser analisada. De acordo com a fórmula de Brown o parâmetro de suavização é restrito a $0 \leq \alpha \leq 1$, portanto, foram realizados dois testes para o TS de Brown com valores de parâmetros diferentes.

4.4.2.1.1 TS de Brown com Alpha 0,1

O primeiro teste foi definido com o parâmetro $\alpha = 0,1$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 5,604991$. Os resultados são apresentados no Apêndice D.

4.4.2.1.2 TS de Brown com Alpha 0,2

O segundo teste foi definido com o parâmetro $\alpha = 0,2$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 3,963327$. Os resultados são apresentados no Apêndice E.

4.4.2.1.3 Comparação de Resultados

Para os parâmetros de suavização diferentes, foram realizados os mesmos testes, a fim de comparar os resultados e escolher o melhor valor para o parâmetro de suavização para o comparativo final.

A Figura 4.20 mostra o gráfico Scatterplot para os resultados dos testes do método de TS de Brown. No gráfico o Y é a quantidade de falsos alarmes e o X é a quantidade de falhas de detecção. Quanto mais os pontos estão perto de $(x, y) = (0,0)$ melhor o *alpha* escolhido. Os valores para o parâmetro de 0,2 estão mais próximos quando existem menos falhas de detecção do que os valores para 0,1. Foram detectados um total de 383 falhas de detecção quando o parâmetro possui o valor de 0,1 e 244 quando seu valor é 0,2. Portanto, a taxa de falhas de detecção é menor quando *alpha* é 0,2, apesar da taxa de falsos alarmes ser maior.

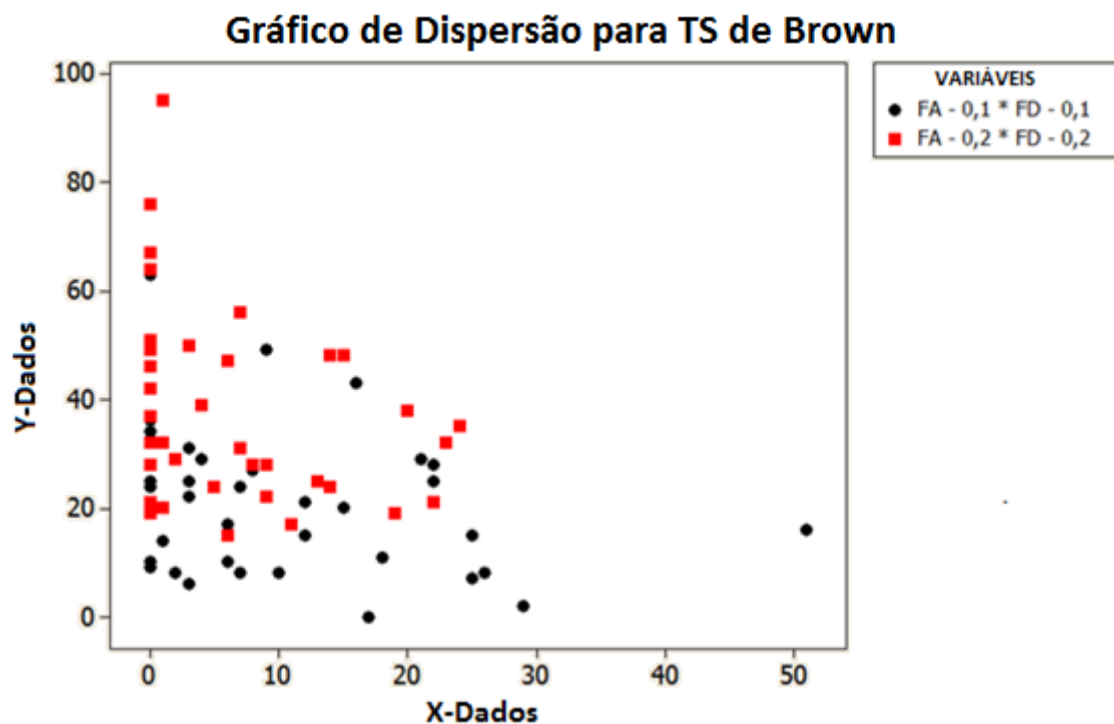


Figura 4.20 – Gráfico de Dispersão para TS de Brown

4.4.2.2 TS de Brown-Gardner

Conforme mencionado na seção 2.4.2, Gardner (1983), propôs a modificação no modelo proposto por Brown (1959). Gardner propôs a não utilização do MAD pela estimativa suavizada do desvio padrão dos erros de previsão no denominador. Ainda de acordo com a fórmula do GTS, parâmetro de suavização é restrito a $0 \leq \alpha \leq 1$, portanto, foram realizados dois testes para o TS de Brown-Gardner com valores de parâmetros diferentes.

4.4.2.2.1 TS de Brown-Gardner com Alpha 0,1

O primeiro teste foi definido com o parâmetro $\alpha = 0,1$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 5,604991$. Os resultados são apresentados no Apêndice F.

4.4.2.2.2 TS de Brown-Gardner com Alpha 0,2

O segundo teste foi definido com o parâmetro $\alpha = 0,2$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 3,963327$. Os resultados são apresentados no Apêndice G.

4.4.2.2.3 Comparação de Resultados

Para os parâmetros de suavização diferentes, foram realizados os mesmos testes, a fim de comparar os resultados e escolher o melhor valor para o parâmetro de suavização para o comparativo final.

A Figura 4.21 mostra o gráfico Scatterplot para os resultados dos testes do método de TS de Brown-Gardner, o mesmo realizado para o TS de Brown. Assim como no TS de Brown, o melhor valor para o parâmetro de suavização é 0,2.

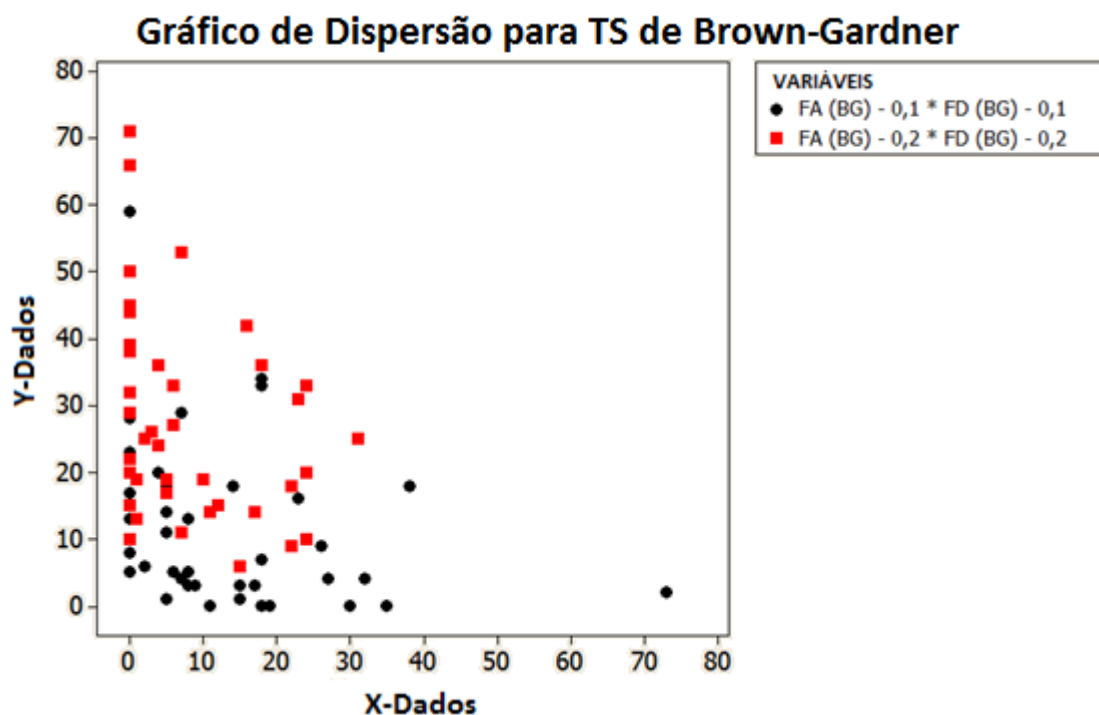


Figura 4.21 – Gráfico de Dispersão para TS de Brown-Gardner

4.4.2.3 TS de Brown-Ravi

Na seção 2.4.3, Ravi (2013), propôs uma nova modificação no modelo proposto por Brown (1959). Ravi propôs uma versão escalada de AVGTS. De acordo com a nova fórmula de Ravi, não é utilizado o parâmetro de suavização, mas sim o parâmetro N, que denota o número de períodos. Portanto, foram realizados 5 testes para o TS de Brown-Ravi com valores de N diferentes. Conforme mencionado pelo autor, os limites de controle são de ± 3 ou ± 4 , e foi escolhido o valor de mais ou menos 4. O resultado dos testes está presente no Apêndice H.

4.4.2.3.1 Comparação de Resultados

Para o parâmetro N, foram utilizados os valores de 0,2; 0,4; 0,6; 0,8 e 1. Com os resultados apresentados, foram realizadas comparações para verificar qual valor de N apresentava os melhores resultados para os testes realizados.

A Tabela 4.6 apresenta a soma total de todos os valores que são apresentados no Apêndice H. O **TOTAL** representa o total de pontos que foram sinalizados pelo método em todas as séries que foram testadas, o **FA** representa o total de falsos alarmes encontrados em todas as séries testadas, **ACERTOS** representa o total de acertos do

método em todas as séries testadas e por fim **FD** representa o total de falhas de detecção encontrados em todas as séries testadas.

Tabela 4.6 - Soma total dos valores para os testes de Brown-Ravi

N	SCALETs				
	0,2	0,4	0,6	0,8	1
TOTAL	3308	3788	4160	4411	4634
FA	151	328	626	742	919
ACERTOS	3157	3480	3597	3669	3715
FD	843	540	403	331	305

Sabe-se que o total de pontos a serem sinalizados e o total de acertos deve ser, na melhor situação, igual a 4000 pontos. E também que o total de FA e de FD deve ser igual a zero, na melhor situação. Por isso, pela tabela 8, pode-se concluir que:

- Para N igual a 0,8 e 1, o método apresentou 91,72% e 92,87%, respectivamente, acertos. Ou seja, o método conseguiu encontrar mais de 90% dos pontos que estavam fora de controle.
- Para N igual a 0,2 e 0,4, o método apresentou uma taxa pequena de falsos alarmes, entretanto, uma taxa muito grande de falhas de detecção, o que não é uma situação ideal.
- Para N igual a 0,8, o método apresentou em média 18 falsos alarmes em cada série testada e, mais ou menos, 8 falhas de detecção. Já para N igual a 1, o método apresentou em média 22 falsos alarmes e 8 falhas de detecção em cada série.

Através das Figuras 4.22 e 4.23, são plotados os BoxPlots dos falsos alarmes e das falhas de detecção para os diferentes N do método de TS de Brown-Ravi. Pela Figura 29, pode-se perceber que para os N com valores de 0,8 e 1, os valores do BoxPlots são maiores, ou seja, apresentam altas taxas de falsos alarmes. Já na Figura 30, pode-se perceber o contrário, ou seja, para os N com valores de 0,8 e 1, as taxas de falhas de detecção são menores do que os outros valores de N.

A Figura 4.24 apresenta o Scatterplot do TS de Brown-Ravi, mostrando que para N com valores de 0,8 e 1, os pontos estão mais posicionados perto dos valores de (0,0). Para os futuros testes, foi escolhido o N de 1, devidos as conclusões apresentadas.




Figura 4.22 - BoxPlot de Falsos Alarmes para TS de Brown-Ravi




Figura 4.23 - BoxPlot de Falhas de Detecção para TS de Brown-Ravi




Figura 4.24 – Gráfico de Dispersão para TS de Brown-Ravi

4.4.2.4 TS de Trigg

Conforme mencionado na seção 2.4.4, Trigg propôs, em 1964, um novo TS para corrigir algumas falhas da versão de Brown (1959). De acordo de Trigg, o parâmetro de suavização, deve assumir os valores de 0,1 ou 0,2. Portanto, foram realizados dois testes para o TS de Trigg com valores de parâmetros diferentes.

4.4.2.4.1 TS de Trigg com Alpha 0,1

O primeiro teste foi definido com o parâmetro $\alpha = 0,1$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 0,550597$. Os resultados são apresentados no Apêndice I.

4.4.2.4.2 TS de Trigg com Alpha 0,2

O segundo teste foi definido com o parâmetro $\alpha = 0,2$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 0,8$. Os resultados são apresentados no Apêndice J.

4.4.2.4.3 Comparação de Resultados

Para os parâmetros de suavização diferentes, foram realizados os mesmos testes, a fim de comparar os resultados e escolher o melhor valor para o parâmetro de suavização para o comparativo final.

