

APLICAÇÃO DO MÉTODO DE MONTE CARLO PARA A PREVISÃO DE FALHAS: UMA FERRAMENTA DE APOIO À GESTÃO DA MANUTENÇÃO

APPLICATION OF MONTE CARLO METHOD FOR FAILURE PREDICTION: A TOOL TO SUPPORT MAINTENANCE MANAGEMENT

Lucas Guedes de Oliveira* E-mail: lucasguedesdeoliveira@gmail.com

Emerson José de Paiva* E-mail: emersonpaiva@unifei.edu.br

Anderson Paulo de Paiva* E-mail: andersonppaiva@unifei.edu.br

*Universidade Federal de Itajubá (UNIFEI), Itajubá, MG

Resumo: A área de manutenção tem passado por mudanças importantes nas últimas décadas, orientada, principalmente, pela evolução dos conceitos gerenciais nas empresas. Embora tenha sido tratada, por longos períodos, como um setor oneroso para as organizações, a manutenção é apontada, na literatura mais recente, como uma enorme fonte de competitividade. Para explorar seu potencial, no entanto, a Gestão da Manutenção deve incorporar a Engenharia como o agente direcionador dos processos de rotina e melhorias. De forma prática, a empresa deve trabalhar para evitar as falhas ou, no mínimo, prevê-las. Alinhado a essa visão estratégica, o presente trabalho empenha-se no desenvolvimento e validação de um sistema de previsão de falhas. Utilizando-se do Método de Monte Carlo, este artigo integra um estudo de natureza quantitativa do gênero modelagem e simulação. A partir de conceitos matemáticos e estatísticos, foram formuladas diferentes séries de previsão de falhas e realizadas análises comparativas de suas precisões. Como resultados, foi constatada a eficácia do método na determinação do momento de ocorrência de falhas a partir de simulações numéricas e evidenciadas as regiões ótimas de previsão de cada série proposta. Dentre as principais contribuições do trabalho, destaca-se a maior precisão das séries simuladas pelo Método de Monte Carlo em relação às séries estimadas a partir da média histórica dos dados, apesar do bom ajuste dessas séries em áreas selecionadas da curva real. Trabalhos futuros irão investigar o comportamento de outros modelos de séries de falhas, geradas a partir de novas combinações dos parâmetros propostos.

Palavras-chave: Engenharia de Manutenção. Simulação de Monte Carlo. Previsão de Falhas. Estatística Aplicada.

Abstract: The maintenance field has undergone important changes in the last decades, oriented, mainly, by the evolution of the managerial concepts in the companies. Although it has been treated for long periods as an onerous sector for organizations, maintenance is pointed out in the latest literature as a huge source of competitiveness. To explore its potential, however, Maintenance Management must incorporate Engineering as the driving force for routine processes and improvements. In a practical way, the company must work to avoid failures or, at least, to foresee them. In line with this strategic vision, the present work engages in the development and validation of a failure prediction system. Using the Monte Carlo Method, this article integrates a quantitative study of modeling and simulation. From mathematical and statistical concepts, different failure prediction series were formulated and comparative analyses were performed on their precisions. As results, it was verified the effectiveness of the method in determining the moment of occurrence of failures from numerical simulations and evidenced the optimal regions of prediction of each proposed series. Among the main contributions of the study, we highlight the higher precision of the series simulated by the Monte Carlo Method in relation to the series estimated from the historical average of the data, despite the good adjustment of these series in selected areas of the real curve. Future works will investigate the behavior of other models of a series of failures, generated from new combinations of the proposed parameters.

Keywords: Maintenance Engineering. Monte Carlo Simulation. Failures Prediction. Applied Statistics.

1 INTRODUÇÃO

Em um cenário de contínuas mudanças, muitos conceitos gerenciais têm evoluído na direção de posicionamentos mais estratégicos (CARVALHO; PALADINI, 2012; HORNGREEN; DATAR; RAJAN, 2012). Na gestão da manutenção, novas diretrizes têm sido apontadas com vistas à agregação de valor para o negócio (SANTOS; SELLITTO, 2016; VAN HORENBEEK; PINTELON; MUCHIRI, 2010). Nesse sentido, a área de manutenção é apresentada como uma proeminente fonte de competitividade para as empresas (BARBERÁ, *et al.*, 2012).

A fim de explorar seu valor estratégico, estudos recentes propõem a Engenharia de Manutenção como o agente direcionador dos processos de rotina e melhorias (KARDEC; NASCIF, 2013). Assim, centrados nas práticas de engenharia, os setores de manutenção podem estabelecer cursos de ação mais assertivos, ao utilizar técnicas e métodos baseados em evidências.

Nesse contexto estratégico, o novo paradigma da manutenção sustenta-se na ideia de que a não existência de falhas é o melhor indicador de sucesso para a empresa. E, quando da impossibilidade de evitá-las, deve-se, no mínimo, prevê-las (KARDEC; NASCIF, 2013).

Em vista disso, o presente trabalho busca o desenvolvimento de um sistema de previsão de falhas, a fim de corroborar para o alinhamento das práticas de engenharia a esse novo conceito. Apesar das múltiplas possibilidades de investigação do tema, este estudo limita-se ao desenvolvimento do sistema e à avaliação de sua eficácia em função das condições impostas ao modelo.

Com esse objetivo, o presente trabalho emprega o Método de Monte Carlo como recurso para a modelagem computacional. Assim, este artigo empenha-se ainda em outro desafio, uma vez que a literatura revela uma não-aplicação do método nas empresas (HALL, 2012), apesar de ter sua eficácia comprovada para a resolução de problemas (SANTOS *et al.*, 2013; PRIESOL *et al.*, 2013). Desse modo, ao empregá-lo no desenvolvimento de uma ferramenta de previsão, o presente estudo acaba por fornecer mais uma aplicação industrial para esse tipo de simulação.

Além disso, ao vislumbrar a validação do modelo desenvolvido, esta análise busca suscitar uma discussão sobre as vantagens dos processos aleatórios na resolução de problemas de engenharia. De forma complementar, busca, ainda, a

construção de uma ferramenta que seja, de fato, aplicável à realidade prática das corporações. Assim, com base nos pontos positivos do uso de planilhas eletrônicas para a simulação (SEILA, 2004), este trabalho propõe o desenvolvimento de um modelo técnico e científico compatível com plataformas de uso cotidiano das empresas, como o Microsoft Excel™.

Dado o exposto, o presente estudo enquadra-se na área temática de Pesquisa Operacional, englobando quatro de suas sete subáreas, a saber: Modelagem, Simulação e Otimização; Processos Decisórios; Processos Estocásticos; e Análise de Demanda (ABEPRO, 2008). De outro lado, por utilizar ferramentas da Pesquisa Operacional para atender à Gestão da Manutenção, também contempla a grande área de Engenharia de Operações e Processos da Produção.

Nesse contexto, este estudo revela um caráter interdisciplinar, incorporando outro atributo de relevância a sua condução, haja vista que “a abordagem interdisciplinar consiste em romper as fronteiras do conhecimento” (LARUCCIA *et al.*, 2012, p.116). Assim, além de desdobrar a problemática segundo métodos científicos, este trabalho busca produzir novos saberes a partir do relacionamento entre disciplinas conhecidas.

A fim de conduzir a análise sob um encadeamento lógico, este trabalho foi organizado em cinco seções principais. Após a Introdução (seção 1), a seção 2 apresenta o referencial teórico, discorrendo sobre o panorama estratégico do tema e os fundamentos do método adotado.

Na sequência, a seção 3 detalha os procedimentos utilizados para a consecução dos objetivos propostos. A seção 4, por sua vez, apresenta e discute os resultados finais da análise, explorando suas múltiplas perspectivas. Finalmente, a seção 5 traz as conclusões do estudo, destacando seus principais pontos e apontando seus direcionamentos futuros.

