

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS NATURAIS E EXATAS
CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA E MODELAGEM
QUANTITATIVA

Ícaro Romolo Sousa Agostino

**MONITORAMENTO E AJUSTE DE MODELOS DE PREVISÃO
BASEADO EM GRÁFICOS DE CONTROLE**

Santa Maria, RS
2020

Ícaro Romolo Sousa Agostino

**MONITORAMENTO E AJUSTE DE MODELOS DE PREVISÃO BASEADO EM
GRÁFICOS DE CONTROLE**

Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de **Especialista em Estatística e Modelagem Quantitativa**.

Orientador: Prof. Dr. Adriano Mendonça Souza

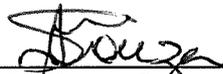
Santa Maria, RS
2020

Ícaro Romolo Sousa Agostino

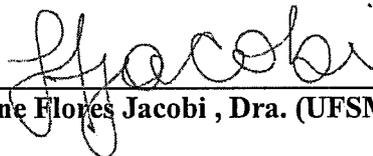
**MONITORAMENTO E AJUSTE DE MODELOS DE PREVISÃO BASEADO EM
GRÁFICOS DE CONTROLE**

Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de Especialista em Estatística e Modelagem Quantitativa.

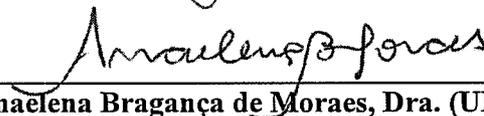
Aprovado em 27 de agosto de 2020



Adriano Mendonça Souza, Dr. (UFSM)
(Presidente/Orientador)



Luciane Flores Jacobi, Dra. (UFSM)



Anaelena Bragança de Moraes, Dra. (UFSM)

Santa Maria, RS
2020

*"Essentially, all models are wrong, but
some are useful"*

George E. P. Box

RESUMO

MONITORAMENTO E AJUSTE DE MODELOS DE PREVISÃO BASEADO EM GRÁFICOS DE CONTROLE

AUTOR: Ícaro Romolo Sousa Agostino
ORIENTADOR: Adriano Mendonça Souza

Os processos industriais estão normalmente sujeitos a efeitos estocásticos, tais como falhas operacionais e variações de tempo de condução. O principal objetivo desta pesquisa é o desenvolvimento de um sistema de monitorização de erros para a reestimação de parâmetros e reajuste de modelos de previsão na recorrência de erros fora do controle estatístico. Foi desenvolvida uma abordagem utilizando modelos ARIMA como preditores do comportamento futuro do sistema, e um gráfico de controle EWMA para a monitorização de erros. A metodologia proposta foi implementada na linguagem de programação 'R' e avaliada utilizando um caso de teste compreendendo um indicador-chave de desempenho de um processo de descarga num grande terminal portuário. Foi demonstrado um ganho médio de 114% no intervalo de tempo até as previsões mostrarem a recorrência de erros fora de controle em comparação a abordagem tradicional, que considerou apenas um modelo de previsão ao longo de todo o horizonte do estudo. Foi também demonstrado um ganho global em termos de acurácia, indicando que a abordagem proposta é uma alternativa viável para a monitorização de erros de previsão num contexto industrial.

Palavras-chave: Monitoramento de Erros de Previsão, EWMA, ARIMA.

ABSTRACT

MONITORING AND ADJUSTMENT OF FORECASTING MODELS BASED ON CONTROL CHARTS

AUTHOR: Ícaro Romolo Sousa Agostino

ADVISOR: Adriano Mendonça Souza

Industrial processes are commonly subject to stochastic effects such as operational failures and leading time variations. The main purpose of this research is the development of an error monitoring system for the re-estimation of parameters and readjustment of forecasting models in the recurrence of errors out of statistical control. An approach was developed using ARIMA models as predictors of future system behavior, and EWMA control chart for error monitoring. The proposed methodology was implemented in the programming language 'R' and evaluated using a test case comprising a key performance indicator of an unloading process at a large port terminal. It was demonstrated an average gain of 114% in the time interval until the predictions show recurrence in out-of-control errors out-of-control compared to the traditional approach, which considered only one forecast model over the whole horizon of the study. It was also demonstrated a global gain in terms of accuracy, indicating that the proposed approach is a viable alternative for monitoring prediction errors in an industrial context.

Keywords: Monitoring Forecasting Errors, EWMA, ARIMA.

SUMÁRIO

1	INTRODUÇÃO	7
1.1	JUSTIFICATIVA.....	8
1.2	OBJETIVOS.....	8
1.2.1	Objetivo geral	8
1.2.2	Objetivos específicos.....	8
1.3	ESTRUTURA DO TRABALHO	9
2	REVISÃO DE LITERATURA	10
2.1	MODELOS DE BOX-JENKINS	10
2.2	GRÁFICOS DE CONTROLE PARA O MONITORAMENTO DE MODELOS DE PREVISÃO.....	13
3	MATERIAIS E MÉTODOS.....	16
3.1	ABORDAGEM PROPOSTA.....	16
3.2	CASO TESTE	18
4	RESULTADOS.....	20
5	CONCLUSÃO	34
	REFERÊNCIAS	35
	APÊNDICE A	39

1 INTRODUÇÃO

A tomada de decisão em processos produtivos se apresenta como um problema complexo para decisores, enfrentando ambientes cada vez mais dinâmicos e voláteis, em que sistemas produtivos comumente estão sujeitos a efeitos estocásticos, como variações em tempos de processamento e falhas operacionais (TERKAJ; TOLIO; URGO, 2015; FRAZZON; KUCK; FREITAG, 2018). Nesse contexto, métodos quantitativos são amplamente utilizados em processos decisórios, permitindo gerar subsídios e decidir sobre aspectos, envolvendo os diversos recursos produtivos (ANDERSON et al., 2018).

Uma alternativa para subsidiar decisões em processos de produção é a análise e modelagem de séries temporais, apresentando uma família de modelos estatísticos e computacionais utilizados, sobretudo para prever o comportamento futuro de variáveis (MONTGOMERY; JENNINGS; KULAHCI, 2015). Entre os modelos de previsão existentes, os modelos Autorregressivos Integrados de Médias Móveis (ARIMA) implementados pela metodologia proposta por Box e Jenkins (1970), se destacam como uma abordagem estatística consolidada na literatura para a realização de previsões (HYNDMAN; ATHANASOPOULOS, 2018).

Usualmente, após o desenvolvimento de um modelo de previsão adequado, o mesmo tende a apresentar boa performance a curto prazo, no entanto, diversos autores argumentam que modelos de previsão tendem a perder acurácia ao longo do tempo devido à variação natural e às mudanças das condições nos processos, podendo resultar em erros sistemáticos e generalizados (DEL CASTILLO, 2002; BOX; LUCENO; DEL CARMEN PANIAGUA-QUINONES, 2011). Montgomery, Jennings e Kulahci (2015) sugerem a utilização de cartas de controle no monitoramento da performance de modelos de previsão a partir da utilização de gráficos de controle estatístico aplicados aos erros de previsão gerados ao longo da utilização de modelos, auxiliando na avaliação de acurácia e na decisão de intervenções e modificações no sistema de previsão utilizado na presença de persistência em erros fora de controle estatístico.

Na literatura atual diversas abordagens são propostas para a utilização dessas ferramentas de forma isolada, porém, há uma escassez de estudos que sistematizem a utilização conjunta de modelos de previsão e gráficos de controle no contexto do gerenciamento de sistemas industriais.

1.1 JUSTIFICATIVA

O atual cenário econômico impôs às organizações dos mais diversos setores a necessidade da busca continuada pela melhor forma de operar seus processos, independente da natureza a qual eles pertencem. Os processos de tomada de decisão nas organizações necessitam constantemente de subsídios que fomentem a correta análise dos elementos constituintes do processo decisório, apresentando os métodos quantitativos possuem vasta aplicação e relevância para essa temática (SLACK; BRANDON-JONES; JOHNSTON, 2015).

Os estudos acerca de modelos de previsões em diversos contextos organizacionais são desenvolvidos de modo que novas abordagens possam reduzir a incerteza, sobretudo em modelos de séries temporais (FIRMINO; MATTOS NETO; FERREIRA, 2014).

A presente pesquisa justifica-se por apresentar tanto potencial de contribuição teórica quanto prática, pois, uma vez que aborda uma temática atual na literatura, ainda há necessidade de avanços teóricos e conceituais. Assim, a presente pesquisa propõe a aplicação de conceitos científicos utilizando dados reais, objetivando a resolução de problemas e a otimização de processos, dessa forma, busca-se a evidenciação empírica e a discussão dos possíveis achados com a atual literatura.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Esta pesquisa tem como objetivo o desenvolvimento de uma abordagem para a aplicação de modelos estatísticos de previsão em conjunto com cartas de controle para o monitoramento de erros de previsão em processos produtivos de modo a gerar subsídios na tomada de decisão.

1.2.2 Objetivos específicos

- a) Revisar de forma sistemática a literatura sobre aplicação de cartas de controle em conjunto com modelos de previsão para subsidiar a abordagem proposta.
- b) Desenvolver uma abordagem para aplicação de modelos de previsão em conjunto com cartas de controle a partir da atual literatura;
- c) Implementar, via linguagem de programação 'R', a abordagem proposta;
- d) Analisar por meio de aplicação com dados reais a viabilidade da abordagem proposta.

1.3 ESTRUTURA DO TRABALHO

Para atender os propósitos da pesquisa, este trabalho está dividido em cinco capítulos apresentados a seguir:

O **capítulo 1** aborda a introdução ao tema, a justificativa da pesquisa, apresenta o objetivo geral do trabalho, assim como os específicos e a estrutura do trabalho.

O **capítulo 2** apresenta uma revisão de literatura sobre modelos de previsões de Box-Jenkins para séries temporais e outra sobre a aplicação de gráficos de controle para monitoramento de modelos de previsão.

O **capítulo 3** apresenta os procedimentos metodológicos propostos, detalhando as etapas da pesquisa, assim como o modelo proposto e, por fim, o caso teste para avaliação do modelo proposto.

O **capítulo 4** apresenta, os resultados da pesquisa, detalhando a análise bibliométrica realizada e a aplicação do modelo proposto no caso teste.

O **capítulo 5** apresenta as conclusões finais da pesquisa.

2 REVISÃO DE LITERATURA

Nesse capítulo será abordada a revisão de literatura a respeito do tema de estudo desta pesquisa. A primeira parte desta seção trata dos modelos para previsão de séries temporais, apresentando a metodologia de Box-Jenkins para aplicação dos modelos ARIMA, e a segunda aborda a aplicação de gráficos de controle para o monitoramento de modelos de previsão.

2.1 MODELOS DE BOX-JENKINS

Todos os eventos espaçados de forma regular no tempo geram séries temporais (BOX; JENKINS, 1970). Modelos de séries temporais são amplamente utilizados na modelagem de processos produtivos, no planejamento da produção e na previsão de demanda (WANG; CHANG, 2010; SCHOLZ-REITER; KÜCK; LAPPE, 2014; ROSIENKIEWICZ; CHLEBUS; DETYNA, 2017).