A Figura 4.25 mostra o gráfico Scatterplot para os resultados dos testes do método de TS de Trigg. No gráfico o Y é a quantidade de falsos alarmes e o X é a quantidade de

falhas de detecção. Quanto mais os pontos estão perto de $(x, y) = (0,0)$ melhor o *alpha* escolhido. Portanto, como mostrado através, o TS de Trigg possui altas taxas de falhas de detecção, o que não é bom para o método. Para o melhor valor do parâmetro de suavização é 0,1, entretanto, mesmo assim o método apresenta altas taxas de falhas de detecção.




Figura 4.25 – Gráfico de Dispersão para TS de Trigg

4.4.2.5 TS de Trigg-Gardner

Conforme mencionado na seção 2.4.5, Gardner propôs a mesma modificação que realizou em Brown, no Ts de Trigg. Os parâmetros de suavização também foram escolhidos entre 0,1 e 0,2. Portanto, foram realizados dois testes para o TS de Trigg-Gardner com valores de parâmetros diferentes.

4.4.2.5.1 TS de Trigg-Gardner com Alpha 0,1

O primeiro teste foi definido com o parâmetro $\alpha = 0,1$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 0,550597$. Os resultados são apresentados no Apêndice K.

4.4.2.5.2 TS de Trigg-Gardner com Alpha 0,2

O segundo teste foi definido com o parâmetro $\alpha = 0,2$. Os limites de controle foram estabelecidos conforme mencionado na fórmula do método com o valor de $\pm 0,8$. Os resultados são apresentados no Apêndice L.

4.4.2.4.3 Comparação de Resultados

Para os parâmetros de suavização diferentes, foram realizados os mesmos testes, a fim de comparar os resultados e escolher o melhor valor para o parâmetro de suavização para o comparativo final.

A Figura 4.26 mostra o gráfico Scatterplot para os resultados dos testes do método de TS de Trigg-Gardner. Como já mencionado, quanto mais os pontos estão perto de $(x, y) = (0,0)$ melhor o α escolhido. Portanto, como mostrado através, o TS de Trigg-Gardner ainda possui altas taxas de falhas de detecção, o que não é bom para o método. Para o melhor valor do parâmetro de suavização é 0,2, entretanto, mesmo assim o método apresenta altas taxas de falhas de detecção.




Figura 4.26 - Scatterplot para TS de Trigg-Gardner

4.4.3 PASSO 3: Análise dos Resultados

A Tabela 9 mostra o resultado final dos cinco testes realizados nos cinco métodos escolhidos. Cada método possui duas variações do parâmetro de suavização, apenas o método de Brown-Ravi que possui mais variações por causa do parâmetro N. A Tabela está ordenada de acordo com a maior porcentagem de falhas de detecção. O **Total** representa os pontos total que foram encontrados como fora de controle em todas as séries que foram testadas. A **% Total** representa a porcentagem relativa de pontos encontrados. O **Acerto** representa quantos pontos que estavam fora de controle e que o método conseguiu identificá-los e a **% Acerto** a porcentagem de acerto em relação aos pontos

encontrados. O **FA** representa a quantidade de falsos alarmes que foram encontrados em todas as séries assim como **FD** representa a quantidade total de falhas de detecção de todas as séries testadas. Já a **% FA** e **% FD** representam a porcentagem de falsos alarmes e de falhas de detecção relativas ao total de pontos que podiam ser considerados como falsos alarmes e falhas de detecção. As porcentagens foram calculadas levando em consideração que são 4000 pontos totais que estavam sob controle (séries lineares) e 4000 pontos totais que não estavam sob controle (séries não lineares).

Pela Tabela 4.7, nota-se que o método de Brown, utilizando o parâmetro de suavização de 0,2, possui uma quantidade pequena de falhas de detecção, 244 pontos, ou seja, apenas 6,10% de falhas de detecção. Apesar de possuir alta taxa de falsos alarmes, para o trabalho em questão, o método será escolhido para os próximos testes, para que se possa realizar a melhora das taxas de falsos alarmes.

Tabela 4.7 - Resultados dos testes realizados nas versões do *Tracking Signal*

MÉTODO	TOTAL	% TOTAL	ACERTO	% ACERTO	FA	% FA	FD	% FD
TRIGG-GARDNER 0,2	387	9,68%	384	9,60%	1	0,03%	3124	78,10%
TRIGG-GARDNER 0,1	855	21,38%	836	20,90%	19	0,48%	3164	79,10%
TRIGG 0,2	828	20,70%	761	19,03%	67	1,68%	3239	80,98%
TRIGG 0,1	1427	35,68%	1344	33,60%	85	2,13%	2658	66,45%
BROWN-RAVI 0,2	3308	82,70%	3157	78,93%	151	3,78%	843	21,08%
BROWN-RAVI 0,4	3788	94,70%	3480	87,00%	328	8,20%	540	13,50%
BROWN-GARDNER 0,1	3994	99,85%	3474	86,85%	520	13,00%	526	13,15%
BROWN-RAVI 0,6	4160	104,00%	3597	89,93%	626	15,65%	403	10,08%
BROWN-RAVI 0,8	4411	110,28%	3669	91,73%	742	18,55%	331	8,28%
BROWN 0,1	4531	113,28%	3617	90,43%	914	22,85%	383	9,58%
BROWN-RAVI 1	4634	115,85%	3715	92,88%	919	22,98%	305	7,63%
BROWN-GARDNER 0,2	4759	118,98%	3669	91,73%	1090	27,25%	331	8,28%
BROWN 0,2	5190	129,75%	3756	93,90%	1494	37,35%	244	6,10%

4.4.4 Considerações Finais

De acordo com os resultados apresentados nos testes realizados para este trabalho, os métodos foram avaliados segundo o critério da quantidade de falsos alarmes e falhas de detecção.

A Figura 4.27 mostra o Scatterplot da quantidade total de falsos alarmes e de falhas de detecção dos métodos em análise. Como se pode notar, o Brown 0,2, possui muitos falsos alarmes, mas a menor quantidade de falhas de detecção. Por este motivo, o método de Brown, com parâmetro de suavização de valor 0,2, foi escolhido para seguir a última etapa do trabalho.




Figura 4.27 – Gráfico de Dispersão da quantidade de falsos alarmes e falhas de detecção dos métodos

4.5 ETAPA 4 - Carta Farol e Aplicação no Método de Brown

Como resultado de todos os testes realização nas Etapas 1, 2 e 3, o método de Brown, com o parâmetro de suavização de 0,2, se mostrou com melhor desempenho com as séries analisadas, pelo fato de possuir menor taxa de falhas de detecção. Os falsos alarmes, como citado no item 2.5 não significam que o método não possui um bom desempenho, mas que ele pode ser aprimorado. Como citado pelos autores McClain e Thomas (1991), é possível melhorar o desempenho do TS tirando vantagem dos falsos alarmes, por este motivo, o método de Brown foi escolhido como método para os futuros testes da Etapa 4. Nesta Etapa serão realizados diferentes passos das etapas anteriores.

4.5.1 PASSO 1: Análise das Séries Testadas

Para esta etapa, não foram necessárias criar novas séries, mas sim analisar as séries já testadas na Etapa 3.

Nesta análise, foram identificados em quais pontos o método de Brown identificou o falso alarme. O Apêndice M mostra exatamente em quais pontos o método sinalizou o falso alarme.

A Tabela 4.8 representa como os pontos encontrados como falso alarme estavam em sequência, ou seja, por exemplo, 3 representa que 3 pontos de falso alarme foram encontrados um do lado do outro.

Tabela 4.8 - Sequência dos falsos alarmes

SÉRIES	1	2	3	4	5	6	7	8	9	10	10+
STAR1	3	2	1								1
STAR2		1					2	1			
NMA	2	1	1							1	1
NAR	3	4								1	
SAR	2		4			1					
TAR	1	1	1	1							1
BI1	1	1		1	1						1
BI2	3			1	1						1
STAR1	5			1							1
STAR2	1			1		1			1		2
NMA	1			1							1
NAR											1
SAR						1					1
TAR		1	1	1	1						1
BI1	1	4		1	1	1					1
BI2	1	1		1	1						1
STAR1	1		1				1				1
STAR2	3	1	1						1	1	1
NMA	2	2			1		1				1
NAR	1		2			1	1				1
SAR	2		1	1		1	1				2
TAR	5				1		1				1
BI1	3		1		1	1					1
BI2	1	2								1	
STAR1	4	2	3	1	1						2
STAR2	2	1	2	2	2						
NMA	2	1	2					1			
NAR	2			1							1
SAR	3			1							1
TAR	2	1	1	1		1					1
BI1		1	1								1
BI2	1										3
STAR1					1						1
STAR2	1	1		1	2						1
NMA	3					1	1				2
NAR	3	2							1		1
SAR	2	2	1		2	1	1				1
TAR	3			1	1						3
BI1	4	1	1				1				
BI2											2

Pela Tabela 4.8, pode-se perceber que os pontos que em quase todas as séries testadas, foram encontrados mais de 10 pontos em sequência. Além disso, pode-se notar que a maioria dos pontos não possuem sequências muito grandes de falsos alarmes. Em

sua maioria eles são encontrados sozinhos, o que pode significar um erro da própria série, como um *outlier*.

Esta análise é importante para determinar como são espalhados os falsos alarmes e como pode-se aprender e melhorar o método de TS Brown. Pelo que se pode perceber, a relevância da quantidade de pontos em sequência é essencial para determinar o próximo passo da Etapa que é a criação de regras para a criação da carta Farol.

4.5.2 PASSO 2: Criação das Regras da Carta Farol

Conforme mencionado no item 2.6, a carta Farol ou pré-controle tem como objetivo prevenir as ocorrências de não conformidades. Esta carta apresenta um algoritmo que baseia-se em tolerâncias, por este motivo, esta carta será utilizada como base das regras para o aprimoramento do método de TS Brown.

Para utilizar a cartas Farol é necessário considerar as áreas estabelecidas como **verde, amarelo e vermelho**. O objetivo principal da carta farol para este trabalho é diminuir as altas taxas de falsos alarmes encontradas no método de TS de Brown.

De acordo com os dados estudados e testados, é proposto o algoritmo da Figura 4.28 para a carta farol deste trabalho.

Carta de farol

Análise do resultado do TS de Brown

1. Se o valor do TS estiver dentro dos limites de controle, ele receberá um novo valor CF = 0, senão CF=1.
2. Se CF = 0, então a previsão está sob controle, sinalizando como **VERDE**.
3. Senão, CF = 1, então:
 1. Será sinalizado como **AMARELO**.
 2. Uma variável SOMA, irá acumular os valores CF dos próximos 10 vizinhos do ponto encontrado.
 3. Se SOMA ≥ 10 , então a previsão precisa ser analisada, sinalizando **VERMELHO**.
 1. Se Soma > 30 , Refazer PREVISÃO. **VERMELHO**
 4. Senão:
 1. Zera a variável SOMA
 2. Volta a sinalizar como **VERDE**.

Os passos devem ser feitos para toda a previsão.

Figura 4.28 - Algoritmo da carta farol

4.5.3 PASSO 3: Testes

Com base no algoritmo da carta farol proposto para o TS de Brown deste trabalho, foram realizados os testes em cima dos resultados da Etapa 3. Ou seja, o algoritmo da carta farol foi aplicado nas 40 séries resultantes dos testes do TS de Brown, com parâmetro de suavização 0,2.

O resultado é apresentado na Tabela 4.9, com os novos valores de falsos alarmes, de falhas de detecção e de acerto do método.

Tabela 4.9 - Resultado da aplicação da carta Farol no TS de Brown 0,2

SÉRIE	NOVO FA	NOVO FD	ACERTO
STAR1	17	0	100
STAR2	0	5	95
NMA	8	16	84
NAR	2	0	100
SAR	0	1	99
TAR	9	0	100
BI1	16	0	100
BI2	20	0	100
STAR1	46	0	100
STAR2	26	0	100
NMA	71	0	100
NAR	67	0	100
SAR	50	0	100
TAR	16	11	89
BI1	4	9	91
BI2	16	0	100
STAR1	13	16	84
STAR2	11	6	94
NMA	33	0	100
NAR	11	11	89
SAR	26	18	82
TAR	34	0	100
BI1	25	0	100
BI2	0	7	93
STAR1	24	3	97
STAR2	0	8	92
NMA	0	23	77
NAR	25	0	100
SAR	12	10	90
TAR	18	0	100
BI1	21	0	100
BI2	37	22	78
STAR1	17	12	88
STAR2	28	0	100
NMA	21	0	100
NAR	15	2	98
SAR	0	27	73
TAR	49	0	100
BI1	0	14	86
BI2	27	7	93

4.5.4 PASSO 4: Análise dos Resultados

Com os resultados da aplicação da carta farol no método de TS Brown, comparou-se com os resultados sem a aplicação da carta. A Tabela 4.10 mostra o total de pontos que cada método conseguiu identificar. **FA** representa o total de falsos alarmes, **FD** representa o total de falhas de detecção e **acerto** represente a quantidade total de pontos que os métodos conseguiram identificar de forma correta.