2 REFERENCIAL TEÓRICO

A fim de percorrer as principais áreas que envolvem a temática proposta neste trabalho, bem como esclarecer o método utilizado, esta seção foi organizada em duas subseções com vistas ao atendimento dos seguintes temas: Gestão da Manutenção (seção 2.1) e Simulação de Monte Carlo (seção 2.2).

2.1 Gestão da Manutenção

Os modernos conceitos de Gestão da Manutenção têm fornecido novos paradigmas para as empresas (KARDEC; NASCIF, 2013). Nesse processo, a área de Manutenção tem sido analisada sob diferentes óticas. Em uma visão do negócio, é tratada como função estratégica. Em níveis mais técnicos, como um setor guiado pela Engenharia. À luz de uma interpretação integrada, porém, essas visões se apresentam como complementares. Com vistas ao esclarecimento dessas perspectivas, esta seção apresenta um panorama sobre ambas, a saber: Manutenção Estratégica (seção 2.1.1) e Engenharia de Manutenção (seção 2.1.2).

2.1.1 Manutenção Estratégica

A área de Manutenção tem passado por grandes avanços ao longo das décadas. Apesar de não ser tratada, em muitos casos, como uma das principais funções de negócios (STEVENSON, 2011), alguns pesquisadores apresentam novos paradigmas.

Em um contexto estratégico, a gestão da manutenção tem sido considerada um importante fator competitivo (BARBERÁ, *et al.*, 2012). Além disso, o setor de Manutenção tem obtido reconhecimento no processo de agregação de valor para o negócio (VAN HORENBEEK; PINTELON; MUCHIRI, 2010). Nessa visão, o controle dos custos de manutenção também tem sido avaliado como um dos pilares estratégicos da excelência operacional (PERES; LIMA, 2008).

Em vista disso, ao nível de execução da manutenção, o aumento da competitividade também tem se traduzido em novas perspectivas. Em uma visão moderna, “não é mais aceitável que o equipamento ou sistema pare de maneira não prevista [...]” (KARDEC; NASCIF, 2013, p. 20). Por esse motivo, estratégias de manutenção são conduzidas a fim de aumentar a disponibilidade das unidades de produção (PAI; RANE, 2013).

Apesar dessa visão, dados revelam que a indisponibilidade devido a manutenção pouco variou nas últimas décadas no Brasil. Além disso, embora tenha ocorrido redução da fração de horas em serviços de manutenção corretiva, esta não se mostrou expressiva em relação a resultados passados (ABRAMAN, 2011).

Em estudos de indústrias de médio e grande porte do Brasil, pesquisadores observam que “[...] ainda é expressiva a quantidade de manutenções corretivas realizadas” (REIS; COSTA; ALMEIDA, 2013, p. 237), apesar de alertarem para os efeitos negativos dessa prática no desempenho da produção.

2.1.2 Engenharia de Manutenção

À nível mais técnico, muitas ferramentas são utilizadas para análises e decisões de Engenharia de Manutenção. Nesse contexto, diferentes métodos são aplicados na tentativa de melhorar índices de confiabilidade, disponibilidade e manutenibilidade (KARDEC; NASCIF, 2013).

Alguns autores explicam o conceito de confiabilidade em função do sucesso das operações na condição de ausência de falhas (FOGLIATTO; RIBEIRO, 2009). O termo disponibilidade, por outro lado, é utilizado para descrever a “capacidade de um item estar em condições de executar uma certa função [...]” (ABNT, 1994, p. 2).

O conceito de manutenibilidade, particularmente, pode ser dado tanto em relação à facilidade que um equipamento oferece à manutenção (KARDEC; NASCIF, 2013) quanto à capacidade dos executantes em realizar os reparos (CASTRO, *et al.*, 2011).

De modo geral, a Engenharia de Manutenção, baseada nesses fundamentos, busca “[...] a redução de desperdícios, a modificação de sistemas obsoletos e a implantação de metodologias eficazes” (PERES; LIMA, 2008, p. 149). Por esse motivo, abordagens recentes têm sugerido técnicas modernas em combinação com estratégias de manutenção existentes (FARIA; RIBEIRO; VIANA, 2016; TINGA, 2010).

Nesse contexto, estudos atuais também aludem à importância de se determinar as melhores estratégias de manutenção, haja vista a presença de restrições orçamentárias (ORCESI; FRANGOPOL, 2011; TEODORO FILHO *et al.*, 2017). Além disso, a finalidade de se escolher diferentes estratégias sustenta-se em “[...] evitar quebras e defeitos prematuros em equipamentos, bem como aumentar os tempos de resposta para o reaparecimento de falhas, a fim de melhorar a disponibilidade total da planta”¹ (PAI; RANE, 2013).

¹ “[...] to avoid breakdowns, premature equipment malfunctions and to increase response times to recover from failure, in order to improve overall plant availability.”

2.2 Simulação de Monte Carlo

A Simulação de Monte Carlo tem sido aplicada para a resolução de diferentes problemas da engenharia moderna. Entretanto, a base para sua fundamentação se apresenta como um conceito antigo. Esta seção expõe os principais pilares que caracterizam esse tipo de simulação. O principal objetivo é esclarecer o encadeamento lógico que pressupõe o método (seção 2.2.1). No entanto, pretende-se também apontar algumas de suas aplicações a fim de ilustrar sua utilização prática (seção 2.2.2).

2.2.1 O Método de Monte Carlo

O Método de Monte Carlo tem sua origem em bases estatísticas e probabilísticas. Sua primeira formulação científica foi enunciada no início da Segunda Guerra Mundial em um estudo envolvendo os pesquisadores Stanislaw Ulam e John von Neumann. Sua terminologia apresenta-se como uma referência aos jogos de azar do famoso cassino de Mônaco (HAMMERSLEY; HANDSCOMB, 1964; METROPOLIS, 1987).

Em uma de suas primeiras definições, esse método é descrito como a utilização de um processo aleatório que, baseado em distribuições de probabilidade, “[...] leva a determinação de um novo conjunto de valores”² (METROPOLIS; ULAM, 1949, tradução nossa). Estudos atuais ampliam esse conceito expressando o método como a associação de valores aleatórios à problemas reais em busca de soluções viáveis (SARAIVA JUNIOR; RODRIGUES; COSTA, 2010).

Alguns pesquisadores, sob outra perspectiva, apontam para o termo “Monte Carlo” como um agrupamento genérico de técnicas de probabilidade e amostragem utilizadas na resolução de problemas de caráter complexo (SYLVESTER, 1970). A literatura recente confirma essa visão ao afirmar que a nomenclatura “[...] descreve uma abordagem ampla que engloba muitas técnicas específicas”³ (HAIGH; PRIESTLEY; ROPE, 2014, tradução nossa).

De fato, em estudos modernos, a ideia básica do método apresenta-se como

² “[...] lead to the determination of a new set of values.”

³ “[...] describes a broad approach encompassing many specific techniques”

um conceito de natureza simples (CHWIF; MEDINA, 2010), o que reforça seu caráter generalista. Utilizando-se de sua fundamentação, porém, encontram-se soluções para variados tipos de problemas, dentre os quais muitos com elevado grau de dificuldade (JIANG *et al.*, 2014).

Nesse contexto, há consenso sobre a eficácia da técnica em diferentes aplicações (SANTOS *et al.*, 2013; PRIESOL *et al.*, 2013). Apesar disso, a literatura também revela que as “[...] empresas têm resistido à utilização da simulação de Monte Carlo [...]”⁴ (HALL, 2012, tradução nossa) ao que atribui, como um dos motivos, a ausência de conhecimento de seus pressupostos estatísticos.