Séries temporais podem ser definidas como uma sequência de observações sobre determinada variável ao longo do tempo, de forma que os dados são observados em instantes discretos e equidistantes (SOUZA, 2016). O campo de análise e modelagem de séries temporais tem como dois de seus principais objetivos: (i) identificar as características e propriedades de forma descritiva e/ou analítica; (ii) realizar previsões com bases em modelos estatísticos, matemáticos ou analíticos. Comumente, as séries temporais são descritas em termos de quatro principais elementos:

- a) Tendência: deslocamento crescentes ou decrescentes da série temporal ao longo do tempo;
- b) Ciclo: movimento ondulatório da série temporal, que, ao longo de vários anos, tende a ser periódico;
- c) Sazonalidade: movimento ondulatório de curta ou média duração, normalmente inferior a um ano, em geral está associado a eventos periódicos como mudanças de estações, sazonalidade econômica, dentre outros efeitos;
- d) Ruído aleatório ou erro: compreende a variabilidade estocástica intrínseca à série temporal, não podendo ser modelado.

Os erros gerados a partir de modelos ajustados são definidos pela diferença entre valores reais observados da série temporal e os valores ajustados pelo modelo. Para um modelo

corretamente ajustado, a sequência de erros gerados deve ser não autocorrelacionada, possuir média aproximadamente zero e variância constante ao longo do tempo. Quando essas características são observadas, os erros gerados são denominados de ruído branco, cuja representação é $RB \sim (0, \sigma^2)$ (BUENO, 2008).

Ao modelar o comportamento de uma série temporal pressupõe-se que exista um mecanismo gerador não aleatório que pode ser representado a partir de um modelo capaz de representar razoavelmente bem tal mecanismo (MONTGOMERY; JENNINGS; KULAHCI, 2007). Dessa forma, uma série temporal denotada Z é passível de ser decomposta em termos de seus componentes por meio da seguinte generalização:

$$Z_t = T + S + C + \varepsilon_t \quad (1)$$

Onde: T representa a tendência; S a sazonalidade; C o ciclo; ε_t o erro. Desta forma, uma série temporal pode ser estudada como uma combinação de seus componentes, além da estrutura aditiva, a série pode ser multiplicativa dada pelo produto de seus componentes.

Nesse contexto, temos o processo de previsão que, de acordo com Montgomery, Jennings e Kulahci (2007), deve ser composto de etapas estruturadas e conectadas. Na Figura é apresentado um sistema estruturado para realização de previsões.

Figura 1 – O processo de previsão



Fonte: Adaptado de Montgomery, Jennings e Kulahci (2007)

A primeira fase consiste na definição do problema e objetivo para a realização da previsão, comumente problemas de previsão de demanda, controle de processos, análise riscos ou tomada de decisões estratégicas de uma forma geral, que se enquadram como problemas que podem ser beneficiados por previsões. A fase seguinte consiste na coleta e na estruturação dos dados que serão utilizados nos processos de análise e modelagem, nessa etapa, deve ser definido escopo, frequência e características gerais que devem ser observadas (WERNER, 2005).

A etapa três consiste na análise com objetivo central de definir qual técnica de previsão pode ser empregada. Na literatura atual diversas abordagens podem ser encontradas para

previsão de séries temporais, variando de acordo com horizonte de previsão, capacidade de acurácia e objetivos. A obtenção de previsões adequadas depende da aplicação de técnicas de previsão adequadas aos dados analisados (MAKRIDAKIS; STEVEN; HYNDMAN, 1998).

A validação de um modelo será realizada pela análise do ajuste do modelo aos dados reais, sendo calculada por meio de medidas de acurácia. Segundo Montgomery, Jennings e Kulahci (2007) quando duas ou mais técnicas se mostram razoáveis para realizar previsões, as medidas de acurácia podem ser usadas para discriminar entre os modelos concorrentes aquele que possuir melhor ajuste.

Após o ajuste e a validação deve-se realizar o monitoramento do modelo, pois, com o passar do tempo, o mecanismo gerador tende a mudar, deteriorando a capacidade preditiva e desempenho do modelo. A aplicação de gráficos de controle é uma das principais alternativas para o monitoramento de modelos de previsão de forma eficaz (MONTGOMERY; JENNINGS; KULAHCI, 2007).

Os modelos autorregressivos integrados de médias móveis (ARIMA) foram desenvolvidos por Box e Jenkins (1970), sendo caracterizados por captar o comportamento da correlação seriada entre os valores da série temporal e assim realizar previsões futuras (MONTGOMERY; JENNINGS; KULAHCI, 2015).

A modelagem ARIMA segue quatro etapas: (i) identificação, consistindo na determinação do modelo que melhor descreve o comportamento da série, por meio da análise das funções de autocorrelação (FAC) e autocorrelação parcial (FACP); (ii) estimação, realizando a estimação dos parâmetros autorregressivos, assim como de médias móveis; (iii) validação, consistindo na análise da adequação do modelo ajustado ao comportamento real da série, em que são analisados os resíduos do modelo; (iv) previsão, que somente é realizada, quando as etapas anteriores forem satisfatórias (FERREIRA, 2018). Usualmente os modelos ARIMA (p, d, q) são representados pela equação (2):

$$\phi(B)\Delta^d Z_t = \theta(B)\varepsilon_t \quad (2)$$

Onde: Z_t representa a série temporal modelada, B representa o operador retroativo, d a ordem de integração, ϕ é termo que representa o parâmetro autorregressivo de ordem p , θ representa o parâmetro de médias móveis de ordem q e ε_t representa a sequência de erros, denotado ruído branco quando a média dos erros é aproximadamente zero e a variância é constante com homocedasticidade $\sim (0, \sigma^2)$.

Aplicações recentes dos modelos de Box e Jenkins, em casos reais envolvendo sistemas de produção industrial, podem ser encontrados no estudo realizado por Jacobs, Souza e Zanini (2016) que utilizaram modelos de Box e Jenkins sazonais em conjunto com outros modelos de previsão combinados para prever a demanda agregada de uma indústria de lácteos, encontrando resultados acurados. Ueda et al. (2018) utilizaram combinação de modelos de Box-Jenkins com modelos de suavização para prever a demanda agregada de indústria de ração, encontrando resultados satisfatórios em termos de precisão.

No Quadro 1 é apresentado o resumo de alguns estudos recentes que abordam a utilização de modelos de previsão que consideram a utilização de gráficos de controle no contexto de sistemas produtivos, destacando o objetivo e a abordagem adotada.

Quadro 1 – Estudos que abordam modelos de previsão da indústria

Autores	Objetivo	Método
Kandananond (2014)	Melhorar o desempenho do gráfico de controle da média móvel exponencialmente ponderada com aplicação de modelos autorregressivos.	O autor utilizou o modelo ARIMA em conjunto com o gráfico de controle EWMA
Ma e Li (2015)	Melhorar o desempenho de um sistema de manufatura de semicondutores.	Os autores aplicaram gráfico EWMA em conjunto com modelos ARIMA.
Lampreia et al. (2018)	Monitorar a condição de equipamentos industriais a partir dos ruídos gerados pelos modelos de séries temporais.	Os autores aplicaram os modelos de gráficos de controle de somas acumuladas e EWMA em conjunto com modelos ARIMA.

Fonte: Elaborado pelo autor

A partir do Quadro 1 é possível verificar a ocorrência de algumas abordagens, considerando diferentes contextos para a modelagem de sistemas produtivos utilizando gráficos de controle para o monitoramento de modelos de previsão. A predominância de abordagens do tipo ARIMA em conjunto com gráficos EWMA é vista nos trabalhos encontrados (WANG; CHANG, 2010; SCHOLZ-REITER; KÜCK; LAPPE, 2014).

2.2 GRÁFICOS DE CONTROLE PARA O MONITORAMENTO DE MODELOS DE PREVISÃO

O monitoramento de sistemas de previsão é uma das etapas essenciais para garantia de performance acurada do modelo quando usado ao longo de um período de tempo. Montgomery, Jennings e Kulahci (2015) argumentam que sistemas de previsão necessitam de monitoramento devido à natureza dinâmica dos processos que tendem a sofrer alterações em seus mecanismos geradores ao longo do tempo. A aplicação de gráficos de controle é uma alternativa robusta no monitoramento de sistemas de previsão a partir da avaliação contínua dos erros estocásticos gerados pelos modelos (ADAMS; TSENG, 1998; SOUZA; SAMOHYL, 2008; MONTGOMERY; JENNINGS; KULAHCI, 2015).

Os erros de previsão são definidos como a diferença entre o valor real e o previsto pelo modelo em um horizonte de tempo específico (HYNDMAN; ATHANASOPOULOS, 2018), dessa forma, o monitoramento é comumente realizado pela aplicação de gráficos de controle para observações individuais em que são analisados os erros um passo à frente cometido pelo modelo avaliado. Os gráficos de somas acumulados (CUSUM) e média móvel exponencialmente ponderada (EWMA) são sugeridos por Adams e Tseng (1998) e Montgomery, Jennings e Kulahci (2015) pela efetividade na detecção de pequenas mudanças em modelos de previsão. Nesta pesquisa decidiu-se aplicar o gráfico de controle EWMA como estratégia de monitoramento.

O gráfico EWMA é aplicado no monitoramento de variáveis utilizando todo o histórico do processo enquanto outros gráficos tratam de subgrupos de amostras individualmente, o gráfico EWMA monitora a média móvel exponencialmente ponderada de toda a série histórica. O gráfico EWMA atribui pesos para as observações em ordem geométrica decrescente, de modo que as observações mais recentes têm maior peso, enquanto as observações mais distantes contribuem menos na identificação de valores fora de controle estatístico (MONTGOMERY; JENNINGS; KULAHCI, 2015). As equações das estatísticas e limites de controle do gráfico EWMA são apresentadas na Tabela 1.

Tabela 1 – Estatísticas e limites de controle do gráfico EWMA

Gráfico de Controle	Estatística	Limite de Controle
EWMA	$W_t = \lambda \varepsilon_t + (1 - \lambda)W_{t-1} \quad (3)$ <p>Onde: W_t representa a média ponderada exponencialmente; λ é uma constante de suavização que varia entre 0 e 1.</p>	$T \pm 3\sigma_\varepsilon \sqrt{\frac{\lambda}{2 - \lambda} [1 - (1 - \lambda)]^{2t}} \quad (4)$ <p>Onde: T é o valor alvo, usualmente igual a zero ou a média dos erros.</p>

Fonte: Adaptado de Adams e Tseng (1998) e Montgomery, Jennings e Kulahci (2015)

A abordagem de gráficos de controle leva em conta não somente os valores contemporâneos dos erros, mas também os valores passados no cálculo das estatísticas, trazendo informações complementares a respeito do controle estatístico da variável estudada (BOX; LUCENO; DEL CARMEN PANIAGUA-QUINONES, 2011).