Conforme a Tabela 4.10, nota-se que uma diminuição de 43% da quantidade total de falsos alarmes, diminuição de 6,6% da quantidade total de falhas de detecção e um aumento de 0,4 do total de acertos dos pontos que estavam fora de controle.

Tabela 4.10 - Total de pontos fora de controle

	BROWN 0,2	BROWN 0,2 COM CARTA FAROL
FA	1434	815
FD	244	228
ACERTO	3756	3772

A Figura 4.29 mostra o Scatterplot dos pontos de falsos alarmes e falhas de detecção do método de TS de Brown 0,2 (FA; FD) e da aplicação da carta farol no método de TS de Brown (NOVO FA; NOVO FD). Os pontos depois da aplicação da carta farol estão mais centrados em (0,0), ou seja, possuem menos taxas de falsos alarmes e falhas de detecção.

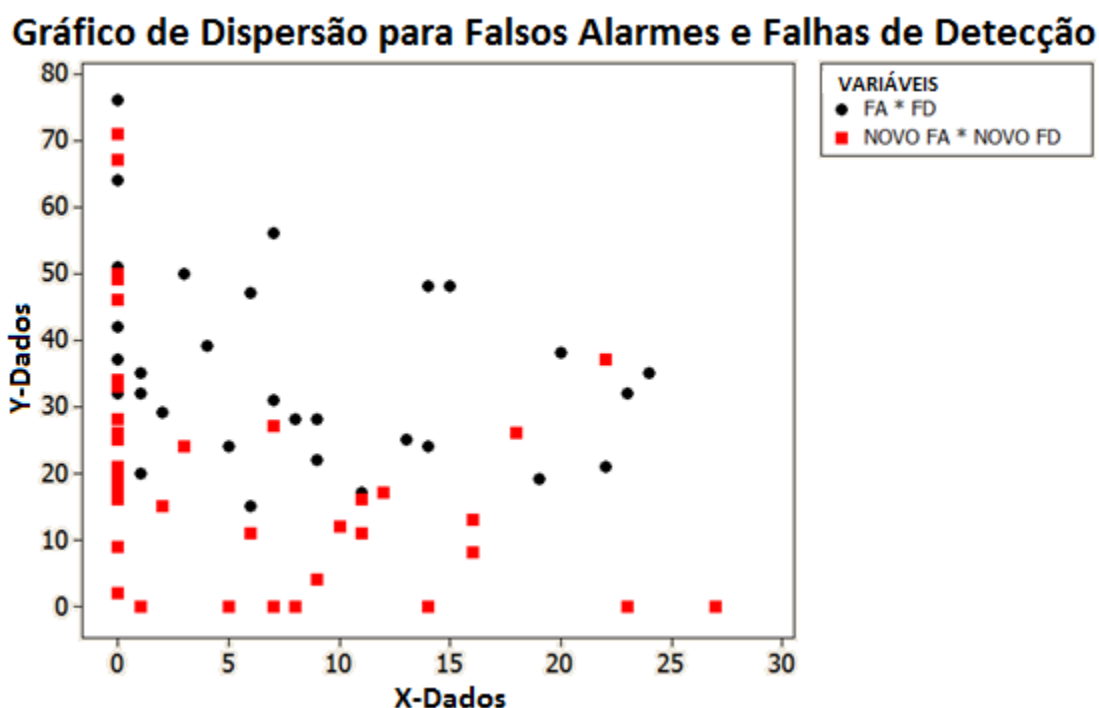


Figura 4.29 – Gráfico de Dispersão de falsos alarmes e falhas de detecção

A Figura 4.30 mostra um gráfico comparativo dos dados de falsos alarmes do método de TS de Brown antes e depois da aplicação da carta farol. Nota-se que a linha vermelha (NOVO FA), que representa os falsos alarmes depois da aplicação da carta farol, está abaixo da linha preta, que representa o método TS de Brown sem a aplicação da carta farol.




Figura 4.30 - Gráfico comparativo de falsos alarmes




Figura 4.31 - Gráfico comparativo de falhas de detecção

A Figura 4.31 mostra um gráfico comparativo dos dados de falhas de detecção do método de TS de Brown antes e depois da aplicação da carta farol. Nota-se que a linha vermelha (NOVO FD), que representa os falsos alarmes depois da aplicação da carta farol, está um pouco abaixo da linha preta, que representa o método TS de Brown sem a aplicação da carta farol.

A fim de demonstrar que os resultados da quantidade de falsos alarmes e da quantidade de falhas de detecção antes e depois da aplicação da carta farol no método de TS de Brown são diferentes um do outro, foi realizado o teste *Paired-T* no Minitab® para os dados.

A Figura 4.32 mostra o resultado do teste para a quantidade de falsos alarmes do TS de Brown antes e depois da aplicação da carta farol. Como *p_value* é 0,00, ou seja, menor que 0,05, os valores são diferentes entre si.

Teste Paired-T e CI: FA: NOVO FA

Paired T para FA E NOVO FA

	N	Media	StDev	Media SE
FA	40	35,85	14,56	2,30
NOVO FA	40	20,38	17,65	2,79
DIFERENÇA	40	15,48	7,71	1,22

95% CI para diferença das médias: (13,01; 17,94)

Teste T da diferença da média: 0 (vs not = 0): T-Value = 12,69 P-Value = 0,000

Figura 4.32 - Teste *Paired-T* para a quantidade de falsos alarmes

A Figura 4.33 mostra o resultado do teste *Paired-T* para a quantidade de falhas de detecção do TS de Brown antes e depois da aplicação da carta farol. Como *p_value* é 0,527, ou seja, maior que 0,05, os valores não são diferentes entre si.

Teste Paired-T e CI: FD; NOVO FD

Paired-T para FD e NOVO FD

	N	Media	StDev	Media SE
FD	40	35,85	14,56	2,30
NOVO FD	40	20,38	17,65	2,79
DIFERENÇA	40	15,48	7,71	1,22

95% CI para diferença das médias: (-0,869; 1,669)

Teste T da diferença da média: 0 (vs not = 0): T-Value = 0,64 P-Value = 0,527

Figura 4.33 - Teste *Paired-T* para a quantidade de falhas de detecção

Entretanto, ainda é necessário provar que os falsos alarmes e as falhas de detecção do método de TS de Brown com a carta farol é menor do que sem a aplicação da carta farol. Para isso, foi realizado o teste *Two-Sample T*, que realiza o teste para verificar se

as médias de dois grupos são independentes e diferente entre si e ainda se uma é maior que a outra.

Para os falsos alarmes, foi definida a hipótese nula: $FA < NOVO FA$. A Figura 4.34 mostra o resultado do teste realizado no Minitab®. Como p_value é 0,00, ou seja, menor que 0,05, a hipótese nula é rejeitada e $FA > NOVO FA$.

Teste Two-Sample T e CI para Falsos Alarmes

Two-Sample T para FA vs NOVO FA

	N	Média	StDev	SE Média
FA	40	35,9	14,6	2,3
NOVO FA	40	20,4	17,6	2,8

Diferença = μ (FA) - μ (NOVO FA)

Estimativa para diferença: 15,48

95% limite inferior para a diferença 9,45

T-teste para diferença = 0 (vs >): T-Value = 4,28 P-Value = 0,000 DF = 75

Figura 4.34 - Teste Two-Sample T para falsos alarmes

As Figuras 4.35 e 4.36 mostram os valores individuais e o BoxPlot dos falsos alarmes do método do TS de Brown, com parâmetro de suavização de 0,2, antes e depois da aplicação da carta farol. Nota-se, pelos gráficos, que os valores dos falsos alarmes depois da aplicação da carta farol são menores que sem a aplicação do mesmo.

Gráfico de valores Individuais dos Falsos Alarmes




Figura 4.35 - Gráfico dos valores individuais dos falsos alarmes

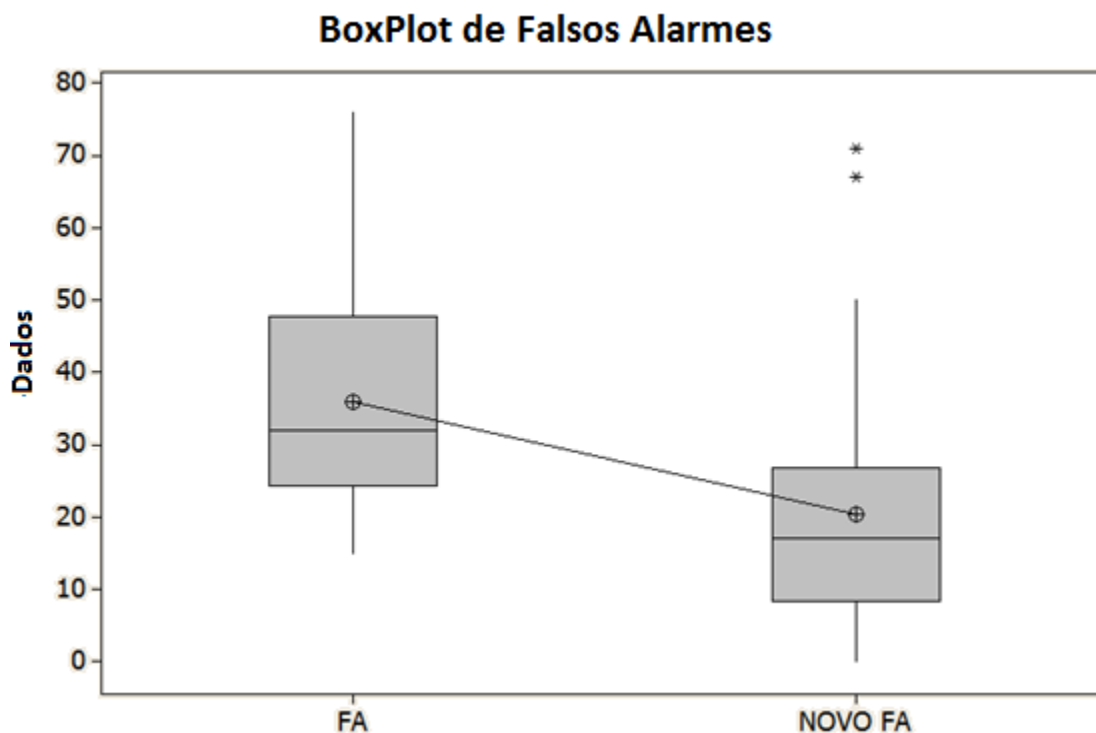


Figura 4.36 - BoxPlot dos valores de falsos alarmes

Para as falhas de detecção, foi definida a hipótese nula: $FD < NOVO FD$. A Figura 4.37 mostra o resultado do teste realizado no Minitab®. Como p_value é 0,407, ou seja, maior que 0,05, ou seja, a hipótese nula não é rejeitada.

Teste Two-Sample T e CI para Falhas de Detecção

Two-Sample T para FD VS NOVO FD

	N	Média	StDev	SE Média
FD	40	6,10	7,55	1,2
NOVO FD	40	5,70	7,64	1,2

Diferença = μ (FA) - μ (NOVO FA)

Estimativa para diferença: 0,40

95% limite inferior para a diferença -2,43

T-teste para diferença = 0 (vs >): T-Value = 0,24 P-Value = 0,407 DF = 77

Figura 4.37 - Teste *Two-Sample T* para falhas de detecção

Entretanto, através das Figuras 4.38 e 4.39, nota-se uma pequena diferença nos valores de falhas de detecção, mostrando que são menores quando aplicada a carta farol ao método de TS de Brown.

4.5.5 Considerações Finais

Com base nos resultados apresentados, conclui-se que a aplicação da carta farol ao método de TS de Brown, com parâmetro de suavização de 0,2, obteve melhores resultados do que sem a sua aplicação. O objetivo da aplicação da carta farol era a diminuição das taxas de falsos alarmes, o que foi comprovado através dos testes aplicados através do Minitab®.

Notou-se também que em algumas séries, a aplicação da carta farol também melhorou as taxas de falhas de detecção, entretanto, em algumas outras séries não foi possível essa melhora e, ainda em outras, o resultado foi inferior. Porém, o método de TS de Brown já possuía grande eficácia em relação aos outros métodos em relação as falhas de detecção, por este motivo, a melhora da quantidade de falhas de detecção não foi tão significativa, pois não era o objetivo da aplicação da carta farol.

Além disso, o desempenho do método foi superior com a carta farol aplicada, pois o mesmo foi capaz de detecção mais pontos que estavam fora de controle do que sem a sua aplicação.

Por fim, através dos testes realizados, foi possível comprovar a eficácia do método TS de Brown, como também aprimorar sua deficiência em detecção de falsos alarmes através da aplicação da carta farol.