Em termos conceituais, essa constatação concorda com os enunciados do método, uma vez que, por definição, este envolve uma abordagem estatística e estocástica (WANG, 2014). Além disso, destaca uma lacuna importante, haja vista o enorme campo de aplicação industrial para esse modelo de simulação.

2.2.2 Aplicações Recentes

Em vista de sua conceituação, a simulação de Monte Carlo tem sido aplicada desde a melhoria dos processos de atendimento em oficinas de manutenção (CASTRO, *et al.*, 2011) até a otimização do desempenho de computadores (PAULI; KOHLER; ARBENZ, 2014). Em decisões gerenciais, o método tem garantido a definição do melhor mix de produtos, baseando-se em conceitos contábeis (SARAIVA JUNIOR; RODRIGUES; COSTA, 2010). Por outro lado, também tem possibilitado o desenvolvimento de ferramentas de auxílio à decisão de investimentos (MONTEIRO; SANTOS; WERNER, 2012).

Em muitos casos, o Método de Monte Carlo também tem sido utilizado em conjunto com outras metodologias, a fim de atender a particularidades de certos problemas. Estudos para a determinação do ciclo de vida e confiabilidade, por exemplo, associam-no às Cadeias de Markov (PEIRAVI, 2008). Para a estimativa da capacidade de geração de energia eólica, alguns pesquisadores utilizam-se do mesmo recurso (GURGUR; JONES, 2010). Outras análises, todavia, com o objetivo de quantificar incertezas associadas à prospectos de exploração mineral, acabam por

⁴ “[...] companies have been reluctant to implement Monte Carlo simulation [...]”

integrá-lo à Lógica Fuzzy (LISITSIN; PORWAL; MCCUAIG, 2014).

Nesse contexto de vastas aplicações, os sistemas de previsão se apresentam como mais um dos desdobramentos da simulação de Monte Carlo. Trabalhos recentes, por exemplo, utilizam-se do método para previsão do ciclo de vida de ativos (ZHOU, *et al.*, 2011). Em outras abordagens, pesquisadores investigam a probabilidade de ocorrência de falhas em tubulações de geradores de vapor (HU *et al.*, 2011). Alguns autores, ainda, apresentam modelos para validação da probabilidade de falha de estruturas sujeitas ao fogo (NIGRO, *et al.*, 2014).

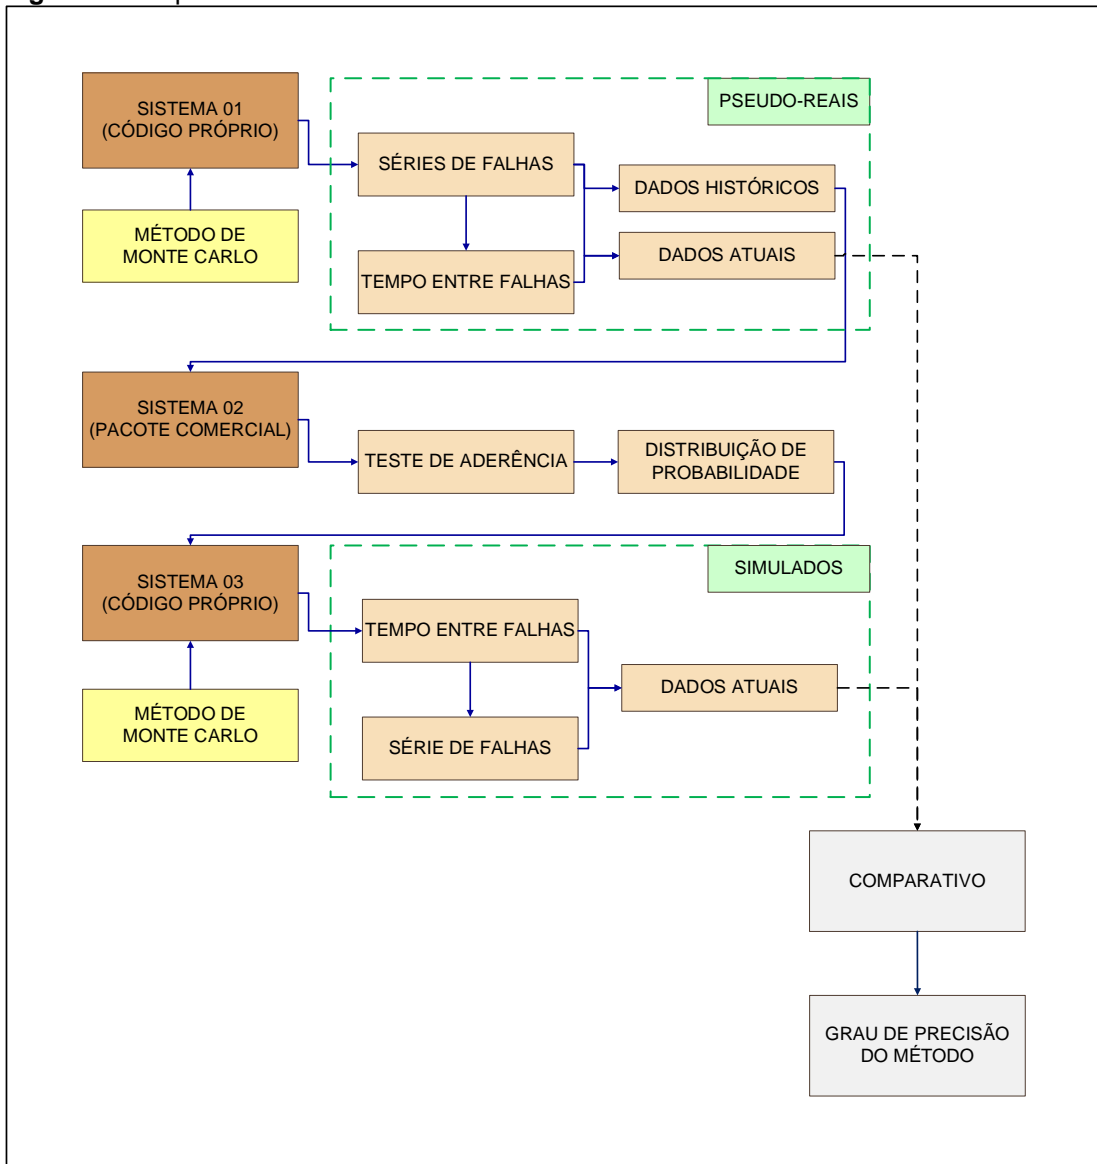
3 MATERIAIS E MÉTODOS

Esta seção discorre sobre os recursos e procedimentos utilizados para consecução dos objetivos do presente trabalho. Na seção 3.1, são descritos os conceitos e modelos do estudo. Na seção 3.2, é apresentado o equacionamento geral da análise.

3.1 Mapa conceitual e modelo matemático

O presente estudo utiliza-se do Método de Monte Carlo como recurso para o desenvolvimento de um sistema de previsão de falhas. Para isso, este é empregado em diferentes partes da estrutura do modelo a fim de constituir a base necessária à obtenção dos resultados. A Figura 1 ilustra o mapa conceitual do presente estudo. Por meio dela, é possível verificar a hierarquia de processos e visualizar, de forma geral, todos os procedimentos metodológicos do trabalho.