Aplicações de gráficos de controle para o monitoramento de erros de previsão são encontrados no estudo desenvolvido por Sousa e Samohyl (2008) que utilizaram um gráfico de controle combinado CUSUM e Shewhart para monitorar a sequência de erros gerados na previsão do consumo de energia elétrica no estado de Santa Catarina. Souza et al. (2011) utilizaram um gráfico de observações individuais para a média, no monitoramento de um modelo de previsão para o consumo de cimento no estado do Rio Grande do Sul, encontrando resultados satisfatórios para a validação do modelo de previsão. Em outro estudo Matias et al. (2011) comparou diferentes gráficos de controle para o monitoramento do erro de previsão para tráfego de dados em rede, encontrando resultados superiores no controle dos erros para a abordagem com a utilização do gráfico EWMA. Oliveira e Rosa (2018) utilizam o gráfico de controle EWMA para monitorar um modelo de previsão de pico de demanda de energia elétrica.

Na seção seguinte serão apresentados os aspectos metodológicos da pesquisa, assim como descrito o modelo proposto e o caso de teste em que o modelo foi avaliado.

3 MATERIAIS E MÉTODOS

Neste capítulo são apresentados os aspectos metodológicos adotados neste trabalho.

3.1 PROCEDIMENTOS METODOLÓGICOS

Para atingir os objetivos propostos, a pesquisa foi executada em cinco etapas:

(i) Revisão sistemática da literatura: foi realizada uma revisão sistemática permitindo conhecer, discutir e analisar as principais abordagens adotadas por pesquisadores da área (TRANFIELD; DENYER; SMART, 2003). Como recurso computacional para manipulação e análise dos dados nessa etapa foi utilizado o software R 3.5.2 (R CORE TEAM, 2019), em todas as análises bibliométricas foram suportadas pelo pacote “Bibliometrix” 2.1.2 (ARIA; CUCCURULLO, 2017).

(ii) Desenvolvimento da abordagem conceitual: a partir da abordagem proposta foi realizada a integração das práticas adotadas na literatura atual, que objetivará a sistematização detalhada dos métodos propostos (MILLER; TSANG, 2011).

(iii) Implementação via linguagem de programação ‘R’: a metodologia proposta foi implementada via linguagem de programação livre ‘R’ (R CORE TEAM, 2019). A linguagem ‘R’ é amplamente utilizada no desenvolvimento de pesquisas científicas por viabilizar a reprodutibilidade metodológica (GANDRUD, 2016).

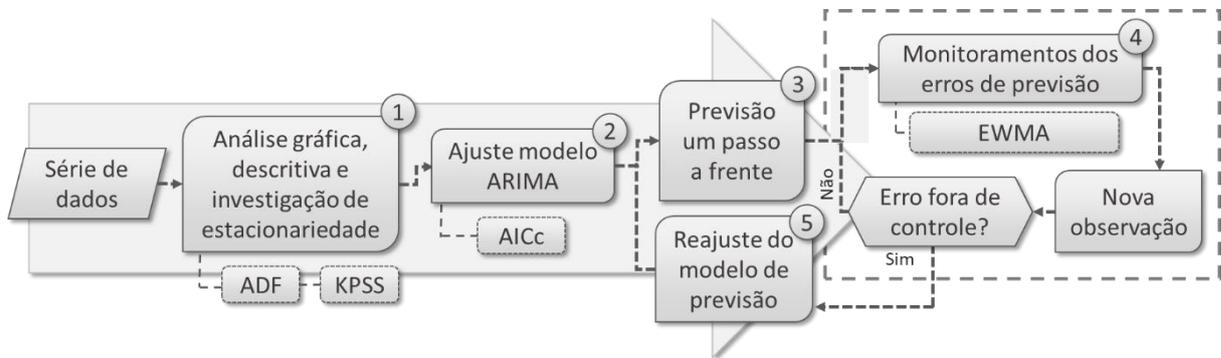
(iv) Aplicação da metodologia implementada: após o desenvolvimento e implementação, foi realizada a aplicação caso teste envolvendo dados reais em um sistema produtivo objetivando analisar a aplicabilidade da abordagem proposta.

(v) Análise e discussão dos resultados: a partir dos resultados empíricos provenientes dos achados foi realizada a discussão dos resultados confrontando-os com a atual literatura.

3.2 MODELO PROPOSTO

A abordagem proposta objetivou sistematizar a aplicação de gráficos de controle no monitoramento de previsões no contexto de sistemas industriais, propondo uma abordagem metodológica ao considerar métodos estatísticos e computacionais na resolução de problemas práticos. Diante do exposto, a abordagem metodológica proposta é composta por cinco etapas, descritas a seguir e ilustradas pela Figura 3.

Figura 3 – Abordagem proposta para o monitoramento de erros e reajuste de modelos de previsão.



Fonte: Elaborado pelo autor

Etapa 1: Análise gráfica e descritiva da variável. Ainda nessa fase é verificada a estacionariedade da série pelo teste de raiz unitária KPSS (KWIATKOWSKI et al., 1992) e realizada a investigação da presença de autocorrelação.

Etapa 2: Ajuste do modelo ARIMA para a variável de interesse, seguindo a metodologia de Box e Jenkins (BOX; JENKINS, 1970) com o auxílio do algoritmo de Hyndman e Khandakar (2008), utilizando o critério de AICc (MONTGOMERY; JENNINGS; KULAHCI, 2015; AKAIKE, 1973) para definição da dimensão do modelo. Foram utilizadas inicialmente as primeiras 120 observações para o ajuste do modelo inicial.

Etapa 3: Realização da previsão um passo à frente, em que a cada inclusão de nova observação será computado o erro de previsão que será monitorado na etapa seguinte.

Etapa 4: Monitoramento dos erros de previsão um passo à frente pelo gráfico de controle EWMA para observações individuais, utilizando $\lambda = 0,2$ e $L = 2$, desvios padrões para que o gráfico detecte menores mudanças no processo (MONTGOMERY; JENNINGS; KULACHI, 2015). Para o cálculo dos intervalos de controle foram utilizados os primeiros 24 erros um passo à frente a cada etapa de monitoramento. Quando o modelo ajustado apresentou recorrência em erros fora de controle, foi realizado o reajuste do modelo de previsão a partir da inclusão de novas observações. Tal recorrência nesse estudo foi caracterizada pela ocorrência de três períodos fora de controle estatístico no intervalo consecutivo de 24 períodos.

Para a avaliação dos erros de previsão da abordagem proposta foram utilizadas as medidas de acurácia Erro Absoluto Médio (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE), sendo realizada a comparação da abordagem proposta em relação à estimação de um modelo único de previsão para todo o período

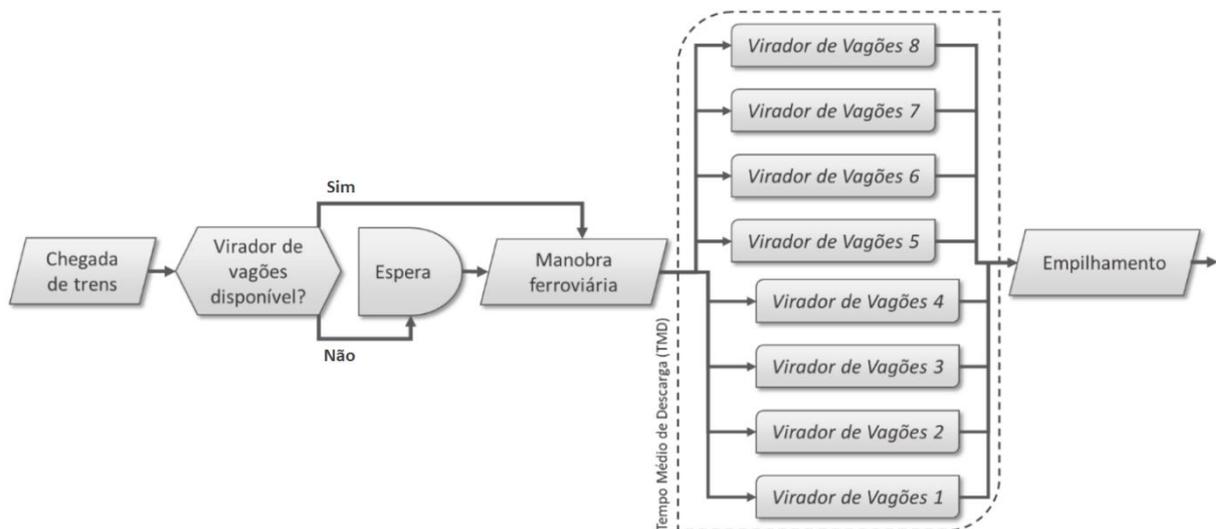
considerado. Também foi avalizado o ganho em termos de tempo médio entre recorrência de erros fora de controle estatístico.

Como recurso computacional para tratamento, análise e modelagem foi utilizada a linguagem de programação livre ‘R’ (R CORE TEAM, 2019), incluindo a implementação da abordagem proposta (Apêndice A), objetivando a reprodutibilidade metodológica (GANDRUD, 2016). Foi utilizado como ambiente de desenvolvimento integrado (IDE) o software RStudio que permitiu o desenvolvimento da abordagem com suporte dos pacotes ‘forecast’ (HYNDMAN; KHANDAKAR, 2008) e ‘qcc’ (SCRUCCA, 2004).

3.3 CASO TESTE

A abordagem proposta foi avaliada em estudo desenvolvido em um sistema logístico integrado de movimentação de minério de ferro (contendo mina, ferrovia e porto), objetivando a modelagem e previsão de um indicador chave de desempenho do processo de descarga realizado por viradores de vagões. A Figura 4 ilustra o processo de movimentação estudado.

Figura 4 – Sistema de descarregamento



Fonte: Elaborado pelo autor

O descarregamento é o processo portuário inicial que ocorre após a extração e a movimentação do minério de ferro via sistema ferroviário por composição de vagões, realizado utilizando oito viradores de vagões, em que cada equipamento industrial gira um par de vagões por vez, direcionando o material para um sistema de correias transportadoras. O principal

parâmetro de gerenciamento desse processo é o indicador Tempo Médio de Descarga (TMD), representado pela equação (8):

$$TMD = \frac{TTD}{N^{\circ} \text{ Lotes}} \quad (5)$$

Onde: TTD representa o tempo total de descarga; N° Lotes representa o número total de lotes operados no período, sendo cada lote constituído de 110 vagões.

A variável TMD é considerada um indicador chave de produção, pois o processo de descarga atende aos processos portuários posteriores de empilhamento e embarque. A previsão acurada do comportamento futuro do indicador torna-se um importante fator a ser abordado nos processos decisórios, tais como o dimensionamento de produção e o planejamento de rotinas de manutenção.

Os dados utilizados para modelagem foram coletados a partir do banco de apontamentos do sistema de automação industrial, sendo referentes a um mês de operação, com observações a cada hora, gerando uma série temporal com 720 observações.