5. 5. CONCLUSÕES

Esta dissertação contém o estudo dos principais métodos que são utilizados para detectar mudanças em previsão de séries temporais. A principal contribuição desta pesquisa foi a aplicação da técnica de carta farol que, aliada ao método que demonstrou um melhor desempenho neste estudo, obteve o aprimoramento do mesmo. Portanto, o objetivo geral da pesquisa, que era estudar os métodos de detecção de mudanças em previsão de séries temporais, identificando e analisando, através da simulação, qual o melhor método e também estabelecer regras e/ou padrões dessas detecções, foi alcançado.

Em relação aos objetivos específicos, foi possível concluir que a carta de controle EWMA, de acordo com os resultados apresentados, obteve o pior desempenho comparado aos outros métodos de detecção de mudanças em séries lineares. Concluiu-se que a carta apresentou uma menor taxa de detecção de mudanças comparados aos outros métodos e por isso, ela não foi considerada para as outras etapas deste trabalho.

Outra conclusão baseada nos objetivos deste trabalho foi o comparativo entre a versão simples do TS com a carta de controle CUSUM em relação aos falsos alarmes e as falhas de detecção. Pode-se concluir que a carta CUSUM não possui muita taxa de falsos alarmes, entretanto, muitas falhas de detecção. Em contrapartida, o método TS possui uma quantidade maior de falsos alarmes e menor de falhas de detecção. Com isso, conclui-se que nenhum dos métodos possui uma quantidade satisfatória de falsos alarmes e falhas de detecção, entretanto, eles necessitam de mais estudos e aprimoramento em suas técnicas.

Comparando o método TS e a carta CUSUM, o método TS foi escolhido como melhor em relação à carta CUSUM, pois a alta taxa de falso alarme pode fazer com que o método melhore ainda mais o seu desempenho, já as altas taxas de falhas de detecção mostram a dificuldade do método de identificar que a previsão está defasada e necessita de acompanhamento.

Com o estudo das variações do método TS, que apresentou o melhor desempenho dos métodos escolhidos neste trabalho, foi possível identificar a versão que apresentou o melhor desempenho. Os resultados apresentados levaram a conclusão de que o método do TS proposto por Brown, com parâmetro de suavização de valor 0,2, possui a menor quantidade de falhas de detecção. O método apresentou uma alta quantidade de falsos alarmes, o que o caracterizou também como potencial para a aplicação da carta farol proposta nesta dissertação.

Depois de estudados todos os métodos de detecção de mudanças, identificando os que possuem melhor desempenho, bem como as suas principais vantagens e desvantagens, foi possível, dentre as características apresentadas e definidas como principais, escolher o método de melhor desempenho (TS de Brown) para a pesquisa e estabelecer regras e padrões de detecções aplicando uma nova técnica – a carta farol – que aliada ao método, oferece um desempenho ainda melhor.

A aplicação da carta farol ao método de TS de Brown, com parâmetro de suavização de 0,2, foi capaz de elevar o desempenho do método, aprimorando a alta detecção de falsos alarmes. Em alguns casos, esta nova técnica combinada, conseguiu melhorar as falhas de detecção.

Depois de todas as etapas realizadas e os resultados comprovados, chega-se à conclusão e a principal contribuição do trabalho, a combinação das técnicas do método de TS de Brown e a carta farol, que comprovam a eficácia na detecção de mudanças em séries temporais.

5.1 Sugestões para Trabalhos Futuros

Algumas das sugestões para os trabalhos futuros:

- Criação do gráfico da carta farol combinada com o método TS de Brown.
- Estudo de como melhorar as altas quantidades de falhas de detecção que foram apresentadas por alguns dos métodos que foram apresentados.
- Criação de *software* que utilize o método TS, em suas diferentes versões, pois, ainda não é possível utilizá-lo em *software* como Minitab®.
- Estudo e criação de uma nova versão do TS que seja capaz de eliminar as deficiências que as outras versões de TS demonstraram nesta pesquisa.

APÊNDICE A – RESULTADO TS PARA MODELO NÃO LINEAR SAR

PERIODO, T	SAR1	ACUMULADO	ABSOLUTO	MAD	TRACKING SIGNAL
1	-2,11	-2,11	2,11		
2	0,83	-1,28	0,83	1,47	-0,87
3	-0,66	-1,95	0,66	1,20	-1,62
4	1,16	-0,78	1,16	1,19	-0,66
5	0,97	0,18	0,97	1,15	0,16
6	-0,77	-0,59	0,77	1,08	-0,54
7	-0,13	-0,72	0,13	0,95	-0,76
8	-0,63	-1,34	0,63	0,91	-1,48
9	-0,29	-1,63	0,29	0,84	-1,95
10	-0,63	-2,26	0,63	0,82	-2,77
11	0,36	-1,91	0,36	0,78	-2,46
12	1,58	-0,33	1,58	0,84	-0,39
13	0,31	-0,02	0,31	0,80	-0,03
14	-2,32	-2,34	2,32	0,91	-2,58
15	0,51	-1,84	0,51	0,88	-2,08
16	-0,09	-1,93	0,09	0,83	-2,32
17	-0,97	-2,90	0,97	0,84	-3,44
18	0,16	-2,74	0,16	0,80	-3,41
19	-0,06	-2,79	0,06	0,76	-3,66
20	0,18	-2,61	0,18	0,74	-3,55
21	-0,69	-3,30	0,69	0,73	-4,50
22	-0,29	-3,59	0,29	0,71	-5,03
23	-0,07	-3,66	0,07	0,69	-5,35
24	-0,96	-4,62	0,96	0,70	-6,64
25	0,73	-3,90	0,73	0,70	-5,59
26	1,20	-2,70	1,20	0,72	-3,77
27	-0,33	-3,03	0,33	0,70	-4,31
28	-2,84	-5,87	2,84	0,78	-7,54
29	0,00	-5,88	0,00	0,75	-7,81
30	-1,01	-6,89	1,01	0,76	-9,05
31	-0,96	-7,85	0,96	0,77	-10,23
32	-0,38	-8,23	0,38	0,76	-10,90
33	-0,61	-8,84	0,61	0,75	-11,78
34	1,56	-7,28	1,56	0,77	-9,39
35	-0,53	-7,81	0,53	0,77	-10,17
36	-1,81	-9,62	1,81	0,80	-12,07
37	0,03	-9,60	0,03	0,78	-12,37
38	1,23	-8,37	1,23	0,79	-10,61
39	1,00	-7,36	1,00	0,79	-9,28
40	0,21	-7,15	0,21	0,78	-9,18
41	1,59	-5,56	1,59	0,80	-6,97
42	2,06	-3,50	2,06	0,83	-4,23

PERIODO, T	SAR1	Acumulado	Absoluto	MAD	Tracking Signal
43	1,70	-1,80	1,70	0,85	-2,12
44	0,76	-1,04	0,76	0,85	-1,22
45	2,44	1,40	2,44	0,88	1,59
46	-0,54	0,86	0,54	0,88	0,98
47	-0,13	0,73	0,13	0,86	0,85
48	-2,61	-1,88	2,61	0,90	-2,10
49	-1,20	-3,08	1,20	0,90	-3,41
50	-1,05	-4,13	1,05	0,90	-4,56
51	0,65	-3,48	0,65	0,90	-3,86
52	1,39	-2,09	1,39	0,91	-2,29
53	2,40	0,31	2,40	0,94	0,33
54	0,70	1,01	0,70	0,93	1,09
55	0,64	1,65	0,64	0,93	1,78
56	-0,45	1,20	0,45	0,92	1,31
57	-2,63	-1,43	2,63	0,95	-1,51
58	-0,02	-1,45	0,02	0,93	-1,56
59	0,56	-0,89	0,56	0,93	-0,96
60	-0,84	-1,73	0,84	0,93	-1,87
61	-0,34	-2,07	0,34	0,92	-2,26
62	-0,23	-2,30	0,23	0,90	-2,54
63	-0,42	-2,71	0,42	0,90	-3,03
64	-0,98	-3,70	0,98	0,90	-4,11
65	-1,67	-5,36	1,67	0,91	-5,89
66	0,32	-5,04	0,32	0,90	-5,59
67	-1,70	-6,74	1,70	0,91	-7,38
68	-3,02	-9,77	3,02	0,94	-10,34
69	-0,93	-10,69	0,93	0,94	-11,33
70	-2,26	-12,95	2,26	0,96	-13,45
71	-0,85	-13,80	0,85	0,96	-14,36
72	-1,03	-14,84	1,03	0,96	-15,42
73	-2,65	-17,49	2,65	0,99	-17,75
74	-0,84	-18,32	0,84	0,98	-18,64
75	-0,32	-18,64	0,32	0,97	-19,13
76	-0,82	-19,46	0,82	0,97	-20,02
77	0,07	-19,39	0,07	0,96	-20,18
78	2,00	-17,39	2,00	0,97	-17,85
79	0,90	-16,49	0,90	0,97	-16,94
80	1,43	-15,06	1,43	0,98	-15,39
81	1,04	-14,02	1,04	0,98	-14,31
82	0,17	-13,85	0,17	0,97	-14,28
83	-0,30	-14,15	0,30	0,96	-14,71
84	-3,91	-18,06	3,91	1,00	-18,12
85	0,46	-17,60	0,46	0,99	-17,77
86	0,77	-16,83	0,77	0,99	-17,03
87	1,31	-15,52	1,31	0,99	-15,65
88	0,48	-15,04	0,48	0,99	-15,26

PERIODO, T	SAR1	Acumulado	Absoluto	MAD	Tracking Signal
89	0,62	-14,42	0,62	0,98	-14,69
90	0,02	-14,41	0,02	0,97	-14,84
91	1,48	-12,92	1,48	0,98	-13,23
92	1,87	-11,05	1,87	0,99	-11,21
93	0,21	-10,85	0,21	0,98	-11,09
94	0,35	-10,50	0,35	0,97	-10,81
95	-1,01	-11,51	1,01	0,97	-11,85
96	-1,66	-13,17	1,66	0,98	-13,45
97	-0,62	-13,79	0,62	0,98	-14,14
98	-0,39	-14,18	0,39	0,97	-14,63
99	-2,19	-16,37	2,19	0,98	-16,68
100	-0,98	-17,35	0,98	0,98	-17,67
101	-1,98	-19,32	1,98	0,99	-19,49
102	-1,78	-21,10	1,78	1,00	-21,12
103	-0,79	-21,89	0,79	1,00	-21,96
104	-0,99	-22,89	0,99	1,00	-22,95
105	0,53	-22,36	0,53	0,99	-22,52
106	0,36	-22,00	0,36	0,99	-22,30
107	0,69	-21,30	0,69	0,98	-21,65
108	1,64	-19,66	1,64	0,99	-19,86
109	0,57	-19,09	0,57	0,99	-19,36
110	-0,19	-19,28	0,19	0,98	-19,70
111	-0,60	-19,88	0,60	0,98	-20,38
112	0,57	-19,31	0,57	0,97	-19,87
113	0,84	-18,47	0,84	0,97	-19,03
114	0,24	-18,23	0,24	0,96	-18,91
115	0,78	-17,45	0,78	0,96	-18,13
116	-0,98	-18,43	0,98	0,96	-19,15
117	-0,93	-19,37	0,93	0,96	-20,12
118	-0,68	-20,05	0,68	0,96	-20,88
119	-0,78	-20,83	0,78	0,96	-21,73
120	-2,05	-22,88	2,05	0,97	-23,64
121	-2,71	-25,59	2,71	0,98	-26,05
122	-0,69	-26,28	0,69	0,98	-26,82
123	0,14	-26,14	0,14	0,97	-26,87
124	-0,61	-26,75	0,61	0,97	-27,58
125	-0,75	-27,50	0,75	0,97	-28,40