Figura 1 – Mapa conceitual do estudo



Fonte: Autoria própria (2017)

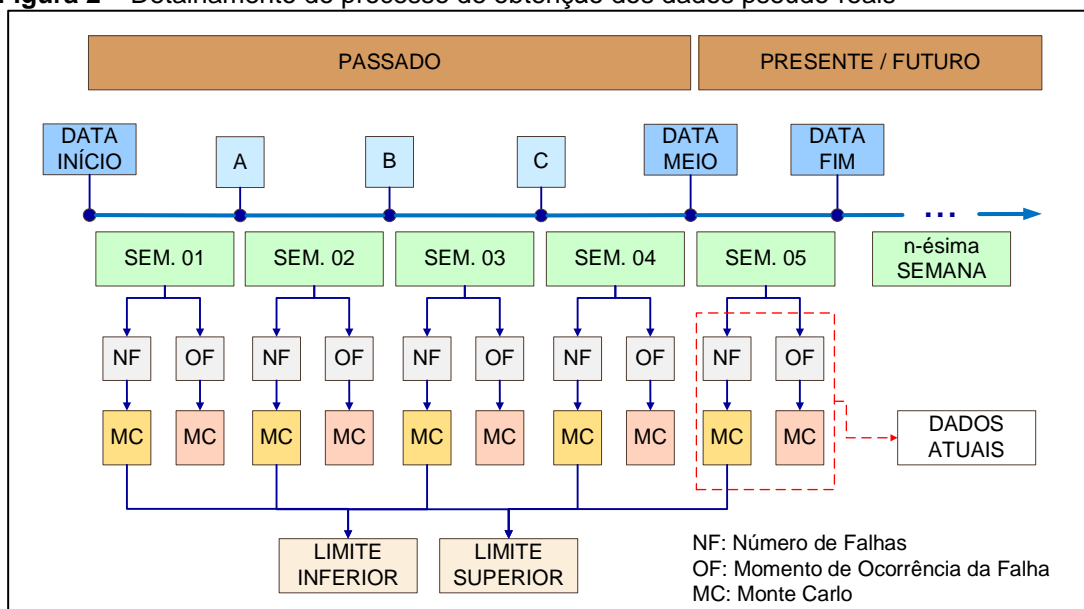
Para a consecução dos objetivos deste projeto, são necessários três sistemas principais. O primeiro deles (Sistema 01) é responsável pela obtenção dos dados denominados pseudo-reais. Isto é, a partir dele, são produzidas séries de falhas denotadas por datas de ocorrência. Por meio delas, são calculados os tempos entre falhas. Dessa forma, são gerados dois conjuntos de dados, a saber: históricos e atuais.

A Figura 2 detalha o método para a condução dessa primeira etapa e explicita de que maneira são incluídos os processos aleatórios que caracterizam o Método de Monte Carlo. Para a obtenção dos dados históricos (Passado), são definidas duas datas: início e meio. Assim, o intervalo de tempo entre elas pode ser dividido em quatro

subintervalos. Considerando-se o intervalo maior como um mês de 30 dias, têm-se, em seus subintervalos, as quatro semanas denotadas por Sem. 01, Sem. 02, Sem. 03 e Sem. 04⁵. Na Figura 2, as letras A, B e C representam as datas finais das três primeiras semanas.

Para cada semana considerada, são produzidos dois tipos de dados: o número de falhas da semana (*NF*) e o momento de ocorrência de cada falha (*OF*). A fim de garantir a aleatoriedade, são utilizados processos aleatórios para ambos os tipos de dados. Por esse motivo, a Figura 2 indica o Método de Monte Carlo (MC) abaixo de todas as caixas *NF* e *OF*.

Figura 2 – Detalhamento do processo de obtenção dos dados pseudo-reais



Fonte: Autoria própria (2017)

A fim de viabilizar a aplicabilidade desses resultados aos problemas reais de engenharia de manutenção, são incluídos os limites inferior e superior para o número de falhas de cada semana. Isso garante que, ao gerar um dado aleatório, o sistema não seja capaz de produzir resultados absurdos. Por exemplo, pode-se supor o caso da inclusão de zero falhas na primeira semana e milhares de falhas na segunda. Utilizando-se de limites adequados, é possível evitar cenários como esse.

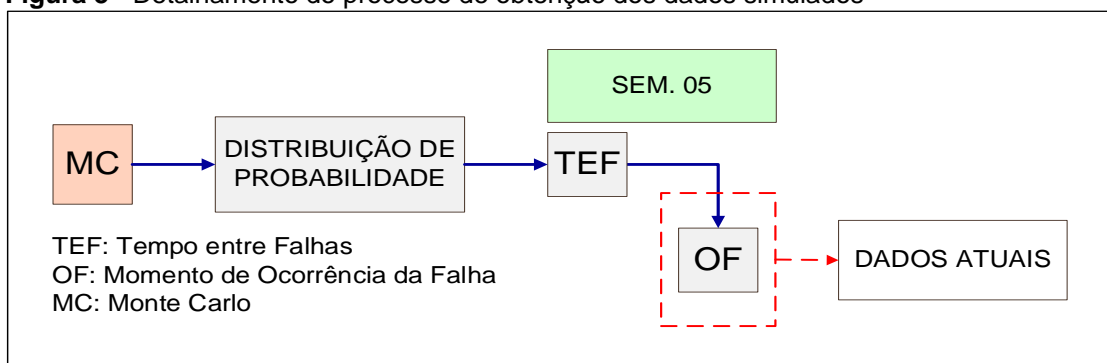
⁵ Para efeito de simplificação, a quarta semana irá conter nove dias, incluindo os dois dias restantes do mês. As demais conterão, convencionalmente, apenas sete.

De maneira indireta, a utilização das datas de início, meio e fim também impõem limites aos valores das variáveis *OF*, uma vez que não podem ser gerados fora dos intervalos definidos.

Para a obtenção dos dados atuais (Presente), são utilizadas as datas de meio e fim. Dessa forma, obtém-se uma quinta semana utilizando-se dos mesmos processos descritos para as quatro primeiras. Em termos práticos, esta pode ser considerada uma primeira semana do mês seguinte. A Figura 2 estende todo o encadeamento lógico para qualquer outro tempo futuro (genericamente, em uma *n*ésima semana).

Utilizando-se de um pacote comercial com ferramenta para análises de dados, o Sistema 02 ilustrado na Figura 1 é destinado à realização de um teste de aderência a partir dos dados históricos gerados pelo Sistema 01. Para esse teste, são utilizados os tempos entre falhas. Com isso, é possível a obtenção da distribuição de probabilidade desses dados, contendo todos os seus parâmetros estatísticos.

Figura 3 - Detalhamento do processo de obtenção dos dados simulados



Fonte: Autoria própria (2017)

Uma vez conhecida a distribuição de probabilidade, o Método de Monte Carlo é novamente empregado para a geração dos tempos entre falhas simulados (SYLVESTER, 1970). Esses tempos são obtidos para a produção dos dados atuais da quinta semana, como explicitado na Figura 1. De forma inversa ao primeiro sistema, o terceiro utiliza esses tempos para produzir a série de falhas. A Figura 3 apresenta os detalhes desse modelo.

Os tempos entre falhas produzidos definem todos os valores das variáveis *OF* com base na última ocorrência histórica. Isto é, a série de falhas atual simulada no Sistema 03 é resultado de um encadeamento de tempos vinculados ao último *OF*

existente. Em vista desse fato, pode-se conceituá-lo como um processo iterativo, no qual o último dado conhecido possibilita a geração de seu subsequente.

Para o desenvolvimento dos Sistemas 01 e 03 foi utilizado o pacote comercial de planilhas eletrônicas Microsoft Excel™, tendo em vista às inúmeras vantagens que proporciona à simulação (SEILA, 2004).

Considerando as características metodológicas apresentadas, este estudo é definido, conceitualmente, como uma abordagem quantitativa de caráter exploratório do gênero modelagem e simulação (GIL, 2002; MARTINS; MELLO; TURRIONI, 2014).