4 RESULTADOS

4.1 ANÁLISE BIBLIOMÉTRICA

Com o objetivo de conhecer, analisar e avaliar a literatura atual sobre gráficos de controle para monitoramento de erros de previsão foi realizado uma análise bibliométrica sobre a temática. O processo de busca considerou as bases Web of Science e Scopus, sendo consideradas como maiores repositórios de documentos científicos (GUERRERO-BOTE; MOYA-ANEGON, 2012). Para tanto, foi construído uma estratégia de busca a partir da definição de termos centrais da área, na Tabela 2 são apresentadas as versões finais das strings de busca utilizadas em cada base, assim como a quantidade de resultados em termos do número de publicações.

Tabela 2 – *Strings* de busca

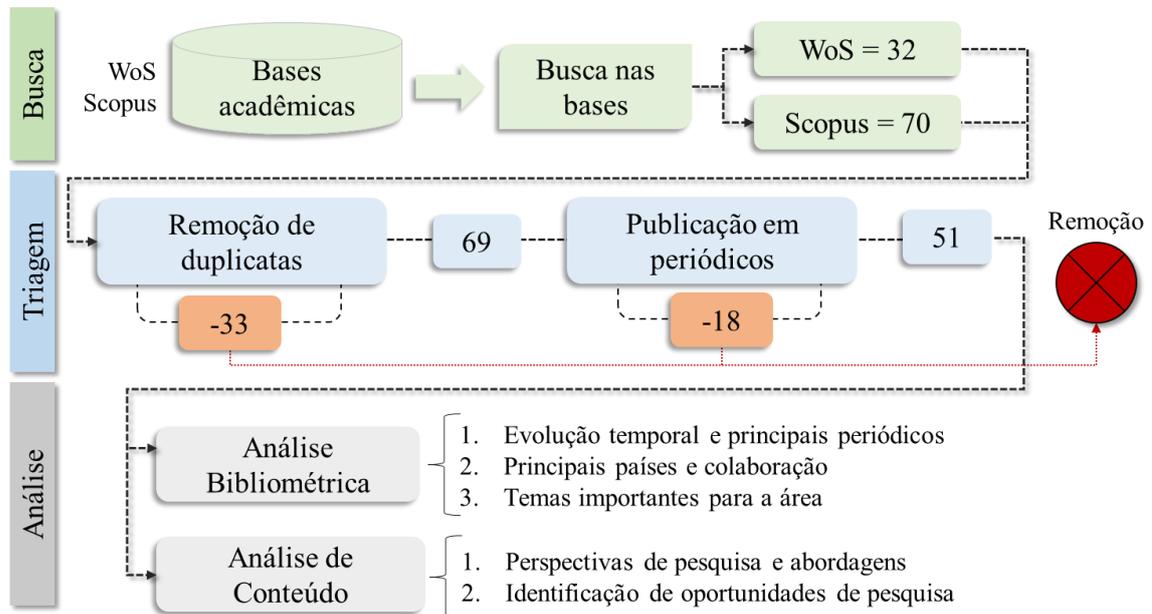
Database	String de busca	Resultados
Web of Science	<i>TS=("control chart*" AND forecast* AND (industr* OR production*))</i>	32
Scopus	<i>TITLE-ABS-KEY("control chart*" AND forecast* AND (industr* OR production*))</i>	70
Total		102

Fonte: Elaborado pelo autor

A busca foi realizada no mês de outubro de 2019, foram encontrados 102 artigos, sendo 32 da base Web of Science, 70 da Scopus. Os termos utilizados para o primeiro constructo foram “*control chart**” e “*forecast**”, e para o segundo “*indutr**” e “*production**”, sendo a busca aplicada nos títulos, nas palavras-chave e no resumo dos artigos.

O protocolo de pesquisa foi então construído conforme o modelo de processo apresentado na Figura 5. O principal propósito deste estudo foi selecionar apenas artigos que claramente tratavam de valor no contexto da aplicação de cartas de controle para monitorar erros de previsão, dessa forma, a taxonomia de classificação incluindo todas as etapas foi composta da seguinte forma: (i) identificação do problema de pesquisa; (ii) a busca nas bases de periódicos; (iii) seleção de artigos publicados somente em periódicos; (iv) remoção de artigos duplicados.

Figura 5 – Processo de busca e seleção dos artigos



Fonte: Elaborado pelo autor

A seleção final totalizou 51 artigos publicados em periódicos com alinhamento a temática, a análise bibliométrica foi realizada considerando esse grupo. Após análise bibliométrica, para identificação dos contextos de aplicações em casos específicos será considerado um subgrupo selecionado a partir de uma segunda leitura dos resumos, buscando identificar artigos que foram publicados em veículos de reconhecida qualidade científica e que possam contribuir com a discussão aqui abordada.

A evolução temporal da frequência de publicações sobre a temática é apresentada na Figura 6. Em 2013 obteve-se 7 publicações, se estendendo até o ano de 2019 que atualmente já conta com 3 publicações, percebe-se que a área apresenta maturidade, com o número de publicações tendendo a se estabilizar nos últimos anos.

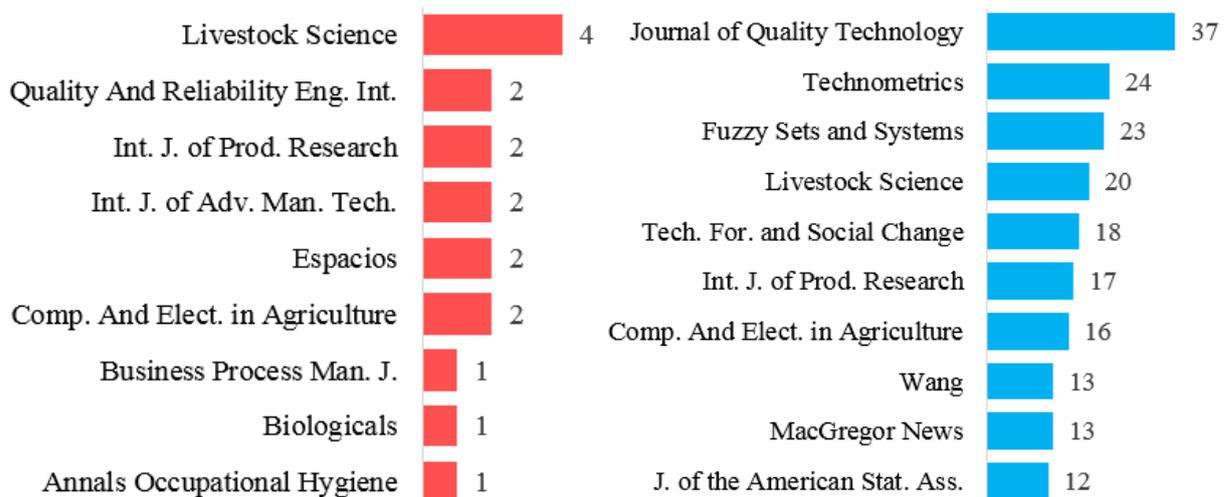
Figura 6 – Evolução temporal das publicações



Fonte: Elaborado pelo autor

Na Figura 7(a) apresentam-se os dez periódicos que tiveram maior concentração de publicações no grupo analisado. O periódico “*Livestock Science*” foi o que apresentou maior número de publicações. Na Figura 7(b) são apresentados os dez periódicos que mais vincularam pesquisa que foram citados no grupo de estudos analisado, nesse caso, observa-se grande destaque ao “*Journal of Quality Technology*”, assim como diversos outros periódicos que vinculam estudos de qualidade, previsão e gestão de operações.

Figura 7 – Principais periódicos

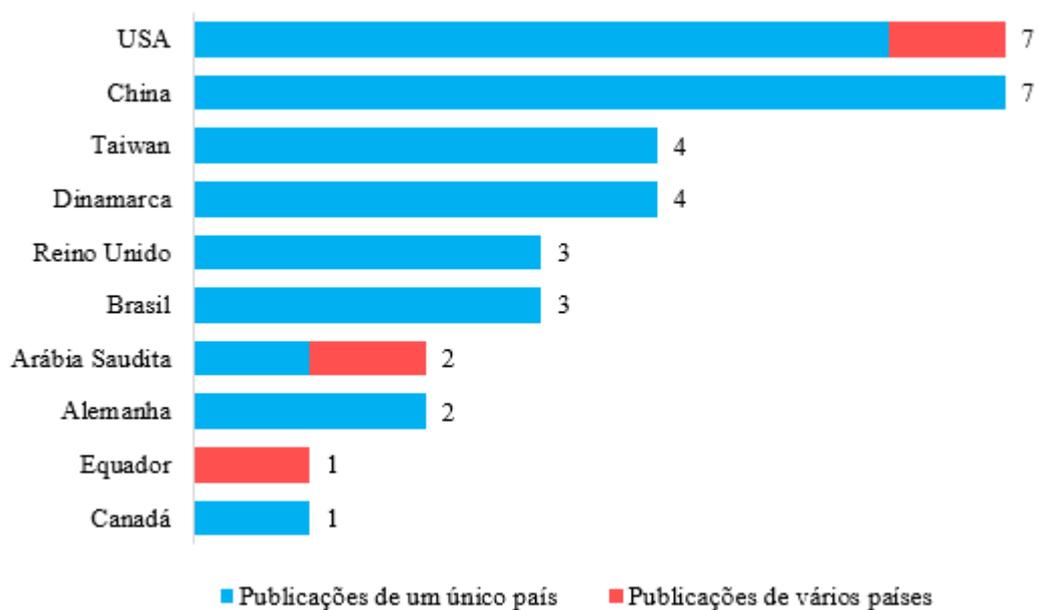


Fonte: Elaborado pelo autor

Na Figura 8 são apresentados os países que vincularam estudos sobre a temática no grupo analisado, categorizados por publicações que tiveram autoria de apenas um país (em azul) e de vários países (em vermelho). China e USA apresentam grande destaque com sete

publicações cada, seguidos por Taiwan e Dinamarca com quatro, Reino Unido e Brasil com três, Arábia Saudita e Alemanha com dois, os demais países apresentaram apenas uma publicação cada.