APÊNDICE B – RESULTADOS DOS TESTES DA ETAPA 1 – CUSUM X EWMA X TS

SÉRIE	EWMA			CUSUM			TRACKING SIGNAL		
	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%
SAR1	12	42	9,60%	34	43	27,20%	84	21	67,20%
SAR2	9	65	7,20%	48	43	38,40%	82	42	65,60%
SAR3	10	55	8,00%	47	30	37,60%	84	14	67,20%
SAR4	53	31	42,40%	100	26	80,00%	100	26	80,00%
SAR5	31	30	24,80%	77	30	61,60%	82	30	65,60%
SAR6	24	29	19,20%	70	28	56,00%	75	16	60,00%
SAR7	26	26	20,80%	79	32	63,20%	95	26	76,00%
SAR8	25	62	20,00%	93	33	74,40%	94	29	75,20%
SAR9	37	11	29,60%	93	28	74,40%	88	28	70,40%
SAR10	25	36	20,00%	82	36	65,60%	87	18	69,60%
SAR11	28	27	22,40%	59	27	47,20%	78	18	62,40%
SAR12	30	30	24,00%	79	29	63,20%	94	28	75,20%
SAR13	23	43	18,40%	72	32	57,60%	80	18	64,00%
SAR14	26	33	20,80%	61	33	48,80%	93	13	74,40%
SAR15	26	58	20,80%	88	29	70,40%	100	13	80,00%
SAR16	29	33	23,20%	67	33	53,60%	90	30	72,00%
SAR17	10	53	8,00%	72	29	57,60%	76	20	60,80%
SAR18	42	18	33,60%	91	17	72,80%	66	17	52,80%
SAR19	20	27	16,00%	81	31	64,80%	93	27	74,40%
SAR20	14	30	11,20%	65	29	52,00%	96	28	76,80%
BI1	0	-	0,00%	1	70	0,80%	52	25	41,60%
BI2	0	-	0,00%	0	-	0,00%	64	34	51,20%
BI3	4	32	3,20%	27	31	21,60%	109	16	87,20%
BI4	2	68	1,60%	4	68	3,20%	70	30	56,00%
BI5	12	38	9,60%	48	38	38,40%	81	16	64,80%
BI6	6	80	4,80%	29	50	23,20%	90	20	72,00%
BI7	7	35	5,60%	28	35	22,40%	81	21	64,80%
BI8	1	67	0,80%	3	67	2,40%	105	21	84,00%
BI9	2	117	1,60%	9	117	7,20%	28	19	22,40%
BI10	1	33	0,80%	7	33	5,60%	89	10	71,20%
BI11	3	119	2,40%	6	119	4,80%	29	49	23,20%
BI12	11	52	8,80%	48	51	38,40%	87	29	69,60%
BI13	0	-	0,00%	1	120	0,80%	85	30	68,00%
BI14	8	77	6,40%	32	74	25,60%	85	29	68,00%
BI15	3	64	2,40%	6	64	4,80%	41	22	32,80%
BI16	2	39	1,60%	17	39	13,60%	57	30	45,60%
BI17	3	72	2,40%	9	62	7,20%	75	13	60,00%
BI18	2	109	1,60%	6	109	4,80%	87	16	69,60%
BI19	3	35	2,40%	18	35	14,40%	87	15	69,60%
BI20	11	85	8,80%	35	57	28,00%	60	34	48,00%

SÉRIE	EWMA			CUSUM			Tracking Signal		
	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%
B2	9	20	7,20%	46	51	36,80%	88	20	70,40%
B3	5	28	4,00%	58	27	46,40%	110	13	88,00%
B4	8	8	6,40%	71	36	56,80%	86	33	79,20%
B5	9	62	7,20%	64	62	51,20%	99	27	76,00%
B6	6	33	4,80%	79	33	63,20%	95	22	76,00%
B7	3	81	2,40%	17	55	13,60%	97	16	77,60%
B8	6	97	4,80%	61	46	48,80%	105	21	84,00%
B9	5	50	4,00%	33	38	26,40%	80	29	64,00%
B10	8	47	6,40%	81	45	64,80%	84	23	67,20%
B11	1	50	0,80%	78	48	62,40%	79	47	63,20%
B12	11	107	8,80%	40	47	32,00%	101	19	80,80%
B13	9	38	7,20%	80	32	64,00%	95	28	76,00%
B14	5	49	4,00%	25	49	20,00%	83	18	66,40%
B15	4	81	3,20%	25	40	20,00%	94	15	75,20%
B16	14	49	11,20%	91	35	72,80%	100	26	80,00%
B17	7	106	5,60%	22	62	17,60%	78	6	62,40%
B18	17	23	13,60%	90	30	72,00%	100	8	80,00%
B19	7	26	5,60%	36	26	28,80%	75	18	60,00%
B20	10	36	8,00%	79	36	63,20%	91	34	72,80%
TAR1	0	-	0,00%	0	-	0,00%	88	18	70,40%
TAR2	0	-	0,00%	0	-	0,00%	58	27	46,40%
TAR3	0	-	0,00%	1	8	0,80%	51	29	40,80%
TAR4	0	-	0,00%	0	-	0,00%	98	26	78,40%
TAR5	0	-	0,00%	0	-	0,00%	66	14	52,80%
TAR6	0	-	0,00%	0	-	0,00%	76	20	60,80%
TAR7	0	-	0,00%	0	-	0,00%	107	18	85,60%
TAR8	0	-	0,00%	0	-	0,00%	80	31	64,00%
TAR9	0	-	0,00%	0	-	0,00%	64	29	51,20%
TAR10	0	-	0,00%	0	-	0,00%	95	31	76,00%
TAR11	1	54	0,80%	0	-	0,00%	89	26	71,20%
TAR12	0	-	0,00%	0	-	0,00%	93	15	74,40%
TAR13	0	-	0,00%	2	104	1,60%	64	25	51,20%
TAR14	0	-	0,00%	0	-	0,00%	72	21	57,60%
TAR15	0	-	0,00%	0	-	0,00%	96	16	76,80%
TAR16	0	-	0,00%	0	-	0,00%	81	26	64,80%
TAR17	0	-	0,00%	0	-	0,00%	67	24	53,60%
TAR18	0	-	0,00%	0	-	0,00%	68	38	54,40%
TAR19	0	-	0,00%	2	19	1,60%	108	16	86,40%
TAR20	0	-	0,00%	0	-	0,00%	66	14	52,80%
NAR1	3	22	2,40%	25	44	20,00%	77	22	61,60%
NAR2	0	-	0,00%	5	29	4,00%	97	29	77,60%
NAR3	2	48	1,60%	42	44	33,60%	104	22	83,20%
NAR4	0	-	0,00%	3	114	2,40%	65	23	52,00%
NAR5	0	-	0,00%	1	98	0,80%	109	17	87,20%

SÉRIE	EWMA			CUSUM			Tracking Signal		
	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%
NAR7	0	-	0,00%	5	93	4,00%	88	12	70,40%
NAR8	0	-	0,00%	16	84	12,80%	48	78	38,40%
NAR9	4	16	3,20%	40	67	32,00%	97	15	77,60%
NAR10	0	-	0,00%	1	52	0,80%	84	16	67,20%
NAR11	0	-	0,00%	0	-	0,00%	91	34	72,80%
NAR12	2	72	1,60%	48	70	38,40%	68	25	54,40%
NAR13	0	-	0,00%	5	23	4,00%	68	18	54,40%
NAR14	1	42	0,80%	5	42	4,00%	93	29	74,40%
NAR15	2	50	1,60%	34	48	27,20%	91	10	72,80%
NAR16	0	-	0,00%	7	66	5,60%	94	32	75,20%
NAR17	0	-	0,00%	0	-	0,00%	77	13	61,60%
NAR18	0	-	0,00%	4	122	3,20%	96	27	76,80%
NAR19	1	64	0,80%	7	64	5,60%	105	13	84,00%
NAR20	0	-	0,00%	4	47	3,20%	104	22	83,20%
NMA1	0	-	0,00%	1	88	0,80%	95	27	76,00%
NMA2	3	81	2,40%	7	81	5,60%	99	23	79,20%
NMA3	0	-	0,00%	0	-	0,00%	62	23	49,60%
NMA4	2	103	1,60%	4	103	3,20%	56	14	44,80%
NMA5	0	-	0,00%	0	-	0,00%	88	37	70,40%
NMA6	0	-	0,00%	0	-	0,00%	80	39	64,00%
NMA7	0	-	0,00%	3	109	2,40%	63	27	50,40%
NMA8	0	-	0,00%	0	-	0,00%	96	24	76,80%
NMA9	2	107	1,60%	12	107	9,60%	94	15	75,20%
NMA10	0	-	0,00%	8	64	6,40%	91	16	72,80%
NMA11	0	-	0,00%	0	-	0,00%	98	17	78,40%
NMA12	0	-	0,00%	1	83	0,80%	95	27	76,00%
NMA13	0	-	0,00%	4	109	3,20%	53	14	42,40%
NMA14	2	75	1,60%	4	75	3,20%	79	13	63,20%
NMA15	0	-	0,00%	0	-	0,00%	53	22	42,40%
NMA16	0	-	0,00%	0	-	0,00%	89	30	71,20%
NMA17	0	-	0,00%	0	-	0,00%	80	33	64,00%
NMA18	0	-	0,00%	0	-	0,00%	104	13	83,20%
NMA19	0	-	0,00%	5	74	4,00%	94	15	75,20%
NMA20	0	-	0,00%	0	-	0,00%	77	18	61,60%
ST1	15	1	12,00%	67	37	53,60%	92	32	73,60%
ST2	11	29	8,80%	80	45	64,00%	82	44	65,60%
ST3	21	14	16,80%	89	32	71,20%	96	17	76,80%
ST4	42	10	33,60%	74	30	59,20%	101	18	80,80%
ST5	37	2	29,60%	103	4	82,40%	93	16	74,40%
ST6	2	47	1,60%	34	19	27,20%	92	19	73,60%
ST7	18	14	14,40%	80	46	64,00%	99	21	79,20%
ST8	13	33	10,40%	97	23	77,60%	109	16	87,20%
ST9	15	35	12,00%	83	43	66,40%	92	16	73,60%
ST10	37	13	29,60%	44	15	35,20%	93	14	74,40%

SÉRIE	EWMA			CUSUM			Tracking Signal		
	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%	Qtd pontos detectados	Primeiro Ponto Detectado	%
ST12	17	11	13,60%	91	35	72,80%	101	25	80,80%
ST13	61	11	48,80%	82	29	65,60%	102	24	81,60%
ST14	12	31	9,60%	61	28	48,80%	98	28	78,40%
ST15	15	30	12,00%	86	39	68,80%	111	12	88,80%
ST16	42	10	33,60%	97	29	77,60%	101	18	80,80%
ST17	7	100	5,60%	25	35	20,00%	59	28	47,20%
ST18	51	1	40,80%	90	36	72,00%	93	33	74,40%
ST19	37	9	29,60%	87	26	69,60%	108	18	86,40%
ST20	38	4	30,40%	89	37	71,20%	94	25	75,20%
S1	23	10	18,40%	92	34	73,60%	0	0	0,00%
S2	37	13	29,60%	94	32	75,20%	97	28	77,60%
S3	41	5	32,80%	92	34	73,60%	93	33	74,40%
S4	11	14	8,80%	79	47	63,20%	99	13	79,20%
S5	35	2	28,00%	90	36	72,00%	100	21	80,00%
S6	7	24	5,60%	93	32	74,40%	104	10	83,20%
S7	31	1	24,80%	88	38	70,40%	94	19	75,20%
S8	40	8	32,00%	92	34	73,60%	102	19	81,60%
S9	15	9	12,00%	81	25	64,80%	97	29	77,60%
S10	52	3	41,60%	85	41	68,00%	90	21	72,00%
S11	21	8	16,80%	82	39	65,60%	99	11	79,20%
S12	56	1	44,80%	92	34	73,60%	114	12	91,20%
S13	26	13	20,80%	94	32	75,20%	95	22	76,00%
S14	40	7	32,00%	93	33	74,40%	94	17	75,20%
S15	11	14	8,80%	85	41	68,00%	87	28	69,60%
S16	65	3	52,00%	93	32	74,40%	98	8	78,40%
S17	49	4	39,20%	97	29	77,60%	106	21	84,80%
S18	40	8	32,00%	94	32	75,20%	99	16	79,20%
S19	21	17	16,80%	91	35	72,80%	100	12	80,00%
S20	53	1	42,40%	91	35	72,80%	93	33	74,40%

APÊNDICE C – RESULTADO PARA FALSO ALARME E FALHAS DE DETEÇÃO: CUSUM X TS

SÉRIE	CUSUM		TS	
	FA	FD	FA	FD
SAR1	0	66	5	21
SAR2	0	52	0	18
SAR3	0	53	2	18
SAR4	0	0	0	0
SAR5	0	23	0	18
SAR6	0	30	10	35
SAR7	0	21	0	5
SAR8	0	7	0	6
SAR9	0	7	0	12
SAR10	0	18	3	16
SAR11	0	41	6	28
SAR12	0	21	0	6
SAR13	0	28	8	28
SAR14	0	39	7	14
SAR15	0	12	1	1
SAR16	0	33	0	10
SAR17	0	28	3	27
SAR18	0	9	9	43
SAR19	0	19	0	7
SAR20	0	35	0	4
BI1	0	99	1	49
BI2	0	100	0	36
BI3	0	73	10	1
BI4	0	96	0	30
BI5	0	52	7	26
BI6	0	71	2	12
BI7	0	72	5	24
BI8	0	97	5	0
BI9	0	91	7	79
BI10	0	93	1	12
BI11	0	94	2	73
BI12	0	52	0	13
BI13	0	99	0	15
BI14	0	68	0	15
BI15	0	94	4	63
BI16	0	83	0	43
BI17	0	91	5	30
BI18	0	94	7	20
BI19	0	82	11	24