3.2 Equacionamento Geral

Como parte integrante do Sistema 01 (geração de dados pseudo-reais), as Equações 1 e 2 expressam o cálculo para obtenção das variáveis *OF* e *NF*. A partir da Equação 1, o momento de ocorrência de falhas é limitado tanto em relação ao horizonte de dias (período em data-calendário), quanto ao intervalo de operação (definido em horas):

$$OF = [LIP + (LFP - LIP) \times FPR_1] + [HIO + (HFO - HIO) \times FPR_2] , \quad (1)$$

onde *LIP* e *LFP* são, respectivamente, os limites inferior e superior do período em data-calendário; *HIO* e *HFO* são, respectivamente, as horas inicial e final de operação e *FPR*₁ e *FPR*₂ constituem-se dos fatores de proporção randômicos, gerados a partir do algoritmo aleatório do MS Excel™.

O número de falhas, por outro lado, é definido, exclusivamente, em termos de números típicos do processo analisado:

$$NF = MIF + (MAF - MIF) \times FPR_3 , \quad (2)$$

onde *MIF* e *MAF*, são, respectivamente, os números típicos de falhas mínimo e máximo do processo e *FPR*₃ é o fator de proporção randômico da expressão.

Para o Sistema 03, tem-se a geração dos valores aleatórios associada a função inversa daquela obtida por meio do Sistema 02. A Equação 3 denota esse processo,

evidenciando o componente aleatório e os parâmetros provenientes do teste de aderência. O tempo entre falhas é, então, obtido pela seguinte fórmula:

$$TEF = f^{-1}(x)_{[P;A]}, \quad (3)$$

onde $f^{-1}(x)$ é a função inversa da curva com o melhor ajuste sobre os dados pseudo-reais; P é o conjunto dos parâmetros da função desconhecida $f(x)$ e A é o valor aleatório gerado a partir do pacote comercial MS Excel™.

4 RESULTADOS E DISCUSSÕES

A partir do método proposto na seção 3, foi realizado um estudo detalhado das séries previstas. A fim de contrastá-las, foi utilizado um horizonte de 100 falhas, por meio das quais foram construídas as curvas características e contabilizados os erros associados a cada uma delas, validando o modelo e apontando seu grau de precisão.

Com o objetivo de esclarecer toda a pesquisa realizada, esta seção contempla desde os processos de obtenção dos dados (seções 4.1 a 4.3) até a condução dos testes e análise dos resultados obtidos (seções 4.4 e 4.5).

4.1 Dados pseudo-reais

A fim de produzir os dados históricos pseudo-reais, os parâmetros das variáveis OF e NF foram definidos para cada intervalo semanal. Em todos eles, o tempo de operação foi fixado em 24 horas (com início às 0:00h e fim às 23:59h), considerando-se o caso de equipamentos que operam constantemente (ou seja, param somente mediante demandas de manutenção).

Como quantidade típica de falhas, foram adotados limites arbitrários para as variáveis MIF e MAF , quais sejam 50 e 200, respectivamente. Em um caso real, isso representaria a ocorrência típica de 50 a 200 falhas a cada semana.

A Tabela 1 apresenta os resultados da simulação, supondo o mês de junho de 2015 como fonte de dados para a análise. Utilizando-se dos termos propostos na Figura 2, têm-se a datas início e meio como 01/06/2015 e 30/06/2015, respectivamente. Esse intervalo representa o histórico (ou passado) de falhas

adotados como reais.

No total, foram obtidas 504 ocorrências no mês, registrando-se a primeira falha às 0:48h do dia 01/06/2015 e a última às 12:36h do dia 30/06/2015.

Tabela 1 – Resumo dos dados históricos pseudo-reais

Semana	Tempo de Operação	Limite Inferior	Limite Superior	Primeiro OF	Último OF	NF
01	24 horas	01/06/2015	07/06/2015	01/06/15 0:48	07/06/15 23:17	167
02	24 horas	08/06/2015	14/06/2015	08/06/15 1:18	14/06/15 23:03	186
03	24 horas	15/06/2015	21/06/2015	15/06/15 0:00	21/06/15 18:26	62
04	24 horas	22/06/2015	30/06/2015	22/06/15 0:28	30/06/15 12:36	89
Total	24 horas	01/06/2015	30/06/2015	01/06/15 0:48	30/06/15 12:36	504

Fonte: Autoria própria (2017)

Esse procedimento foi repetido para uma quinta semana, utilizando-se do intervalo entre as datas 01/07/2015 e 07/07/2015 (*LIF* e *LFP*, respectivamente). Todos os demais parâmetros foram mantidos. A Tabela 2 resume os dados obtidos com a nova simulação. Esses dados foram adotados como atuais com a finalidade de efetuar a validação do modelo de previsão (apresentada na seção 4.5).

Tabela 2 – Resumo dos dados atuais pseudo-reais

Semana	Tempo de Operação	Limite Inferior	Limite Superior	Primeiro OF	Último OF	NF
05	24 horas	01/07/2015	07/07/2015	01/07/15 1:16	07/07/15 22:12	142
Total	24 horas	01/07/2015	07/07/2015	01/07/15 1:16	07/07/15 22:12	142

Fonte: Autoria própria (2017)

4.2 Distribuição de Probabilidade

Com base nos tempos entre falhas, calculados a partir dos dados históricos pseudo-reais, foram realizados ajustes de diferentes distribuições de probabilidade. A Tabela 3 exhibe os resultados dos testes de aderência realizados.

Dentre as nove funções avaliadas, cinco apresentaram-se como distribuições satisfatórias. Isso porque, estatisticamente, resultaram em um *p-value* superior ao

nível de significância de 0,05. Em uma análise mais ampla, envolvendo o erro quadrático e o *p-value*, tem-se, pela Tabela 3, que a distribuição de Weibull possui o melhor ajuste, combinando o menor erro (0,001567) e o maior *p-value* (superior a 0,15).


Tabela 3 – Resultados obtidos com as distribuições de probabilidade testadas

Distribuição Testada	Erro Quadrático	Teste Kolmogorov-Smirnov	Resultado
Weibull	0,001567	<i>p-value</i> > 0,15	Válida
Exponencial	0,003952	<i>p-value</i> = 0,0835	Válida
Erlang	0,003952	<i>p-value</i> = 0,0835	Válida
Gama	0,004264	<i>p-value</i> > 0,15	Válida
Lognormal	0,002782	<i>p-value</i> = 0,108	Válida
Beta	0,008690	<i>p-value</i> < 0,01	Inválida
Normal	0,155064	<i>p-value</i> < 0,01	Inválida
Triangular	0,275127	<i>p-value</i> < 0,01	Inválida
Uniforme	0,350027	<i>p-value</i> < 0,01	Inválida

Fonte: A autoria própria (2017)

Uma vez que o cálculo da função inversa de Weibull envolve métodos complexos, foi adotada uma das outras quatro distribuições válidas para a condução do presente trabalho. Esse processo foi realizado com base em três critérios principais. Em primeiro lugar, foi observada a função com melhor resultado no teste Kolmogorov-Smirnov (a saber, Gama); em seguida, ponderou-se a distribuição com menor erro quadrático (Lognormal); finalmente, foi avaliada aquela cuja inversa apresentasse formas mais práticas de implementação no pacote MS Excel™ (equivalendo-se Gama e Lognormal).

Figura 4 - Dados ajustados a função Gama



Fonte: A autoria própria (2017)

Com base na análise, foi adotada a função Gama para realização das simulações numéricas propostas neste estudo. A Figura 4 exibe o histograma e o ajuste dessa distribuição (com parâmetros $\alpha = 1,52$ e $\beta = 0,929$).

4.3 Simulação numérica

Com base na distribuição apresentada na seção 4.2, foi gerado um conjunto de 10.000 dados utilizando-se do método de Monte Carlo. Esses dados representam os tempos entre falhas simulados. A Tabela 4 expõe um resumo dos resultados obtidos com o processo.