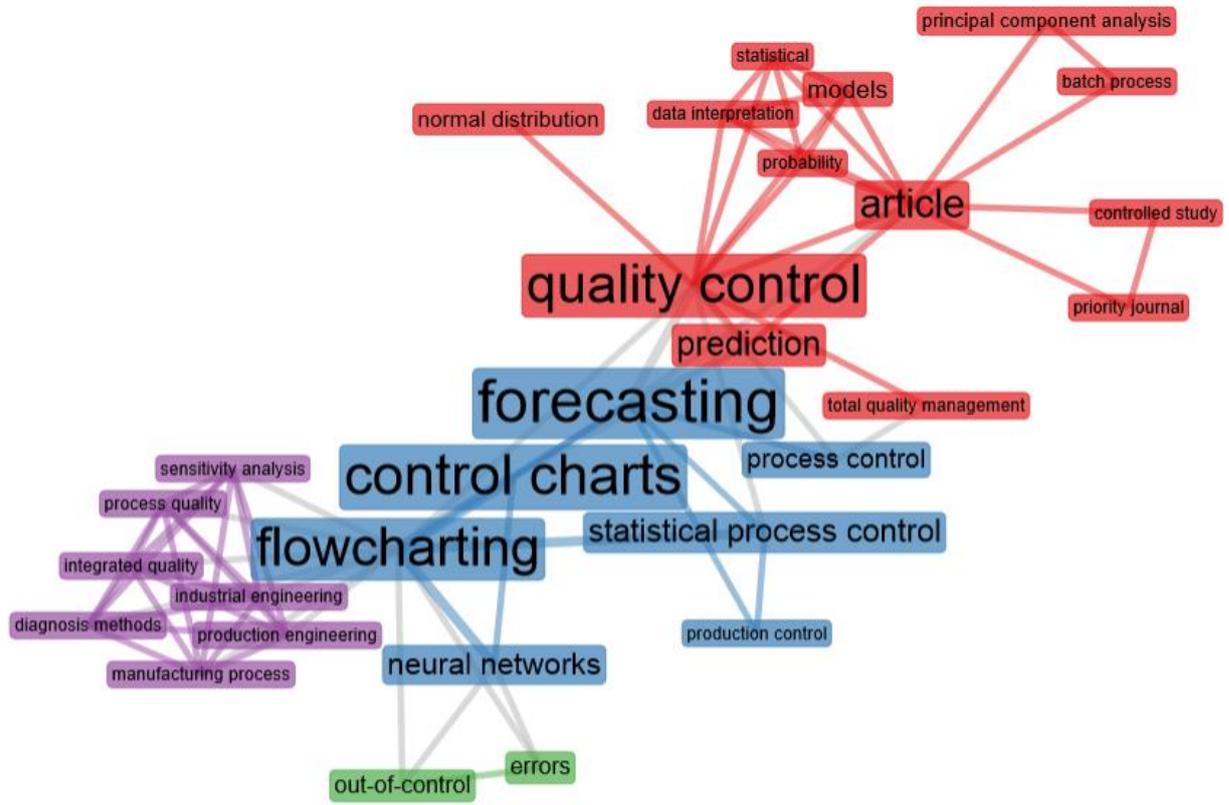
Figura 8 – Países das publicações



Fonte: Elaborado pelo autor

Com o objetivo de identificar os termos mais recorrentes foi utilizado um mapa de rede das palavras contidas nos resumos dos artigos, utilizando o algoritmo de Fruchterman e Reingold (1991), conforme a Figura 9. Percebe-se que o grupo de publicações selecionado está alinhado ao tema investigado, com os termos *forecasting* e *control charts* aparecendo como centrais em conjuntos de termos como *statistical process control*, *prediction* e *quality control*, também é possível destacar os termos *manufacturing process*, *industrial engineering*, *process quality* relacionados a aplicações no campo industrial.

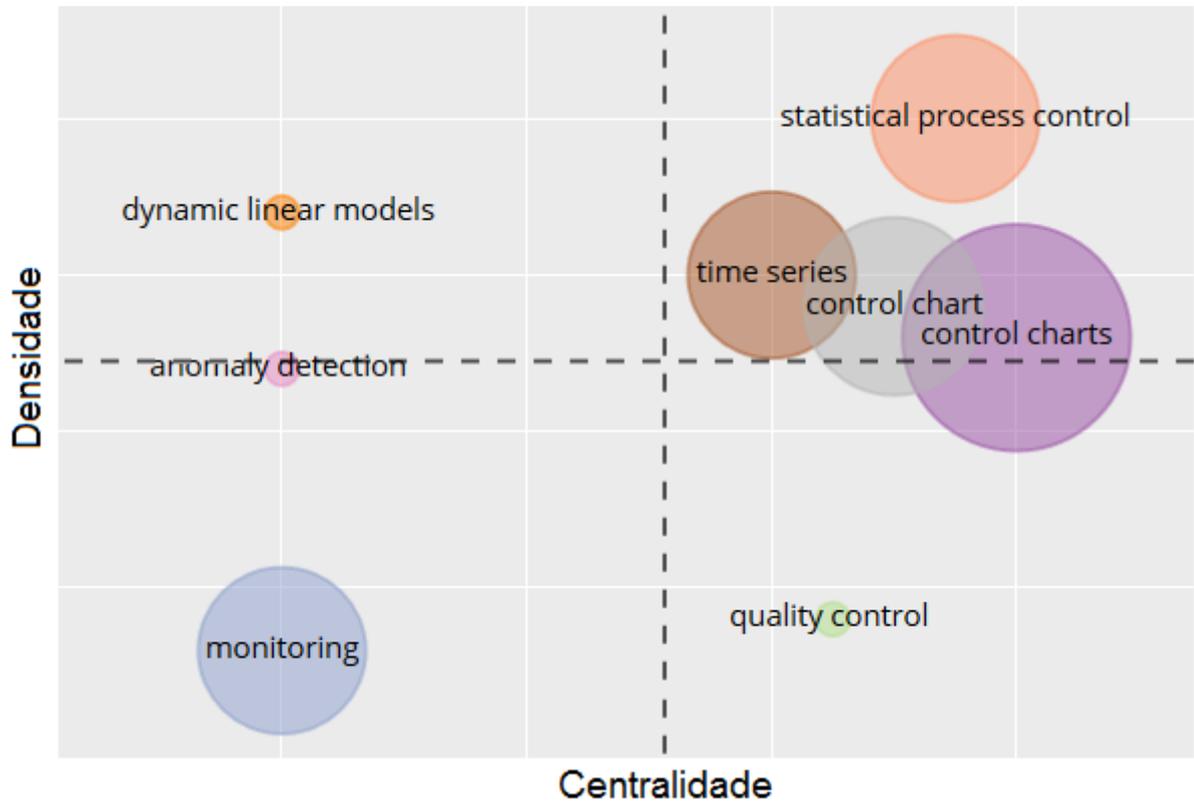
Figura 9 – Rede de palavras contidas nos resumos



Fonte: Elaborado pelo autor

Com o objetivo de realizar um mapeamento temático da área de estudo analisada, Cobo et al. (2011) sugere a construção de um mapa temático considerando os termos mais evidenciados nas palavras-chave das publicações analisadas, relacionando a densidade e centralidade dos termos. Na Figura 10 ilustra-se a construção do mapa temático. Os temas localizados no quadrante superior direito representam temas motores, sendo áreas bem desenvolvidas e importantes para a estruturação de um campo de pesquisa, no caso estudado, os termos *statistical process control*, *time series* e *control charts* aparecem nessa classificação. Os temas no quadrante superior esquerdo representam temas especializados, aparecendo os termos *dynamic linear models*.

Figura 10 – Mapeamento temático



Fonte: Elaborado pelo autor

No quadrante inferior esquerdo estão os temas emergentes, aparecendo *monitoring*. Por fim, no quadrante inferior direito estão os temas base, que são considerados importantes para o desenvolvimento do campo, sendo mais genéricos e transversais, o tema *quality control* está nessa categoria.

Com o objetivo de analisar os conceitos nos estudos analisados, foram selecionados 10 artigos considerando a relevância dentro do escopo previamente selecionado, a partir da quantidade de citações contidas na base Scopus considerando as publicações dos últimos 10 anos. Na Tabela 3 é apresentada uma análise de conteúdo desses estudos. Dessa forma, foram investigados os objetivos, o método aplicado no estudo e o contexto de aplicação.

Tabela 3 – Análise de conteúdo

Autor (ano)	Objetivo	Método(s)	Contexto de aplicação	Citação
Cheng e Huang (2011)	Desenvolver uma abordagem utilizando modelo de máquina de vetores de suporte para prever mudanças em processos em combinação com gráfico de somas acumuladas.	Máquina de vetores de suporte (SVM) e CUSUM	Ambiente industrial emulado via modelo de simulação	22
Zhang, Prajapati e Peden (2011)	Propor um modelo de planejamento da produção integrando previsão de demanda e controle dos processos.	Programação estocástica	Empresa de manufatura em cadeia de suprimentos internacional	14
Miekley et al. (2013)	Desenvolver um método para detecção de problemas na produção de leite combinando previsão e controle multivariado de processo.	Modelo de Vetores Autorregressivos (VAR) e CUSUM multivariado	Produção de leite	13
Bono, Cornou e Kristensen (2012)	Desenvolver um sistema de monitoramento baseado em modelos dinâmicos lineares para produção de carne suína.	Algoritmo de expectativa-maximização e gráfico de Shewhart.	Monitoramento do processo de produção de carne suína.	13
Wang e Yao (2015)	Propor um método para detecção de falhas em processos de lotes multivariados	Análise de componentes principais e gráfico T^2 de Hotelling	Monitoramento de processo industrial em lotes via simulação	12
Bono et al. (2013)	Desenvolver um modelo para monitoramento e previsão para detecção de falhas.	Modelagem linear dinâmica generalizada e gráfico de controle.	Monitoramento de sistema de produção animal	10
Shamsuzzaman e Wu (2012)	Desenvolver um algoritmo para ajuste de gráficos EWMA considerando mudança de tamanhos de amostra.	EWMA e modelo genérico de previsão.	Monitoramento genérico de processos industriais.	10
Harrou et al. (2018)	Propor um método para aumentar confiabilidade na detecção de falhas em processos industriais.	Mínimos quadrados parciais e gráfico de Shewhart, EWMA e T^2 .	Monitoramento genérico de processos industriais.	8
Chopra et al. (2012)	Determinar e prever a qualidade de processos de produção de comprimidos na forma de capacidade do processo sigma.	Gráficos de controle genéricos.	Produção de produtos de saúde.	8
Hamza (2009)	Estabelecer um método de controle e previsão para processos de engenharia para projetos de construção	Gráficos de controle genéricos.	Monitoramento de projetos de engenharia.	8

Fonte: Elaborado pelo autor

A partir da Tabela 3 é possível identificar diversos contextos em que foram relacionados os conceitos de previsão e controle estatístico de processos às aplicações em diferentes áreas como manufatura, saúde, produção animal e gestão de projetos. Predominantemente os gráficos EWMA, Shewhart, CUSUM e T^2 aparecem como principais abordagens. Já em relação aos

métodos de previsão de séries temporais, abordagens diversas são aplicadas sem grande predominância de nenhum método específico. A revisão dos aspectos da literatura reforça o potencial de aplicação dessas duas áreas de forma conjunta, sendo um campo de aplicação ainda com grande espaço para o desenvolvimento de novas abordagens.