SÉRIE	CUSUM		TS	
	FA	FD	FA	FD
B1	6	87	9	28
B2	0	54	5	17
B3	0	42	10	0
B4	0	29	0	14
B5	0	36	0	1
B6	0	21	1	6
B7	0	83	8	11
B8	0	39	5	0
B9	0	67	0	20
B10	0	19	1	17
B11	0	22	0	21
B12	0	60	3	2
B13	0	20	0	5
B14	0	75	1	18
B15	0	75	5	11
B16	0	9	0	0
B17	0	78	4	26
B18	0	10	7	7
B19	0	64	8	33
B20	0	21	0	9
TAR1	0	100	6	18
TAR2	0	100	0	42
TAR3	1	100	0	49
TAR4	0	100	0	2
TAR5	0	100	4	41
TAR6	0	100	6	30
TAR7	0	100	7	0
TAR8	0	100	0	20
TAR9	0	100	0	36
TAR10	0	100	0	5
TAR11	0	100	0	11
TAR12	0	100	3	10
TAR13	0	98	1	37
TAR14	0	100	3	31
TAR15	0	100	1	5
TAR16	0	100	0	19
TAR17	0	100	2	35
TAR18	0	100	0	32
TAR19	2	100	10	2
TAR20	0	100	12	46
NAR1	0	75	2	25
NAR2	0	95	0	3
NAR3	0	58	4	0
NAR4	0	97	3	38
NAR5	0	99	9	0
NAR6	1	100	0	25

SÉRIE	CUSUM		TS	
	FA	FD	FA	FD
NAR8	0	84	0	52
NAR9	0	60	9	12
NAR10	0	99	5	21
NAR11	0	100	0	9
NAR12	0	52	1	33
NAR13	0	95	1	33
NAR14	0	95	0	7
NAR15	0	66	2	11
NAR16	0	93	0	6
NAR17	0	100	11	34
NAR18	0	96	0	4
NAR19	0	93	13	8
NAR20	0	96	4	0
NMA1	0	99	0	5
NMA2	0	93	3	4
NMA3	0	100	3	41
NMA4	0	96	5	49
NMA5	0	100	0	12
NMA6	0	100	0	20
NMA7	0	97	0	37
NMA8	0	100	2	6
NMA9	0	88	8	14
NMA10	0	92	6	15
NMA11	0	100	8	10
NMA12	0	99	0	5
NMA13	0	96	11	58
NMA14	0	96	7	28
NMA15	0	100	4	51
NMA16	0	100	0	11
NMA17	0	100	0	20
NMA18	0	100	13	9
NMA19	0	95	9	15
NMA20	0	100	7	30
ST1	0	33	0	8
ST2	0	20	0	18
ST3	0	11	6	10
ST4	0	26	3	2
ST5	7	4	10	17
ST6	7	73	7	15
ST7	0	20	5	6
ST8	1	4	9	0
ST9	0	17	8	16
ST10	1	57	7	14
ST11	0	40	0	22
ST12	0	9	1	0
ST13	0	18	2	0

SÉRIE	CUSUM		TS	
	FA	FD	FA	FD
ST15	0	14	11	0
ST16	0	3	4	3
ST17	0	75	0	41
ST18	0	10	0	7
ST19	0	13	8	0
ST20	0	11	1	7
S1	0	8	0	6
S2	0	6	0	3
S3	0	8	0	7
S4	0	21	7	8
S5	0	10	1	1
S6	0	7	8	4
S7	0	12	6	12
S8	0	8	6	4
S9	1	19	0	3
S10	0	15	5	15
S11	0	18	7	8
S12	0	8	14	0
S13	0	6	1	6
S14	0	7	1	7
S15	0	15	0	13
S16	0	7	3	5
S17	0	3	6	0
S18	0	6	3	4
S19	0	9	5	5
S20	0	9	0	7

APÊNDICE D – RESULTADO PARA TS DE BROWN (ALPHA = 0,1)

TS DE BROWN - ALPHA=0,1				
SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECCÃO
STAR1	113	14	99	1
STAR2	104	10	94	6
NMA	90	15	75	25
NAR	110	10	100	0
SAR	103	6	97	3
TAR	106	8	98	2
BI1	109	9	100	0
BI2	124	24	100	0
STAR1	127	43	84	16
STAR2	128	28	100	0
NMA	167	67	100	0
NAR	163	63	100	0
SAR	140	49	91	9
TAR	65	16	49	51
BI1	106	28	78	22
BI2	103	15	88	12
STAR1	93	11	82	18
STAR2	117	24	93	7
NMA	128	31	97	3
NAR	109	21	88	12
SAR	108	29	79	21
TAR	137	37	100	0
BI1	136	36	100	0
BI2	101	8	93	7
STAR1	122	25	97	3
STAR2	98	8	90	10
NMA	73	2	71	29
NAR	125	25	100	0
SAR	82	7	75	25
TAR	125	29	96	4
BI1	119	22	97	3
BI2	103	25	78	22
STAR1	105	20	85	15
STAR2	134	34	100	0
NMA	121	21	100	0
NAR	111	17	94	6
SAR	82	8	74	26
TAR	142	42	100	0
BI1	83	0	83	17
BI2	119	27	92	8

APÊNDICE E – RESULTADO PARA TS DE BROWN (ALPHA = 0,2)

TS DE BROWN - ALPHA=0,2				
SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	128	28	100	0
STAR2	119	24	95	5
NMA	112	25	87	13
NAR	121	21	100	0
SAR	119	20	99	1
TAR	119	19	100	0
BI1	128	28	100	0
BI2	132	32	100	-
STAR1	133	48	85	15
STAR2	146	46	100	0
NMA	176	76	100	0
NAR	167	67	100	0
SAR	149	56	93	7
TAR	111	35	76	24
BI1	119	28	91	9
BI2	128	28	100	0
STAR1	110	24	86	14
STAR2	135	39	96	4
NMA	151	51	100	0
NAR	124	31	93	7
SAR	134	48	86	14
TAR	151	51	100	0
BI1	142	42	100	0
BI2	109	15	94	6
STAR1	147	50	97	3
STAR2	120	28	92	8
NMA	99	21	78	22
NAR	132	32	100	0
SAR	100	19	81	19
TAR	134	95	99	1
BI1	127	29	98	2
BI2	118	38	80	20
STAR1	113	22	91	9
STAR2	149	49	100	0
NMA	137	37	100	0
NAR	131	32	99	1
SAR	109	32	77	23
TAR	164	64	100	0
BI1	106	17	89	11
BI2	141	47	94	6

APÊNDICE F – RESULTADO PARA TS DE BROWN- GARDNER (ALPHA = 0,1)

TS DE BROWN - ALPHA=0,2

SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	104	6	98	2
STAR2	99	5	94	6
NMA	77	4	73	27
NAR	86	1	85	15
SAR	96	1	95	5
TAR	97	5	92	8
BI1	105	5	100	0
BI2	109	14	95	5
STAR1	116	34	82	18
STAR2	117	17	100	0
NMA	166	66	100	0
NAR	159	59	100	0
SAR	115	33	82	18
TAR	29	2	27	73
BI1	80	18	62	38
BI2	82	0	82	18
STAR1	89	7	82	18
STAR2	94	3	91	9
NMA	122	29	93	7
NAR	88	3	85	15
SAR	93	16	77	23
TAR	128	28	100	0
BI1	123	23	100	0
BI2	95	3	92	8
STAR1	106	11	95	5
STAR2	89	0	89	11
NMA	65	0	65	35
NAR	113	13	100	0
SAR	70	0	70	30
TAR	104	18	86	14
BI1	116	20	96	4
BI2	83	9	74	26
STAR1	86	3	83	17
STAR2	117	17	100	0
NMA	108	8	100	0
NAR	97	4	93	7
SAR	72	4	68	32
TAR	113	18	95	5
BI1	81	0	81	19
BI2	105	13	92	8

APÊNDICE G – RESULTADO PARA TS DE BROWN-GARDNER (ALPHA = 0,2)

TS DE BROWN-GARDNER - ALPHA=0,2

SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	118	19	99	1
STAR2	112	17	95	5
NMA	96	18	78	22
NAR	115	15	100	0
SAR	112	13	99	1
TAR	110	10	100	0
BI1	120	20	100	0
BI2	120	24	96	4
STAR1	126	42	84	16
STAR2	138	38	100	0
NMA	171	71	100	0
NAR	166	66	100	0
SAR	146	53	93	7
TAR	94	25	69	31
BI1	109	33	76	24
BI2	103	14	89	11
STAR1	97	14	83	17
STAR2	121	27	94	6
NMA	144	44	100	0
NAR	109	19	90	10
SAR	118	36	82	18
TAR	145	45	100	0
BI1	132	32	100	0
BI2	104	11	93	7
STAR1	132	36	96	4
STAR2	103	14	89	11
NMA	86	10	76	24
NAR	122	22	100	0
SAR	87	9	78	22
TAR	123	25	98	2
BI1	123	26	97	3
BI2	108	31	77	23
STAR1	103	15	88	12
STAR2	139	39	100	0
NMA	129	29	100	0
NAR	114	19	95	5
SAR	96	20	76	24
TAR	150	50	100	0
BI1	91	6	85	15
BI2	127	33	94	6

APÊNDICE H – RESULTADO PARA TS DE BROWN-RAVI

	SCAETS				SCAETS				SCAETS				SCAETS				SCAETS			
	N = 0,2				N = 0,4				N = 0,6				N = 0,8				N = 1			
	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD
STAR1	97	0	97	3	101	2	99	1	113	13	100	0	120	20	100	0	125	25	100	0
STAR2	92	0	92	8	96	2	94	6	101	6	95	5	106	11	95	5	115	19	96	4
NMA	65	0	65	35	71	0	91	29	74	1	73	27	77	4	73	27	84	8	76	24
NAR	59	0	59	41	75	0	75	25	83	0	83	17	94	1	93	7	102	6	96	4
SAR	87	0	87	13	92	0	92	8	99	4	95	5	102	6	96	4	107	11	96	4
TAR	46	0	46	54	74	3	71	29	95	6	89	11	105	8	97	3	109	9	100	0
BI1	109	9	100	0	112	12	100	0	113	13	100	0	120	20	100	0	124	24	100	0
BI2	96	0	96	4	98	1	97	3	108	8	100	0	113	13	100	0	117	17	100	0
STAR1	89	8	81	19	101	18	83	17	114	31	83	17	122	37	85	15	128	43	85	15
STAR2	95	0	95	5	103	3	100	0	115	15	100	0	128	28	100	0	134	34	100	0
NMA	147	47	100	0	165	65	100	0	167	67	100	0	167	67	100	0	169	69	100	0
NAR	136	36	100	0	148	48	100	0	152	52	100	0	158	58	100	0	160	60	100	0
SAR	61	0	61	39	89	9	80	20	115	27	88	12	132	40	92	8	141	48	93	7
TAR	3	0	3	97	20	0	20	80	38	1	37	63	56	3	53	47	70	8	62	38
BI1	79	4	75	25	87	9	78	22	96	13	83	17	102	19	83	17	107	22	85	15
BI2	79	0	79	21	83	0	83	17	90	1	89	11	99	5	94	6	105	8	97	3
STAR1	79	0	79	21	89	7	82	18	92	9	83	17	93	10	83	17	95	10	85	25
STAR2	92	0	92	8	94	0	94	6	101	7	94	6	105	11	94	6	110	16	94	6
NMA	97	19	78	22	118	27	91	9	152	29	96	4	126	29	97	3	129	31	98	2
NAR	60	0	60	40	84	2	82	18	91	4	87	13	97	9	88	12	102	14	88	12
SAR	72	0	72	28	86	8	78	22	99	18	81	19	107	23	84	16	117	32	85	25
TAR	111	11	100	0	124	24	100	0	129	29	100	0	134	34	100	0	135	35	100	0

	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD	TOTAL	FA	ACERTO	FD
BI1	107	7	100	0	121	21	100	0	122	22	100	0	122	22	100	0	125	25	100	0
BI2	92	0	92	8	93	0	93	7	95	2	93	7	99	5	94	6	103	8	95	5
STAR1	95	0	95	5	97	0	97	3	106	9	97	3	117	20	97	3	124	26	98	2
STAR2	90	0	90	10	92	1	91	9	95	3	92	8	100	8	92	8	106	14	92	8
NMA	45	0	45	55	59	0	59	41	76	3	73	27	84	7	77	23	87	8	79	21
NAR	77	0	77	23	101	4	97	3	114	14	100	0	119	19	100	0	124	24	100	0
SAR	58	0	58	42	74	0	74	26	80	1	79	21	88	7	81	19	94	10	84	16
TAR	60	0	60	40	103	15	88	12	114	21	93	7	118	23	95	5	123	25	98	2
BI1	97	7	90	10	116	19	97	3	119	21	98	2	121	22	99	1	122	22	100	0
BI2	78	0	78	22	82	3	79	21	84	5	79	21	91	10	81	19	100	19	81	19
STAR1	75	0	75	25	83	1	82	18	91	5	86	14	97	10	87	13	105	15	90	10
STAR2	97	0	97	3	101	1	100	0	110	10	100	0	124	24	100	0	134	34	100	0
NMA	83	0	83	17	102	4	98	2	110	12	98	2	123	23	100	0	130	30	100	0
NAR	82	0	82	18	98	5	93	7	109	15	94	6	115	20	95	5	121	25	96	4
SAR	67	0	67	33	73	1	72	28	79	3	76	24	82	3	79	21	86	6	80	20
TAR	87	3	84	16	106	11	95	5	123	23	100	0	136	36	100	0	142	42	100	0
BI1	79	0	79	21	83	0	83	17	89	0	89	11	92	3	89	11	96	6	90	10
BI2	88	0	88	12	94	2	92	8	107	##	94	6	120	24	96	4	127	31	96	4