Tabela 4 – Resumo dos dados obtidos com a simulação numérica

Número de Iterações	Menor TEF (Horas)	Maior TEF (Horas)	TMEF simulado (Horas)
10.000	0,005905	9,874412	1,420194

Fonte: Autoria própria (2017)

4.4 Testes e Análise Geral

A partir dos dados obtidos nas seções 4.1 e 4.3, foram realizados quatro testes principais, por meio dos quais estruturaram-se a validação do método e a determinação de seu grau de precisão, conforme proposto na seção 3.1 (Figura 1). O Quadro 1 apresenta um comparativo das análises elaboradas, considerando-se algumas variações do incremento utilizado e do dado-base (semente) para construção das séries.

O objetivo principal desta seção é confrontar a série de falhas atual pseudo-real, gerada a partir dos dados resumidos na Tabela 2 (seção 4.1), com as múltiplas séries previstas produzidas a partir da estrutura apresentada no Quadro 1. Cada teste foi agrupado segundo o tipo de incremento utilizado.

Quadro 1 – Análises utilizadas para validação do método


Teste	Série	Incremento Utilizado	Dado-Base	Observações
I	01	TMEF Histórico	Última Falha Prevista	Foram considerados todos os 503 TEFs históricos.
	02	TMEF Histórico	Última Falha Real	
II	01	TMEF Simulado	Última Falha Prevista	Foram considerados todos os 10.000 TEFs simulados.
	02	TMEF Simulado	Última Falha Real	
III	01	TEFs Simulados	Última Falha Prevista	Foram considerados os 100 primeiros TEFs simulados.
	02	TEFs Simulados	Última Falha Real	
IV	01	TMEFs Simulados Agrupados	Última Falha Prevista	Foram considerados os 500 primeiros TEFs simulados, agrupados em 100 conjuntos de cinco dados cada.
	02	TMEFs Simulados Agrupados	Última Falha Real	

Fonte: A autoria própria (2017)

As Figuras 5 a 8 exploram todas as séries propostas no Quadro 1, evidenciando, de forma gráfica, a aderência à previsão em cada um dos testes. Como pode ser verificado nas Figura 5 e 6, as previsões realizadas com base nos tempos médios entre falhas histórico e simulado apresentam comportamentos semelhantes (observados nas séries em pontilhado). Isso pode ser explicado em função do incremento fixo adotado nos Testes I e II para as séries não-ajustadas. Isto é, a cada momento de ocorrência de falha previsto, foram incrementados os mesmos valores para antecipação da falha subsequente.

No Teste I, foi utilizada a média dos TEFs históricos, obtidos pelo processo discutido na seção 4.1. No Teste II, por outro lado, foi utilizada a média dos 10.000 dados simulados com base na distribuição Gama, apresentada na seção 4.2. Em ambos os casos, foi empregado um valor único como incremento das séries.

Figura 5 – Previsão com TMEF histórico (Teste I)

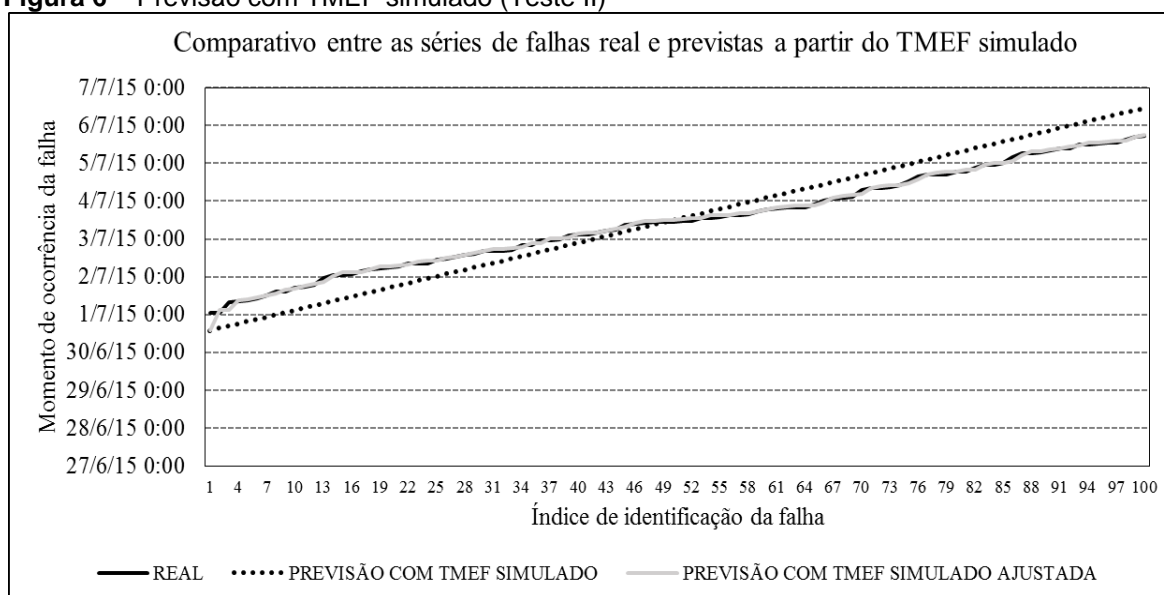


Fonte: Autoria própria (2017)

Além de apresentarem comportamentos semelhantes, essas séries também utilizaram TMEFs próximos (1,41 e 1,42, respectivamente). Esse fato evidencia a aderência da distribuição de probabilidade aos valores históricos, bem como a representatividade da simulação numérica com um elevado volume de dados.


Antagonicamente, nos Testes III e IV, foram aplicados incrementos variáveis para geração das séries de falhas previstas. Por esse motivo, as Figuras 7 e 8 não explicitam nenhuma série com comportamento linear. No entanto, diferem quanto à curvatura, por apresentarem processos de obtenção ligeiramente distintos.

Figura 6 – Previsão com TMEF simulado (Teste II)



Fonte: Autoria própria (2017)

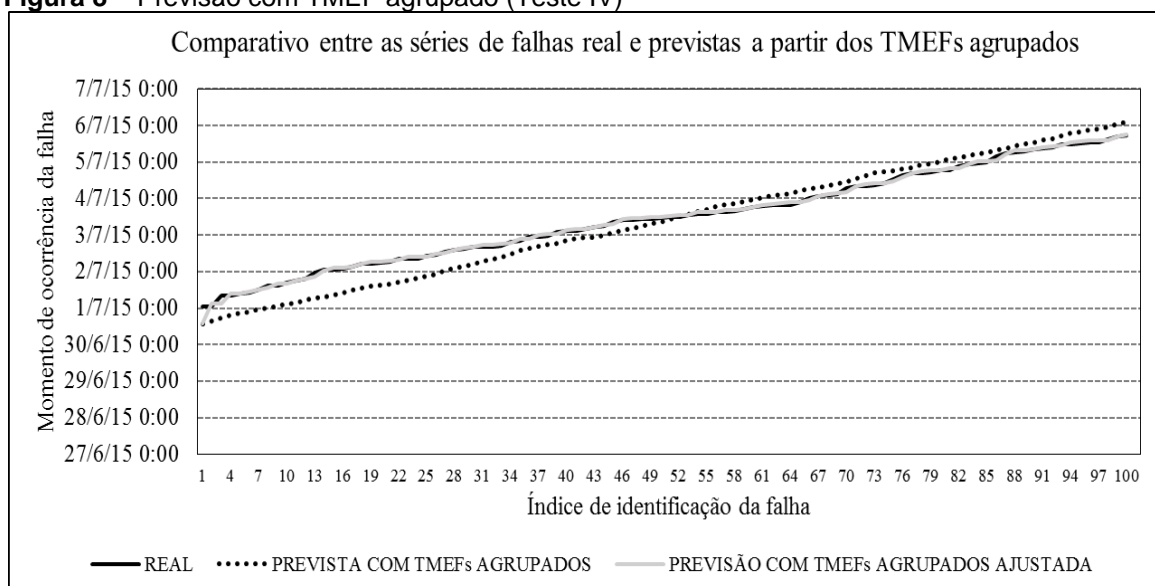
Figura 7 – Previsão com TEFs simulados (Teste III)



Fonte: Autoria própria (2017)

No Teste III, cada dado-base foi somado a um tempo entre falhas aleatoriamente gerado pela distribuição de probabilidade. Dessa forma, foi empregado um tempo diferente a cada iteração da série. No Teste IV, diferentemente, foram realizados agrupamentos formados por cinco valores aleatórios de tempos entre falhas (em um total de 500 números⁶). Como incremento, foi utilizada a média de cada conjunto de dados e gerada a série apresentada em pontilhado na Figura 8.