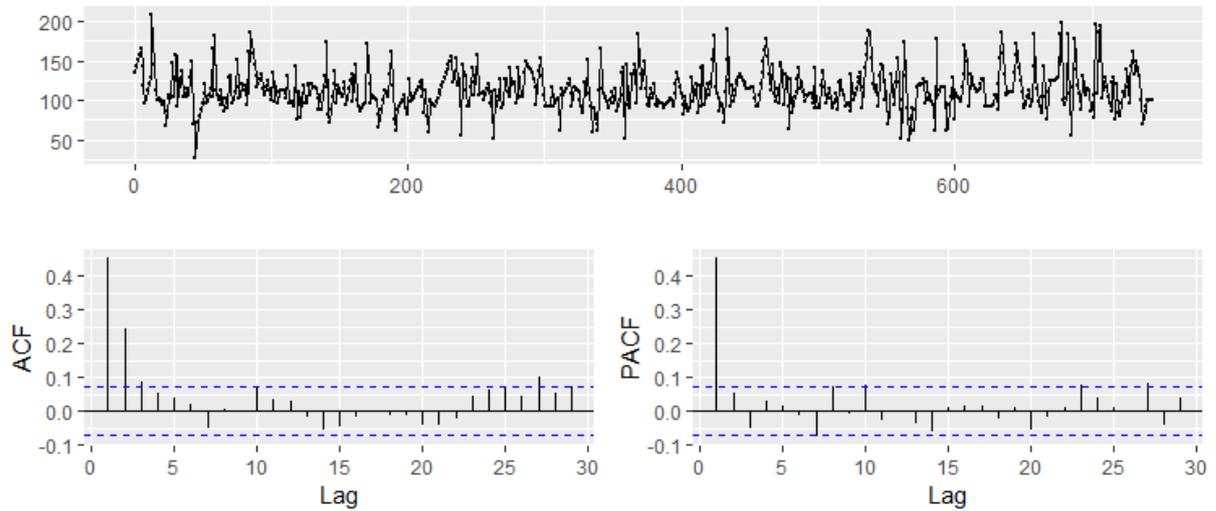
Dessa forma, a abordagem desenvolvida nesse estudo considerou a aplicação do gráfico de controle EWMA e dos modelos de previsão da família ARIMA, sendo suportada pelos resultados da revisão de forma sistemática da literatura. A combinação de ambas abordagens, conforme apresentado no item 3.2, objetivou sistematizar um modelo genérico para monitoramento de modelos de previsão considerando o monitoramento dos erros de previsão. Na seção seguinte a abordagem desenvolvida será aplicada no caso de uso proposto.

4.2 APLICAÇÃO DO MODELO PROPOSTO EM UM CASO TESTE

Após a investigação sistemática realizada na literatura, nesta seção será realizada a aplicação da abordagem descrita na seção 3.2 em um caso teste com o objetivo de avaliar os ganhos em termos de precisão e redução da ocorrência de erros fora de controle estatístico. Dessa forma, foi ajustado um modelo inicial de previsão ARIMA que posteriormente foi monitorado pelos erros de previsão um período a frente utilizando o gráfico EWMA. O monitoramento dos erros previsão permitiu decidir o momento de realizar o reajuste do modelo de previsão de forma dinâmica. esse procedimento ocorreu de forma iterativa até o fim do período considerado.

Na Figura 11 é representado o comportamento da variável tempo médio de descarga (TMD) ao longo de um mês de operação. É possível observar que o indicador possui comportamento estacionário, com média de 113,03 min, desvio padrão de 24,77 min e coeficiente de variação de 21,95%, assim como ausência de tendência. As funções de autocorrelação (ACF) e autocorrelação parcial (PACF) da série original evidenciam uma estrutura de autocorrelação significativa, com dependência entre os períodos Z_t e $Z_{(t-1)}$.

Figura 11 – Série TMD, função de autocorrelação (ACF) e autocorrelação parcial (PACF).



Fonte: Elaborado pelo autor

Foi ajustado o modelo inicial de previsão utilizando o critério de AICc, a partir do procedimento de Hyndman e Khandakar (2008), considerando as primeiras 120 observações da série temporal para o ajuste, sendo o modelo ARIMA (1,0,1) selecionado. Os parâmetros do modelo, assim como os níveis de significância são descritos na Tabela 4. Posteriormente foram computados os erros de previsão um passo à frente utilizando o modelo ajustado.

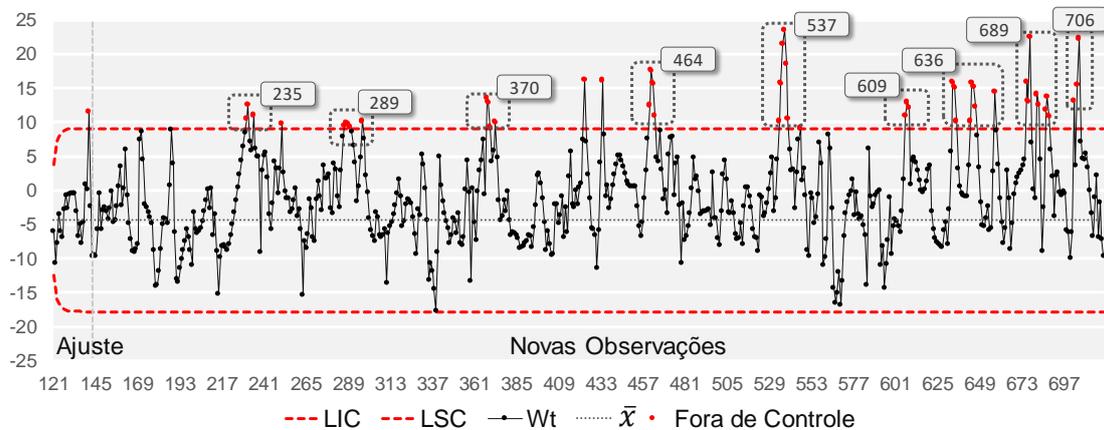
Tabela 4 – Modelo ARIMA inicial

Modelo	Parâmetros	p-valor	AICc
ARIMA (1,0,1)	AR(p) $\phi_1 = 0,7235$	< 0,01	1107,72
	MA(q) $\theta_1 = -0,3385$	< 0,01	

Fonte: Elaborado pelo autor

A sequência de erros gerados pelo modelo inicial, suavizados pelo gráfico EWMA estão dispostos na Figura 12. É possível evidenciar que o modelo de previsão produziu erros sob controle estatístico até o período 232, com presença de recorrência nos erros no instante 235, apresentando três períodos consecutivos fora de controle, tal comportamento se repete nos instantes 289, 370, 464, 537, 609, 636, 689 e 706, conforme destacado na Figura 12. Dessa forma, evidencia-se a necessidade de reajuste do modelo inicial de previsão, uma vez que o modelo foi capaz de produzir erros sob controle estatístico somente no curto prazo, perdendo acurácia ao longo do tempo com redução do intervalo entre os erros (DEL CASTILLO, 2002; BOX; LUCENO; DEL CARMEN PANIAGUA-QUINONES, 2011).

Figura 12 – Gráfico EWMA dos erros do modelo ARIMA(1,0,1) até a hora 720



Fonte: Elaborado pelo autor

O modelo de previsão foi reajustado atualizando a série temporal a partir da inclusão de novas observações, utilizando os 120 períodos anteriores ao momento que o modelo inicial apresentou recorrência em erros fora de controle (116 – 235), sendo selecionado o ARIMA (1,0,0), conforme a Tabela 5. Foram então realizadas as previsões um passo à frente e monitorado os erros pelo gráfico EWMA até o momento de uma nova recorrência em erros fora de controle.

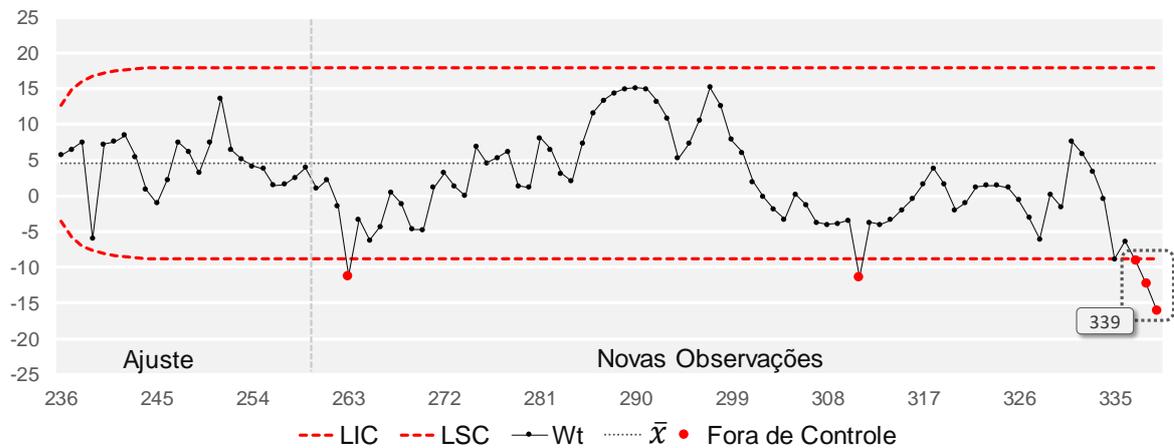
Tabela 5 – Modelo ARIMA – primeiro reajuste

Modelo	Parâmetros		p-valor	AICc
ARIMA (1,0,0)	AR(p)	$\phi_1 = 0,4381$	< 0,01	1055,91
	MA(q)	-	-	

Fonte: Elaborado pelo autor

Na Figura 13 observa-se que com o primeiro reajuste o modelo de previsão apresentou recorrência em erros fora de controle no instante 339, conforme os critérios definidos na seção II. Em relação ao modelo inicial a ocorrência seguinte foi no instante 289 (Figura 12), evidenciando um ganho de 50 períodos com previsão acuradas dentro dos critérios adotados.

Figura 13 – Gráfico EWMA dos erros do modelo ARIMA(1,0,0) até a hora 339



Fonte: Elaborado pelo autor

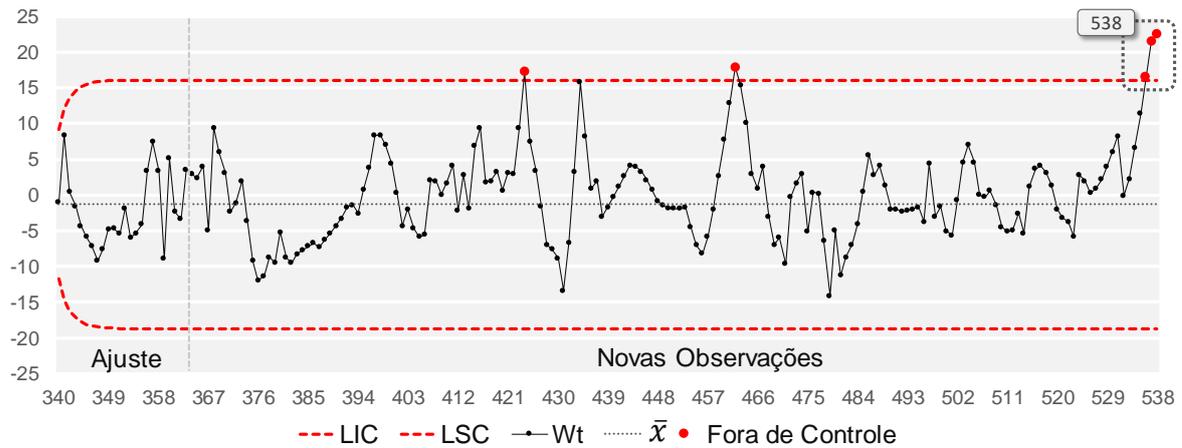
Novamente foi realizado o reajuste do modelo, considerando a inclusão de novas observações, utilizando os 120 períodos anteriores ao momento que o modelo anterior apresentou recorrência em erros fora de controle (220 – 339), sendo selecionado o ARIMA (0,1,2), conforme a Tabela 6. Com o segundo reajuste o modelo de previsão apresentou recorrência em erros fora de controle no instante 538 (Figura 14). Em relação ao modelo inicial a ocorrência seguinte foi no instante 370 (Figura 12), evidenciando um ganho de 168 períodos de acurácia.