APÊNDICE I – RESULTADO PARA TS DE TRIGG (ALPHA = 0,1)

TS DE TRIGG - ALPHA=0,1

SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	92	0	92	8
STAR2	86	0	86	14
NMA	13	0	13	87
NAR	0	0	0	100
SAR	26	0	26	74
TAR	9	1	8	92
BI1	20	6	14	86
BI2	37	0	37	63
STAR1	75	4	71	29
STAR2	96	5	91	9
NMA	33	6	29	73
NAR	11	1	10	90
SAR	38	0	38	62
TAR	0	0	0	100
BI1	2	0	2	98
BI2	62	3	59	41
STAR1	67	4	63	37
STAR2	85	0	85	15
NMA	19	11	8	92
NAR	27	3	24	76
SAR	34	4	30	70
TAR	28	13	15	85
BI1	3	3	0	100
BI2	24	0	24	76
STAR1	81	3	78	22
STAR2	91	1	90	10
NMA	10	0	10	90
NAR	21	4	17	83
SAR	35	0	35	65
TAR	3	1	2	98
BI1	12	2	10	90
BI2	13	1	12	88
STAR1	53	0	53	47
STAR2	104	6	98	2
NMA	15	0	15	85
NAR	19	2	17	83
SAR	29	0	29	71
TAR	11	0	11	89
BI1	3	1	2	98
BI2	40	0	40	60

APÊNDICE J – RESULTADO PARA TS DE TRIGG (ALPHA = 0,2)

TS DE TRIGG - ALPHA=0,2

SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	61	0	61	39
STAR2	78	0	78	22
NMA	0	0	0	100
NAR	1	1	0	100
SAR	23	0	23	77
TAR	4	0	4	96
BI1	8	5	3	97
BI2	8	1	7	93
STAR1	50	2	48	52
STAR2	82	7	75	25
NMA	9	3	6	94
NAR	4	0	4	96
SAR	37	0	37	63
TAR	0	0	0	100
BI1	1	0	1	99
BI2	22	4	18	82
STAR1	37	4	33	67
STAR2	66	0	66	34
NMA	9	3	6	94
NAR	12	4	8	92
SAR	31	4	27	73
TAR	14	5	9	91
BI1	0	0	0	100
BI2	10	3	7	93
STAR1	52	3	49	51
STAR2	66	0	66	34
NMA	3	1	2	98
NAR	11	3	8	92
SAR	28	0	28	72
TAR	3	1	2	98
BI1	8	1	7	93
BI2	4	2	2	98
STAR1	22	0	22	78
STAR2	10	5	5	95
NMA	7	2	5	95
NAR	6	1	5	95
SAR	21	0	21	79
TAR	6	0	6	94
BI1	3	1	2	98
BI2	11	1	10	90

APÊNDICE K – RESULTADO PARA TS DE TRIGG-GARDNER (ALPHA = 0,1)

TS DE TRIGG-GARDNER - ALPHA=0,1

SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	79	0	79	21
STAR2	81	0	81	19
NMA	0	0	0	100
NAR	0	0	0	100
SAR	15	0	15	85
TAR	3	0	3	97
BI1	3	0	3	97
BI2	2	0	2	98
STAR1	60	0	60	40
STAR2	85	5	80	20
NMA	7	0	7	93
NAR	3	0	3	97
SAR	29	3	26	74
TAR	0	0	0	100
BI1	0	0	0	100
BI2	15	0	15	85
STAR1	36	0	36	64
STAR2	72	0	72	28
NMA	1	1	0	100
NAR	2	1	1	99
SAR	22	2	20	80
TAR	12	2	10	90
BI1	0	0	0	100
BI2	5	0	5	95
STAR1	60	0	60	40
STAR2	76	0	76	24
NMA	2	0	2	98
NAR	9	0	9	91
SAR	26	0	26	74
TAR	4	3	1	99
BI1	5	0	5	95
BI2	1	1	0	100
STAR1	22	0	22	78
STAR2	81	0	81	19
NMA	2	0	2	98
NAR	1	0	1	99
SAR	19	0	19	81
TAR	0	0	0	100
BI1	0	0	0	100
BI2	15	1	14	86

APÊNDICE L – RESULTADO PARA TS DE TRIGG-GARDNER (ALPHA = 0,2)

TS DE TRIGG-GARDNER - ALPHA=0,2

SÉRIE	TOTAL	FALSO ALARME	ACERTO	FALHA DE DETECÇÃO
STAR1	30	0	30	70
STAR2	53	0	53	47
NMA	0	0	0	0
NAR	0	0	0	0
SAR	8	0	8	92
TAR	1	0	1	99
BI1	0	0	0	0
BI2	0	0	0	0
STAR1	28	0	28	72
STAR2	56	1	55	45
NMA	0	0	0	100
NAR	0	0	0	100
SAR	15	0	15	85
TAR	0	0	0	100
BI1	0	0	0	100
BI2	3	0	3	97
STAR1	26	0	26	74
STAR2	42	0	42	58
NMA	0	0	0	100
NAR	0	0	0	100
SAR	12	0	12	88
TAR	0	0	0	100
BI1	0	0	0	100
BI2	1	0	1	99
STAR1	23	0	23	77
STAR2	28	0	28	72
NMA	0	0	0	100
NAR	2	0	0	98
SAR	7	0	7	93
TAR	0	0	0	100
BI1	4	0	4	96
BI2	0	0	0	100
STAR1	5	0	5	95
STAR2	29	0	29	71
NMA	0	0	0	100
NAR	0	0	0	100
SAR	11	0	11	89
TAR	0	0	0	100
BI1	0	0	0	100
BI2	3	0	3	97

APÊNDICE M – PONTOS DE FALSO ALARME

SÉRIES	PONTOS - FALSO ALARME
STAR1	31,34,35,43,62,63,64,65,66,67,68,69,70,71,72,73,74,75,76,77,78,81,82,83,93,94,97,99
STAR2	46,47,48,49,50,51,52,55,56,57,58,59,60,61,62,69,70,71,72,73,74,75,82,83
NMA	3,8,24,25,26,28,29,80,81,82,83,84,85,86,87,88,89,93,94,95,96,97,98,99,100
NAR	4,7,8,22,24,25,26,27,28,29,30,31,51,81,82,84,87,88,99,100
SAR	3,41,42,43,46,47,48,61,85,86,87,88,89,90,92,93,94,97,98,99
TAR	44,45,47,63,64,65,87,89,90,92,93,94,95,96,97,98,99,100
BI1	12,14,15,60,61,62,63,64,67,68,69,70,85,86,87,88,89,90,91,92,93,94,95,96,97,98,99,100
BI2	2,4,5,6,52,53,54,55,62,64,67,81,82,83,84,85,86,87,88,89,90,91,92,93,94,95,96,97,98,99,100
STAR1	2,9,20,21,23,25,47,53,55 até 100
STAR2	5,6,7,8,9,10,11,12,13,26,27,28,29,30,31,32,33,34,35,36,37,38,39,52,53,54,55,56,57,68,71,72,73,74,89 até 100
NMA	18,22,23,24,25,30 até 100
NAR	34 até 100
SAR	3,4,5,6,7,8,51 até 100
TAR	4,5,6,7,8,26,27,28,29,30,31,32,33,34,35,36,37,38,39,40,41,43,44,45,49,50,51,52,53,89,90,91,92,99,100
BI1	2,3,8,9,12,13,14,15,16,26,27,31,32,33,34,35,36,42,43,76,81,82,83,84,97,98,99,100
BI2	12,14,15,60,61,62,63,64,67,68,69,70,85 até 100
STAR1	27,28,29,31,56,57,58,59,60,61,62,72,73,74,75,76,77,78,79,80,81,82,83,84
STAR2	2,9,10,16,17,18,19,20,21,22,23,24,25,26,37,38,39,40,41,42,43,44,45,64,65,66,67,68,69,70,71,72,73,75,77,79,80,81,100
NMA	12,14,15,16,17,18,21,22,23,26,27,28,29,30,31,32,35,36,68 até 100
NAR	2,3,4,8,16,17,18,19,20,21,22,50,5,52,53,54,55,68,69,70,85,86,87,88,89,90,91,92,93,94,95
SAR	3,5,6,7,8,9,10,11,19,22,23,24,38,39,40,41,42,43,60,61,62,63,73,74,75,76,77,78,79,80,81,82,83,84,87 até 100

SÉRIES	Pontos - Falso Alarme
TAR	17,23,25,27,30,32,33,34,35,36,37,38,39,40,41,42,43,44,45,46,47,48,49,66,67,68,69,70,71,72,78,79,80,81,82
BI1	3,14,18,19,20,31,32,33,34,35,57,58,59,60,61,62,70,76 até 100
BI2	16,32,33,34,35,36,37,38,39,40,41,44,45,80,81
STAR1	4,9,12,19,20,22,25,26,27,28,29,32,33,34,36,37,38,39,40,41,42,43,44,45,46,47,48,55,56,57,65,66,68,68,72,73,74,75,76,77,78,79,80,81,82,84,85,87,88,89
STAR2	9,10,11,12,13,29,30,32,33,34,45,57,58,59,60,73,74,75,82,83,84,85,87,88,89,90,91,94
NMA	19,25,26,27,33,34,38,53,54,55,82,83,84,85,86,87,88,89,96,97,98
NAR	4,8,25,26,27,28,29,30,31,32,33,34,35,36,37,38,39,40,41,42,43,48,49,50,51,95,96,97,98,99,100
SAR	23,27,28,29,30,31,32,33,34,35,36,37,38,49,50,51,52,71,83
TAR	3,4,5,6,7,8,13,14,17,55,56,57,60,61,62,63,77,83 até 100
BI1	32,33,67,68,69,77 até 100
BI2	3,4,5,6,7,8,9,10,11,12,13,14,19,36,37,38,39,40,41,42,43,44,45,46,86,87,88,89,90,91,92,93,94,95,96,97,98,99,100
STAR1	8,9,10,11,12,13,14,15,16,17,18,19,20,21,22,23,24,67,68,69,70
STAR2	4,5,24,25,26,27,37,38,40,41,46,47,48,49,50,51,52,53,54,55,56,57,58,59,60,61,62,63,64,65,66,67,68,69,73,74,75,76,77,82,83,84,85,86,95,97,98,99,100
NMA	11,12,13,14,15,16,19,21,22,23,24,25,26,27,31,42,43,44,45,46,47,48,49,50,51,52,53,82,92 até 100
NAR	3,4,35,36,37,38,39,40,41,42,43,44,45,46,47,48,49,56,58,80,81,82,83,84,85,86,87,88,89,91,98,99
SAR	16,17,26,27,28,29,30,32,53,55,56,57,78,79,81,82,83,84,85,86,88,89,90,91,92,94 até 100
TAR	3,8,11,12,13,14,15,17,18,19,20,21,22,23,24,25,26,27,28,29,30,31,32,33,34,35,36,37,38,40,58,61,62,63,64,67,70,73,74,75,76,77,78,79,80,81,82,83,84,85,86,87,88,89,90,92 até 100
BI1	16,17,18,20,43,52,71,72,73,74,75,76,77,84,86,88,89
BI2	3,4,5,6,7,8,9,10,11,12,13,14,15,16,19,20,21,22,23,24,25,26,27,28,29,30,35,38,39,44,45,46,54,55,56,57,58,59,60,61,66,67,68,69,70,71