Figura 8 – Previsão com TMEF agrupado (Teste IV)



Fonte: Autoria própria (2017)

⁶ Esse conjunto de dados constituiu-se dos 500 primeiros números obtidos com a simulação numérica apresentada na seção 4.3.

Em todos os gráficos das Figuras 5 a 8, também é possível visualizar as séries denominadas “ajustadas”. Essas curvas utilizam como dado-base a última falha real, em vez de empregarem a última falha prevista, produzindo, com isso, séries atualizadas (ou, ajustadas). Em todos os casos mostrados, quando da aplicação desse recurso, a série prevista (em cinza) quase se sobrepõe à série real (em preto). Esse fato constitui-se de algo esperado, uma vez que o horizonte de previsão é reduzido a cada atualização, eliminando a propagação dos erros.

4.5 Validação e Precisão do Método

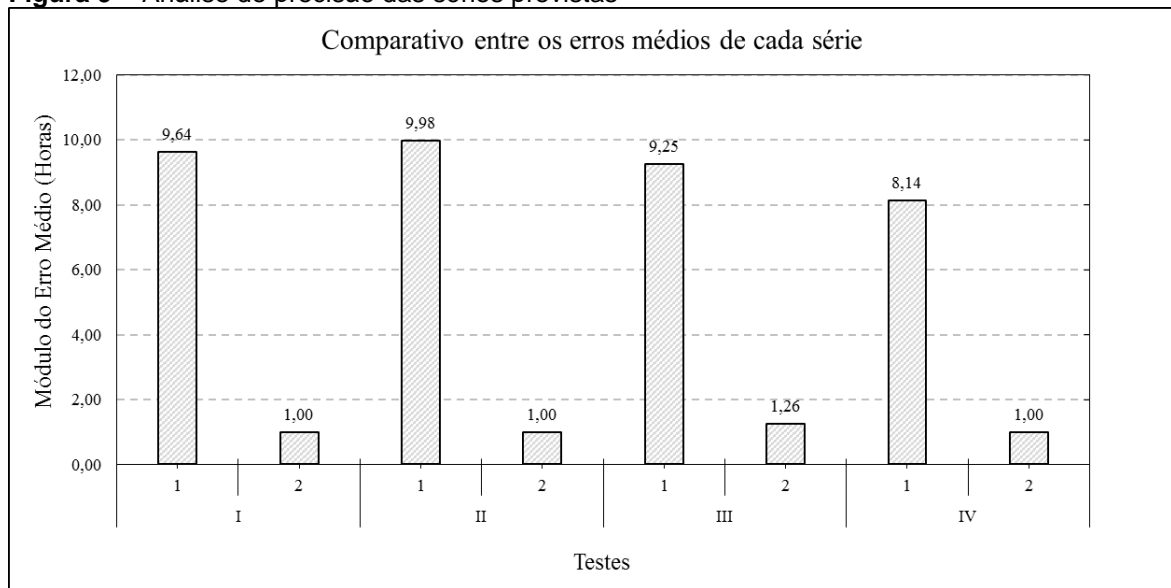
Uma vez discutidas as formas de obtenção das séries de falhas previstas, foram conduzidas análises para validação do método e determinação de sua precisão. Para isso, foi calculada a média dos erros de cada série, obtidos pelo módulo da diferença entre os *OFs* real e previsto.

A Figura 9 apresenta um comparativo entre esses erros. Como esperado, as previsões ajustadas forneceram desvios muito menores, fundamentando a aderência gráfica obtida nas Figuras 5 a 8. Numericamente, tem-se um aumento de precisão de, no mínimo, 86% em relação as séries não-ajustadas, como pode ser verificado em cada teste isoladamente. No Teste II, por exemplo, tem-se a maior redução, em um nível de, aproximadamente, 90% (de 9,98 horas para apenas 1,00 hora).

Comparando-se as séries de índice 1 da Figura 9, foi verificado que o Teste IV apresenta-se como o mais preciso, fornecendo um erro médio de 8,14 horas. De outro lado, o Teste II mostra-se como o de menor aderência, com desvio de quase 10 horas.

Matematicamente, esses resultados constituem-se de uma visão generalista das séries, fornecendo apenas um panorama de suas precisões. Por esse motivo, foi realizado um mapeamento detalhado das curvas, a fim de se avaliar as zonas ótimas de previsão de cada série. Essa análise é apresentada na Figura 10.


Figura 9 – Análise de precisão das séries previstas



Fonte: Autoria própria (2017)

Criteriosamente, foram identificadas as regiões onde as séries apresentaram erros menores que seis horas em todos os pontos – valor adotado como um horizonte de previsão satisfatório. Por esse processo, foi constatado um período de aquecimento com duração de 33 horas⁷ (ou 22 falhas ocorridas), no qual nenhuma das séries não-ajustadas demonstrou precisão satisfatória.

Figura 10 – Análise de complementariedade das séries previstas não-ajustadas



Fonte: Autoria própria (2017)

⁷ Para este cálculo, foram considerados os tempos entre falhas reais.

Por meio do mapeamento apresentado na Figura 10, foi possível constatar que, dentre as 100 primeiras falhas analisadas, 40 foram previstas satisfatoriamente com erro inferior a seis horas. Esse período de previsão ocorreu entre as falhas 23 e 62. A partir da falha 63, foram previstas as últimas 38 ocorrências com erro inferior a nove horas, em um limite de três horas a mais em relação ao primeiro grande intervalo.

De modo específico, após o período de aquecimento (*warm up*), a previsão com TEFs Simulados (Teste III) se apresentou como satisfatória na área entre as falhas 23 e 49, em um total de 27 ocorrências com um erro médio de 3,17 horas.


As previsões com TMEF simulado e TMEF histórico apresentaram regiões próximas de aderência. A série histórica (Teste I) se mostrou adequada entre as falhas 40 e 57, totalizando 18 pontos com um erro médio de 3,37 horas. A série simulada (Teste II), de modo semelhante, demonstrou-se conveniente entre os OFs 40 e 56, somando 17 falhas previstas com erro médio de 3,16 horas.

Novamente, a proximidade entre as regiões ótimas de previsão dessas séries pode ser explicada em função de incrementos aproximadamente idênticos. A partir deles, houve uma composição de retas com inclinação semelhante, tornando-as praticamente sobrepostas.

A previsão com TEFs agrupados apresentou sua área de melhor precisão entre as falhas 47 e 62, contemplando 16 ocorrências com erro médio de 3,57 horas. Por outro lado, entre os últimos OFs (63 a 100), essa série (Teste IV) teve seu erro médio aumentado para 6,10 horas. Apesar de um resultado individual insatisfatório, à nível comparativo, essa previsão se mostrou como a melhor aproximação, uma vez que, na mesma região, as demais curvas forneceram desvios médios superiores a 10 horas.

Por meio do Gráfico de Pareto exibido na Figura 11, foram confrontados os modelos de aderência sequencial. Isto é, foram selecionadas as curvas complementares para aderência contínua da região pós-aquecimento, capazes de formar o “melhor caminho” para previsão.