Tabela 6 – Modelo ARIMA – segundo reajuste

Modelo	Parâmetros	p-valor	AICc	
ARIMA (0,1,2)	AR(p)	-	-	
	MA(q)	$\theta_1 = -0,5227$	$< 0,01$	1045,06
		$\theta_2 = 0,0928$	0,03	

Fonte: Elaborado pelo autor

Figura 14 – Gráfico EWMA dos erros do modelo ARIMA(0,1,2) até a hora 538



Fonte: Elaborado pelo autor

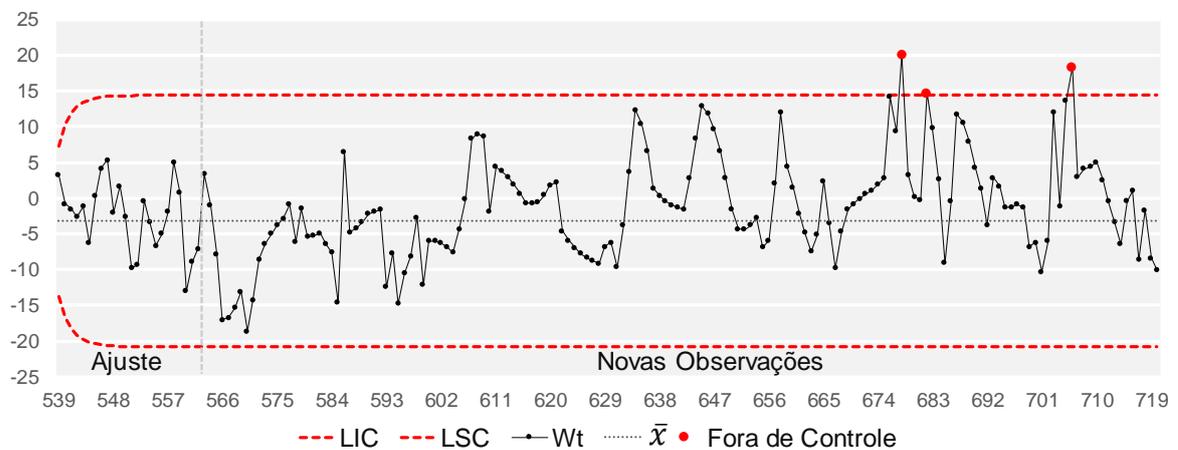
O terceiro reajuste ocorreu utilizando a inclusão das observações (539-562), sendo selecionado o ARIMA (1,0,0), conforme a Tabela 7. Com o terceiro reajuste o modelo de previsão apresentou-se estável até o fim da série temporal analisada, não apresentando comportamento de recorrência em erros fora de controle, conforme Figura 15.

Tabela 7 – Modelo ARIMA – terceiro reajuste

Modelo	Parâmetros		p-valor	AICc
ARIMA (1,0,0)	AR(p)	$\phi_1 = 0,5719$	< 0,01	1059,63
	MA(q)	-	-	

Fonte: Elaborado pelo autor

Figura 15 – Gráfico EWMA dos erros do modelo ARIMA(1,0,0) até a hora 720

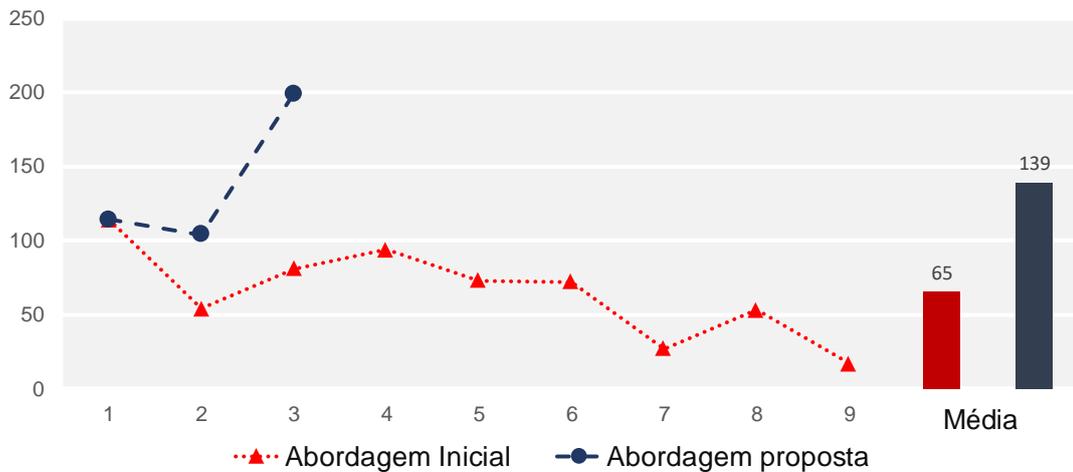


Fonte: Elaborado pelo autor

Comparado com a abordagem inicial, para a variável considerada ao longo de um mês de operação, a abordagem proposta reduziu o número de recorrências nos erros de previsão fora de controle estatístico, em que o modelo inicial apresentou nove momentos em relação a três, quando considerado o reajuste a partir da inclusão de novas observações.

O tempo entre a recorrência nos erros, comparando as duas abordagens, é apresentado na Figura 16, evidenciando que a utilização de um modelo único de previsão tende a apresentar erros com recorrência cada vez maior e com perda de acurácia ao longo do tempo. O comportamento oposto foi observado em relação à abordagem proposta, em que houve uma maior estabilidade entre os intervalos, com tempo médio entre a ocorrência de recorrência de 139 horas em relação a 65 horas da abordagem inicial, resultando em um ganho médio aproximado de 144% no intervalo entre as ocorrências de erros de previsão fora de controle estatístico.

Figura 16 – Tempo entre recorrências de erros fora de controle estatístico.



Fonte: Elaborado pelo autor

Além da redução da recorrência de erros, a acurácia global das duas abordagens foi comparada pelas medidas Erro Absoluto Médio (MAE), Raiz do Erro Quadrático Médio RMSE e Erro Absoluto Percentual Médio (MAPE), conforme Tabela 8. A abordagem proposta se mostrou superior para as três medidas de acurácia consideradas, apresentando menores valores, evidenciando ganhos em termos de precisão.

Tabela 8 – Medidas de acurácia

	MAE	RMSE	MAPE
Abordagem inicial	16.2838	22.1596	15.4272
Abordagem proposta	16.0236	22.0611	15.1319

Fonte: Elaborado pelo autor

Dessa forma, os resultados encontrados demonstraram que, para o caso estudado, a abordagem proposta apresentou resultados significativos, tanto para a redução da recorrência de erros no processo de previsão do indicador, quanto no aumento da acurácia global dos modelos ajustados, indicando a abordagem proposta como uma alternativa viável para o monitoramento de erros de previsão no contexto industrial.

5 CONCLUSÃO

Os métodos de previsão são importantes ferramentas no processo de tomada de decisão nas organizações, gerando subsídios que auxiliam gestores no monitoramento de processos, possibilitando decisões mais assertivas baseadas em modelos estatísticos e computacionais.

A aplicação da modelagem ARIMA foi capaz de capturar o comportamento da variável estudada no curto prazo, muito embora apresentando erros generalizados ao longo do período, devido ao dinamismo e à volatilidade do sistema, indicando a presença de efeitos estocásticos na variação do tempo de processamento. Nesse contexto, a abordagem proposta utilizou o gráfico EWMA para auxiliar no processo de reajuste do modelo de previsão na presença de recorrências em erros fora de controle estatístico.

Foram demonstrados ganhos tanto na redução da recorrência dos erros de previsão, quanto na precisão. Dessa forma, esse estudo apresenta uma contribuição original à literatura ao propor e implementar uma nova abordagem para o monitoramento de modelos previsão na recorrência de erros fora de controle de estatístico no contexto industrial, apresentando conjuntamente a aplicação da proposta em um estudo de caso real em um sistema produtivo de grande porte. A abordagem proposta é facilmente replicável, podendo ser estendida a outros contextos que envolvam tomada de decisão, com a disponibilização da metodologia implementada em linguagem de programação livre R (Apêndice A).

Os resultados encontrados capacitam a abordagem proposta para ser utilizada como uma alternativa robusta e viável na modelagem de sistemas produtivos com características dinâmicas, em que o mecanismo gerador do processo tende a mudar ao decorrer do tempo. Como sugestão para futuras pesquisas recomenda-se a utilização de outros gráficos de controle, como o gráfico de somas acumuladas (CUSUM), assim como outros modelos de previsão como modelos de suavização exponencial e redes neurais artificiais. Em estudos futuros pretende-se estender a abordagem proposta em aplicações com grandes conjuntos de dados, permitindo a avaliação em séries com diferentes características de tendência e sazonalidade.