REFERÊNCIAS

- ALSTRØM, P.; MADSEN, P. **Tracking signals in inventory control systems A simulation study**. International journal of production economics, v. 45, n. 1, p. 293-302, 1996.
- APPOLINÁRIO, F. **Metodologia da Ciência – filosofia e prática da pesquisa**. São Paulo: Editora Pioneira Thomson Learning, 2006.
- AVENT, R. K. et al. **A Monte Carlo technique for signal level detection in implanted intracranial pressure monitoring**. Annals of biomedical engineering, v. 15, n. 1, p. 79-89, 1987.
- BATTY, M. **Monitoring an exponential smoothing forecasting system**. OR, p. 319-325, 1969.
- BALESTRASSI, P. P., POPOVA, E., PAIVA, A. D., LIMA, J. M.; **Design of experiments on neural network's training for nonlinear time series forecasting**. Neurocomputing, 72(4), 1160-1178, 2009.
- BERTRAN, J.W.; FRANSOO, J.C.; **modelling and Simulation: operations management research methodologies using quantitative modeling**. International journal of Operations & Production Management, v.22, p.241-264, 2002.
- BIAU, D. J. et al. **Monitoring the quality of total hip replacement in a tertiary care department using a cumulative summation statistical method (CUSUM)**. Journal of Bone & Joint Surgery, British Volume, v. 93, n. 9, p. 1183-1188, 2011.
- BISSEL, A.F. **Cusum Techniques for Quality Control**. Applied Statistics, v.18, 1969.
- BOX, G.E.P., JENKINS, G.M., e REINSEL, G. **Time Series Analysis: Forecasting and Control**. Englewood Cliffs: Prentice Hall, third edition, 1994.
- BRENCE, J. R.; MASTRANGELO, C. M. **Parameter selection for a robust tracking signal**. Quality and Reliability Engineering International, v. 22, n. 4, p. 493-502, 2006.
- BROWN, R. G. **Statistical forecasting for inventory control**. 1959.
- BROW, R.G. **Smoothing, Forecasting and Prediction of Discrete Time Series**. Prentice-Hall, Englewood Cliffs, New Jersey, 1963
- BROWN, R. G. **Advanced Service Parts Inventory Control**. Norwich. VT. 1982.
- BROWN, R. G. **Smoothing, forecasting and prediction of discrete time series**. Courier Corporation, 2004.
- CAMPOS, R. J. **Previsão de séries temporais com aplicações a séries de consumo de energia elétrica**. Tese de Doutorado. Universidade Federal de Minas Gerais, Belo Horizonte/MG, 2008.
- CHEN, H.; CHEN, Y. **CUSUM Residual Charts for Monitoring Enterovirus Infections**. In: Proceedings of the Institute of Industrial Engineers Asian Conference 2013. Springer Singapore, 2013. p. 871-878.
- CHERNICK, M. R. **Methods for Applying a Tracking Signal to Monitor Single Exponential Smoothing Forecast**. ARMY MATERIEL SYSTEMS ANALYSIS ACTIVITY ABERDEEN PROVING GROUND MD, 1972.
- CHUNG, C. A. **Simulation Modeling Handbook: a practical approach**. Washington, D.C: CRC Press, 2004.

- CORRÊA, H.; GIANESI, I.; CAON, M. **Planejamento, Programação e Controle da Produção MRP II / ERP: Conceitos, Uso e Implementação**. São Paulo: Atlas 1997.
- COWLING, B. J. et al. **Methods for monitoring influenza surveillance data**. International journal of epidemiology, v. 35, n. 5, p. 1314-1321, 2006.
- CRUZ, A.C., AMARAL, C.E., ALVES, C.C., HENNING, E. E CORAZZA, E.J.; **Avaliação e Monitoramento do Desempenho de Modelos de Previsão, IV Congresso de Engenharia de Produção**, Ponta Grossa, PR, Brasil, 2014.
- DALAL, P. G. et al. **Learning curves of novice anesthesiology residents performing simulated fibreoptic upper airway endoscopy**. Canadian Journal of Anesthesia/Journal canadien d'anesthésie, v. 58, n. 9, p. 802-809, 2011.
- De GOOIJER, J. G. e HYNDMAN, R. J. **25 Years of Time Series Forecasting**. International Journal of Forecasting, 22(3):443–473, 2006.
- DENG, Y.; JARAIEDI, M.; ISKANDER, W. H. **Tracking signal test to monitor an intelligent time series forecasting model**. In: Photonics Technologies for Robotics, Automation, and Manufacturing. International Society for Optics and Photonics, 2004. p. 149-160.
- FISCHER, T. et al. **Change-points in climate extremes in the Zhujiang River Basin, South China, 1961–2007**. Climatic Change, v. 110, n. 3-4, p. 783-799, 2012.
- GARDNER, E. S. **Automatic monitoring of forecast errors**. Journal of Forecasting, v. 2, n. 1, p. 1-21, 1983.
- GARDNER JR, E. S. **CUSUM vs smoothed-error forecast monitoring schemes: Some simulation results**. Journal of the Operational Research Society, p. 43-47, 1985.
- GORR, W.; MCKAY, S. A. **Application of tracking signals to detect time series pattern changes in crime mapping systems**. 2003.
- HARRISON, P. J.; DAVIES, Owen L. **The use of cumulative sum (CUSUM) techniques for the control of routine forecasts of product demand**. Operations Research, v. 12, n. 2, p. 325-333, 1964.
- HAWKINS, D.M. **A CUSUM for a Scale Parameter**, Journal of Quality Technology, 13(4), p.228-231, 1981.
- HAWKINS, D.M.; OLWELL, D.H; **Cumulative Sum Charts and Charting for Quality Improvement**, Statistics for Engineering and Physical Science, Springer,1998.
- HUNTER, J.S. **The Exponentially Weighted Moving Average**. Journal of Quality Technology, v. 18, n. 4, 1986.
- HUTWAGNER, L. C. et al. **Using laboratory-based surveillance data for prevention: an algorithm for detecting Salmonella outbreaks**. Emerging infectious diseases, v. 3, n. 3, p. 395, 1997.
- JARDIM, F. S. **Técnicas para Detecção de Viés em Previsão de Demanda—Comparação de Desempenhos**. 2013. Tese de Doutorado. PUC-Rio.
- JOHNSON, R.A. e BAGSHAW M. **The Effect of Serial Correlation on the Performance of CUSUM Tests**. Technometrics, v.16, n. 1, 1974.
- LEWIS, C. D. **Statistical monitoring techniques**. Medical and biological engineering, v. 9, n. 4, p. 315-323, 1971.

- LI, Y.; LANGE, M.; STOCKS, C. **Monitoring forecasting systems—revisit Trigg’s tracking signal**. In: 32nd Annual International Symposium on Forecasting (ISF2012), Boston, MA, USA, available at: www.forecasters.org/proceedings12/LiYikangISF2012.pdf (accessed January 25, 2013). 2012.
- LUCAS, J.M.; SACCUCCI, M.S. **Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements**. *Technometrics*, v. 32, n. 1, 1990
- MAGALHÃES, R. R.; CYMROT, R. **Técnicas de monitoramento e controle estatístico de processos através de cartas de controle da soma cumulativa e de cartas de controle de média móvel exponencialmente ponderada**. Encontro Latino Americano de Iniciação Científica e VI Encontro Latino Americano de Pós-Graduação—Universidade do Vale do Paraíba, 2006.
- MARTINICH, J. S. **Production and operations management: An applied modern approach**. John Wiley & Sons, 2008.
- MARTINS, R.A.; MELLO, C.H.P.; TURRIONI, J.B.; **Guia para Elaboração de monografia e TTC em Engenharia de Produção**. São Paulo. Editora Atlas. 2014.
- MATHIAS, D.B.; REBELATO, M.G. **Aplicação da Carta de Farol no monitoramento de torque de parafusos numa linha de montagem: um estudo de caso**. XXVI Encontro Nacional de Engenharia de Produção, Florianópolis, SC, Brasil, 2004.
- MCCLAIN, J. O. **Dominant tracking signals**. *International Journal of Forecasting*, v. 4, n. 4, p. 563-572, 1988.
- MCCLAIN, J. O.; THOMAS, L. J. **Using false alarms to improve forecast accuracy**. *European journal of operational research*, v. 55, n. 2, p. 218-227, 1991.
- MIGUEL, P.A.C.; FLEURY, A.; MELLO, C.H.O.; NAKANO, D.N.; TURRIONI, J.B.; LEE HO, L.; MORABITO, R.; MARTINS, R.A.; PUREZA, V. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. Rio de Janeiro: Elsevier, 2010.
- MINGOTI, S. A.; YASSUKAWA, F. R.S. **Uma comparação de gráficos de controle para a média de processos autocorrelacionados**. *Revista Eletrônica Sistemas & Gestão*, v. 3, n. 1, p. 55-73, 2008.
- MONTGOMERY, D.C. **Introduction to Statistical Quality Control**. 3th. ed. New York: John Wiley, 1996.
- MONTGOMERY, D. C. **Introduction to statistical quality control**. John Wiley & Sons, 2007.
- MONTGOMERY, D. C., JENNINGS, C. L.; KULAHCI, M., **Introduction to time series analysis and forecasting**, Vol. 526, John Wiley & Sons, 2011.
- MORETTIN, P.A.; TOLOI, C.M.C.; **Análise de séries temporais**. 2a. ed. São Paulo: Edgard Blucher, 2006.
- MORETTIN, P.A.; TOLOI, C.M.C.; **Previsão de séries temporais**. 2a. ed. São Paulo:Atual Editora; 1985.
- MORTON, A. P. et al. **The application of statistical process control charts to the detection and monitoring of hospital-acquired infections**. *Journal of quality in clinical practice*, v. 21, n. 4, p. 112-117, 2001.
- NAVIDI, W. **Probabilidade e Estatística para Ciências Exatas**. McGraw Hill Brasil, 2012.

- ONAFOWORA, O. A.; OWOYE, O. **Modelling international tourism demand for the Caribbean**. *Tourism Economics*, v. 18, n. 1, p. 159-180, 2012.
- PAGE, E.S.; **Continous Inspection Schemes**, *Biometrika*, v. 41, 1954.
- PAGE, E. S. **A test for a change in a parameter occurring at an unknown point**. *Biometrika*, p. 523-527, 1955.
- RAVI, P. S. **An analysis of a widely used version of the CUSUM tracking signal**. *Journal of the Operational Research Society*, v. 65, n. 8, p. 1189-1192, 2013.
- RISTROPH, J. H. **Monte Carlo modeling of the tracking signal for forecast errors in computer integrated manufacture**. *Computers & Industrial Engineering*, v. 19, n. 1, p. 67-71, 1990.
- ROBERTS, S.W.; **Control Chart Tests Based on Geometric Moving Averages**, *Technometrics*, v. 1, 1959.
- ROBINSON, S. **Simulation Projects: building the right conceptual model**. *Industrial Engineering*, September 1994.
- ROGERSON, P. A.; YAMADA, I. **Approaches to syndromic surveillance when data consist of small regional counts**. *Morbidity and Mortality Weekly Report*, p. 79-85, 2004.
- S RUSSELL, R.; W TAYLOR, B. **Operations Management Creating Value Along the Supply Chain**. 2011.
- SASTRI, T.; FLORES, B.; VALDÉS, J. **Detecting points of change in time series**. *Computers & Operations Research*, v. 16, n. 3, p. 271-293, 1989.
- SCHROEDER, M. A., *Carta de Farol: Um estudo de Caso*. EFEI, Itajubá-MG, 2003.
- SOARES, G. M. V. P. P., **Aplicação do Controle Estatístico de Processo em Indústrias de Bebidas: Um Estudo de Caso**. Dissertação (Mestrado) Programa de Pós Graduação em Engenharia de Produção da UFSC – SC, 2001.
- STEVENSON, W. **Operations management**. McGraw-Hill/Irwin, 2011.
- SLUTSKY, E. **Über stochastische asymptoten und grenzwerte**. *Amministrazione del" Metron"*, 1925.
- SHU, M., KUNG, J., NGUYEN, T., HSU, B.; **Dynamically monitoring the service efficiency with tracking signals**. *Industrial Management & Data Systems*, v. 113, n. 9, p. 1334-1350, 2013.
- SUPERVILLE, C. R. **An Evaluation of Tracking Signals in Forecast Monitoring**. *Journal of the Chilean Statistical Society*, v. 11, n. 1-2, p. 17-27, 1995.
- TRIGG, D. W. **Monitoring a forecasting system**. *OR*, p. 271-274, 1964.
- TRIGG, D. W.; LEACH, A. G. **Exponential smoothing with an adaptive response rate**. *OR*, p. 53-59, 1967.
- DE VARGAS, V. D. C. C., & LOPES, L. F. D. **Estudo comparativo do desempenho das cartas de controle CUSUM e EWMA**. XXIII Encontro Nacional de Engenharia de Produção, Salvador, BA, Brasil, 2001.
- VERÍSSIMO, A. J.; ALVES, C. C. ; HENNING, E.; AMARAL, C.E.; CRUZ, A.C.; **Métodos Estatísticos de Suavização Exponencial Holt-Winters para Previsão de Demanda em uma Empresa do Setor Metal Mecânico**, *Gestão Industrial*, v. 8, n. 4, p. 154-171, 2012.

YANG, Z. et al. **The causes of flow regime shifts in the semi-arid Hailiutu River, Northwest China.** *Hydrology and Earth System Sciences*, 12,(1), 2012.

WOODALL, W. H. **The use of control charts in health-care and public-health surveillance.** *Journal of Quality Technology*, v. 38, n. 2, p. 89-104, 2006.

WOODALL, W. H. et al. **On the use and evaluation of prospective scan methods for health-related surveillance.** *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, v. 171, n. 1, p. 223-237, 2008.