REFERÊNCIAS

- ADAMS, B. M.; TSENG, I.-T. Robustness of forecast-based monitoring schemes. **Journal of Quality Technology**, v. 30, p. 328-339, 1998.
- AKAIKE, H. Information theory and an extension of the maximum likelihood principle. **2nd International Symposium on Information Theory**, Tsahkadsor, Armenia, USSR, 1973.
- ANDERSON, D. R. et al. **An Introduction to Management Science: Quantitative Approach**. [S.l.]: Cengage learning, 2018.
- ARIA, M.; CUCCURULLO, C. bibliometrix: An R-tool for comprehensive science mapping analysis, v. 11, n. 4, p. 959-975, 2017.
- BONO, C. et al. Dynamic production monitoring in pig herds II. Modeling and monitoring farrowing rate at herd level. **Livestock Science**, v. 155, n. 1, p. 92-102, 2013.
- BONO, C.; CORNOU, C.; KRISTENSEN, A. R. Dynamic production monitoring in pig herds I: Modeling and monitoring litter size at herd and sow leve. **Livestock Science**, v. 149, n. 3, p. 289-300, 2012.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control**. [S.l.]: Holden Day, 1970.
- BOX, G.; LUCENO, A.; DEL CARMEN PANIAGUA-QUINONES, M. **Statistical control by monitoring and adjustment**. [S.l.]: John Wiley & Sons, 2011.
- BUENO, R. L. S. **Econometrica de séries temporais**. São Paulo: Cengage Learning, 2008.
- CHENG, C.-S.; CHEN, P.-W.; HUANG, K.-K. Estimating the shift size in the process mean with support vector regression and neural networks. **Expert Systems with Applications**, v. 38, n. 8, p. 10624-10630, 2011.
- CHOPRA, V. et al. A case study: application of statistical process control tool for determining process capability and sigma level. **PDA journal of pharmaceutical science and technology**, v. 66, n. 2, p. 98-115, 2012.
- COBO, M. et al. An approach for detecting, quantifying, and visualizing the evolution of a research field: A practical application to the fuzzy sets theory field. **Journal of informetrics**, v. 5, n. 1, p. 146-166, 2011.
- DEL CASTILLO, E. **Statistical process adjustment for quality control**. [S.l.]: Wiley-Interscience, v. 369, 2002.
- FERREIRA, P. G. C. **Análise de Séries Temporais em R: curso introdutório**. [S.l.]: Rio de Janeiro: Elsevier, 2018.
- FIRMINO, P. R. A.; MATTOS NETO, P. S. G.; FERREIRA, T. A. E. Correcting and combining time series forecasters. **Neural Networks**, v. 50, p. 1-11, 2014.

FRAZZON, E.; KUCK, M.; FREITAG, M. Data-driven production control for complex and dynamic manufacturing systems. **CIRP Annals**, v. 67, n. 1, p. 515-518, 2018.

GANDRUD, C. **Reproducible research with R and R studio**. [S.l.]: Chapman and Hall/CRC, 2016.

GUERRERO-BOTE, V.; MOYA-ANEGON, F. A further step forward in measuring journals' scientific prestige: The SJR2 indicator, v. 6, n. 4, p. 674-688, 2012.

HAMZA, S. Monitoring and controlling design process using control charts and process sigma. **Business process management Journal**, v. 15, n. 3, p. 358-370, 2009.

HARROU, F. et al. An improved multivariate chart using partial least squares with continuous ranked probability score. **IEEE Sensors Journal**, v. 18, n. 16, p. 6715-6726, 2018.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. [S.l.]: OTexts, 2018.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series for forecasting: the forecast package for R. **Journal of Statistical Software**, v. 27, 2008.

JACOBS, W.; SOUZA, A. M.; ZANINI, R. R. Combination of Box-Jenkins and MLP/RNA models for forecasting. **IEEE Latin America Transactions**, v. 14, p. 1870-1878, 2016.

KANDANANOND, K. Guidelines for applying statistical quality control method to monitor autocorrelated processes. **Procedia Engineering**, v. 69, p. 1449-1458, 2014.

KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, p. 159-178, 1992.

LAMPREIA, S. et al. Condition monitoring based on modified CUSUM and EWMA control charts. **Journal of Quality in Maintenance Engineering**, v. 24, n. 1, p. 1355-2511, 2018.

MA, M.-D.; LI, J.-Y. Improved variable EWMA controller for general ARIMA processes. **IEEE Transactions on Semiconductor Manufacturing**, v. 28, n. 2, p. 129-136, 2015.

MAKRIDAKIS, S.; STEVEN, W.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3. ed. New Jersey: John Wiley & Sons, 1998.

MATIAS, R. et al. **Comparison analysis of statistical control charts for quality monitoring of network traffic forecasts**. 2011 IEEE International Conference on Systems, Man, and Cybernetics. [S.l.]: [s.n.]. 2011. p. 404-409.

MIEKLEY, B. et al. Implementation of multivariate cumulative sum control charts in mastitis and lameness monitoring. **Journal of dairy science**, v. 96, n. 9, p. 5723-5733, 2013.

MILLER, K.; TSANG, E. Testing management theories: Critical realist philosophy and research methods. **Strategic Management Journal**, v. 32, n. 2, p. 139-158, 2011.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. New Jersey: John Wiley & Sons, 2007.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. [S.l.]: John Wiley & Sons, 2015.

OLIVEIRA, G.; ROSA, L. Aplicação de Cartas de Controle MMEP Em Resíduos de um Modelo de Previsão de Pico de Demanda de Energia Elétrica/Application of Ewma Control Charts in Residuals of a Forecast Model of Peak Electric Power Demand. **Revista FSA (Centro Universitário Santo Agostinho)**, v. 15, p. 130-146, 2018.

R CORE TEAM. R: A language and environment for statistical computing, 2019.

ROSIENKIEWICZ, M.; CHLEBUS, E.; DETYNA, J. A Hybrid Spares Demand Forecasting Method Dedicated to Mining Industry. **Applied Mathematical Modelling**, v. 49, p. 87-107, 2017.

SCHOLZ-REITER, B.; KÜCK, M.; LAPPE, D. Prediction of customer demands for production planning--Automated selection and configuration of suitable prediction methods. **CIRP Annals**, v. 63, p. 417-420, 2014.

SCRUCCA, L. qcc: an R package for quality control charting and statistical process control. **dim (pistonrings)**, v. 1, p. 3, 2004.

SHAMSUZZAMAN, M.; WU, Z. Design of EWMA control chart for minimizing the proportion of defective units. **International Journal of Quality & Reliability Management**, v. 29, n. 8, p. 953-969, 2012.

SLACK, N.; BRANDON-JONES, A.; JOHNSTON, R. **Administração da Produção**. São Paulo: Atlas, 2015.

SOUZA, A. M. et al. Eletrical energy supply for Rio Grande do Sul, Brazil, using forecast combination of weighted eigenvalues. **GEPROS: Gestão da Produção, Operações e Sistemas**, v. 6, p. 23, 2011.

SOUZA, F. M. **Modelos de Previsão: aplicações à energia elétrica - ARIMA - ARCH - AI e ACP**. Curitiba: Appris, 2016.

SOUZA, G. P.; SAMOBYL, R. W. **Monitoring forecast errors with combined CUSUM and Shewhart control charts**. 26th Proceedings of the International Symposium of Forecasting. [S.l.]: [s.n.]. 2008.

TERKAJ, W.; TOLIO, T.; URGO, M. A virtual factory approach for in situ simulation to support production and maintenance planning. **CIRP Annals**, v. 64, n. 1, p. 451-454, 2015.

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a methodology for developing evidence-informed management knowledge by means of systematic review. **British journal of management**, v. 14, n. 3, p. 207-222, 2003.

UEDA, R. et al. Combinação de técnicas de previsão de demanda: aplicação em uma agroindústria de nutrição animal. **Exacta**, v. 16, n. 2, p. 83-93, 2018.

WANG, F.-K.; CHANG, K.-K. Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer. **Expert Systems with Applications**, v. 37, p. 8119-8126, 2010.

WANG, F.-K.; CHANG, K.-K. Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer. **Expert Systems with Applications**, v. 37, p. 8119-8126, 2010.

WANG, H.; YAO, M. Fault detection of batch processes based on multivariate functional kernel principal component analysis. **Chemometrics and Intelligent Laboratory Systems**, v. 149, p. 78-89, 2015.

WERNER, L. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. **Tese (Doutorado) - Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2005.

ZHANG, X.; PRAJAPATI, M.; PEDEN, E. A stochastic production planning model under uncertain seasonal demand and market growth. **International journal of production research**, v. 49, n. 7, p. 1957-1975, 2011.

APÊNDICE A

Código em R da abordagem proposta, desenvolvido na versão 3.5.2, utilizando os pacotes ‘forecast’ versão 8.5 e ‘qcc’ versão 2.7. O banco de dados utilizado no caso teste está disponível na forma de hyperlink (<https://zenodo.org/record/2591771/files/TMD.txt>) direto no código a seguir (como argumento da função “read.table”):

Instalação das bibliotecas

```
install.packages("forecast", dependencies = TRUE)
```

```
install.packages("qcc", dependencies = TRUE)
```

Carregando bibliotecas

```
library(forecast)
```

```
library(qcc)
```

Importando dados

```
st <- read.table("https://zenodo.org/record/2591771/files/TMD.txt", header=T)
```

```
TMD <- ts(st$TMD, start = 1, frequency = 1)
```

Cálculo da média e desvio padrão

```
mean(TMD)
```

```
sd(TMD)
```

Modelo ARIMA Inicial

```
TMD1 <- window(TMD, end = 120) # série inicial (1 - 120)
```

```
fit1 <- Arima(TMD1, order = c(1,0,1)) # Modelo inicial
```

```
erro_out <- resid(Arima(window(TMD, start = 145, end = 720), model = fit1))
```

```
erro1 <- resid(Arima(window(TMD, start = 121, end = 144), model = fit1))
```

```
erro2 <- resid(Arima(window(TMD, start = 145, end = 235), model = fit1))
```

```
ewma(erro1, newdata = erro2, nsigmas = 2) # Gráfico EWMA
```

Modelo ARIMA – Primeiro Reajuste

```
TMD2 <- window(TMD, start = 116, end = 235) # série primeiro reajuste
```

```
fit2 <- auto.arima(TMD2)
```

```
erro3 <- resid(Arima(window(TMD, start = 236, end = 259), model = fit2))
erro4 <- resid(Arima(window(TMD, start = 260, end = 339), model = fit2))
ewma(erro3, newdata = erro4, nsigmas = 2)
```

Modelo ARIMA – Segundo Reajuste

```
TMD3 <- window(TMD, start = 220, end = 339) # série segundo reajuste
fit3 <- auto.arima(TMD3)
erro5 <- resid(Arima(window(TMD, start = 340, end = 363), model = fit3))
erro6 <- resid(Arima(window(TMD, start = 364, end = 538), model = fit3))
ewma(erro5, newdata = erro6, nsigmas = 2)
```

Modelo ARIMA – Terceiro Reajuste

```
TMD4 <- window(TMD, start = 419, end = 538) # série terceiro reajuste
fit4 <- auto.arima(TMD4)
erro7 <- resid(Arima(window(TMD, start = 539, end = 562), model = fit4))
erro8 <- resid(Arima(window(TMD, start = 563, end = 720), model = fit4))
ewma(erro7, newdata = erro8, nsigmas = 2)
```

Medidas de acurácia

```
erro2_8 <- ts(c(erro2,erro3,erro4,erro5,erro6,erro7,erro8), start=start(erro2), frequency = 1)
```

```
MAE_A <- mean(abs(erro_out)) %>% print
```

```
MAE_B <- mean(abs(erro2_8)) %>% print
```

```
RMSE_A <- sqrt(mean(erro_out^2)) %>% print
```

```
RMSE_B <- sqrt(mean(erro2_8^2)) %>% print
```

```
Mape_A <- mean(abs(erro_out/(window(TMD, start = 145, end = 720)))) %>% print
```

```
Mape_B <- mean(abs(erro2_8/(window(TMD, start = 145, end = 720)))) %>% print
```