Figura 11 – Análise de aderência dos modelos sequenciais



Fonte: Autoria própria (2017)

A partir desse processo, foi identificado o caminho com as curvas provenientes dos Testes III e IV como o de maior continuidade. Ao todo, foi possível prever, com elas, 78% das falhas, excluindo-se apenas o período de aquecimento.

Com os resultados apresentados nas Figuras 10 e 11, pode-se dizer que as séries obtidas com os TMEFs histórico e simulado são dispensáveis para o caso analisado. Isso porque, além de cobrirem regiões curtas, não se enquadraram no melhor caminho de previsão. Alternativamente, podem ser consideradas séries auxiliares entre as quadragésima e quinquagésima dezenas de falhas.

De modo específico, a média histórica dos dados (Teste I) forneceu a terceira menor aderência à previsão. Associado a isso, sua região de melhor atuação foi suplantada por um conjunto de outras três séries simuladas. Adicionalmente, em comparação com a série construída com o TMEF simulado, apresentou erro médio superior, com diferença de 0,21 horas (ou 12,6 minutos).

Com base nessas evidências, tem-se que, para o caso estudado, o Método de Monte Carlo apresenta-se como o melhor modelo de previsão da série de falhas real. No entanto, esse resultado constitui-se de uma conclusão parcial, visto ser necessário, em uma análise mais profunda, avaliar os mecanismos de interação entre as séries previstas com base na simulação estocástica.

Em trabalhos futuros, pretende-se realizar essa avaliação, bem como efetuar a variação dos agrupamentos propostos no Teste IV a fim de compreender melhor o

fenômeno e o comportamento das diferentes curvas de previsão.

O processo de formação do período de aquecimento também caracteriza-se como um ponto crítico das previsões e passível de estudos futuros. No caso analisado, foi identificado um longo tempo para obtenção de pontos com erro satisfatório. Isso se deveu a utilização de um último momento de ocorrência de falhas muito distante.

Uma vez que a última falha histórica havia ocorrido às 12:36 do dia 30/06/2015 e a primeira atual às 1:16h do dia 01/07/2015, foi necessário obter uma enorme soma de incrementos para tornar as séries previstas adequadas à série real.

Outra justificativa plausível para esse fato encontra-se nas séries ajustadas. Em nenhuma delas, há período de aquecimento, justamente por serem atualizadas por dados-base reais. Nas Figuras 5 a 8, é possível visualizar que o maior desvio entre essas séries localiza-se no ponto onde o dado-base é o mesmo das séries não-ajustadas (*OFs* de índice 1).

Uma ação para contornar o problema pode ser iniciar as séries não-ajustadas a partir da primeira falha ocorrida no dia (neste caso, a primeira atual). Por outro lado, essa solução pode mudar completamente a dinâmica das regiões apresentadas no mapeamento da Figura 10, levando a desvios maiores.

De modo geral, porém, não há impedimento para a criação de novos testes incluindo essas alterações. Nesse caso, poderiam ser obtidas mais séries complementares para a análise. Por exemplo, ao incluir novos parâmetros para geração das séries, seriam ampliadas, fatorialmente, as possibilidades apresentadas no Quadro 1.

Em vista de todos esses resultados, pode-se dizer que os algoritmos aleatórios acabaram por fornecer horizontes maiores de análise em relação ao uso de dados históricos puros. Em outras palavras, tem-se que a Simulação de Monte Carlo apresentou-se como um método vantajoso para o tipo de estudo proposto.

Paralelamente, o uso do pacote comercial MS Excel™ não demonstrou qualquer impedimento para o desenvolvimento do sistema de previsão de falhas. Mas, ao contrário, acabou por criar novas possibilidades de análise, por meio de recursos dinâmicos para o tratamento dos dados. Com isso, as vantagens apresentadas na literatura sobre sua utilidade foram confirmadas.

5 CONSIDERAÇÕES FINAIS

Este trabalho apresentou um estudo interdisciplinar envolvendo a aplicação do Método de Monte Carlo como componente de um sistema de previsão de falhas voltado ao novo alinhamento estratégico da Engenharia de Manutenção nas empresas. O principal objetivo do trabalho foi propor, desenvolver e avaliar o grau de precisão do sistema, considerando seus diferentes modelos.

Especificamente, foram estabelecidos critérios para a geração de oito séries de falhas previstas. Por meio de um mapeamento da região ótima das séries não-ajustadas, foi verificado que as curvas simuladas produziram melhores aproximações em relação à curva real do que as curvas geradas com a média de dados históricos.

Em um total de 100 falhas, 78 foram previstas utilizando-se do sistema proposto. Dentre elas, 40 registraram-se em uma região com desvio máximo de seis horas. As demais, no entanto, localizaram-se ao final das curvas, apresentando erros inferiores a nove horas.

Considerando-se as séries ajustadas, o grau de precisão do modelo foi elevado para, no mínimo, 86% em relação as séries não-ajustadas. Esse resultado demonstrou o efeito da eliminação da propagação dos erros.

Dentre as contribuições do presente trabalho, pode-se destacar o mapeamento das regiões ótimas de previsão das séries. Isso porque, em geral, os trabalhos envolvendo a previsão de falhas resumem-se ao cálculo do ciclo de vida de componentes. Este artigo, no entanto, estendeu esse conceito para a determinação do momento de ocorrência das falhas.

Como principal resultado, foi verificada a eficácia da técnica utilizada, apesar de algumas limitações. Em termos específicos, embora nenhuma das séries previstas tenha se mostrado autossuficiente para antecipação da curva real, todas elas se mostraram complementares na região posterior ao período de aquecimento.

Com a análise, também foi constatada a necessidade de investigações mais profundas, a fim de identificar os mecanismos de interação entre as séries previstas. Assim, trabalhos futuros poderão contemplar novos mapeamentos das curvas de previsão, bem como análises de sensibilidade nos parâmetros *MIF* e *MAF* e *LIP* e *LFP*.

Com esse direcionamento, o presente artigo demonstra a possibilidade de estudos proeminentes no tema, uma vez que, ao todo, foram consideradas apenas quatro variações do incremento e duas variações do dado-base das séries. Alterando-se somente os tipos de agrupamento do Teste IV, poderão ser obtidas infinitas curvas. Além disso, novos parâmetros poderão ser incluídos para geração das séries, produzindo outra enorme quantidade de modelos.

Assim, uma vez que o presente trabalho revelou resultados satisfatórios sob as condições apresentadas, tem-se uma maior probabilidade de sucesso em análises futuras envolvendo um número maior de modelos.

De modo mais amplo, ao desenvolver um sistema de previsão de falhas, este estudo acabou por propor, também, novas discussões sobre ferramentas práticas para a Gestão da Manutenção. Como foi constatado ao longo do artigo, o pacote comercial MS Excel™ dispôs de todas as facilidades necessárias às simulações. Em trabalhos futuros, os recursos dessa plataforma poderão ser mais explorados, inclusive, na realização dos testes de aderência às distribuições de probabilidade.

Finalmente, na condição de estudo exploratório, o presente trabalho vislumbrou tornar-se a base para futuros desdobramentos do tema envolvendo a aplicabilidade dos sistemas de previsão junto às empresas. Em uma visão de longo prazo, o setor de Manutenção poderá planejar a mão-de-obra, os recursos materiais e outros ativos necessários às correções (como espaço para veículos, instalações especiais, etc.) utilizando-se de uma ferramenta prática para previsão. Em consequência, poderá haver redução de custos e maior rapidez no processo.

6 AGRADECIMENTOS

Os autores agradecem a CAPES, ao CNPq, à FAPEMIG e à UNIFEI pelo apoio para a realização deste trabalho.

REFERÊNCIAS

ABEPRO - ASSOCIAÇÃO BRASILEIRA DE ENGENHARIA DE PRODUÇÃO. Áreas e Sub-áreas de Engenharia de Produção, 2008. Disponível em: <<http://www.abepro.org.br/interna.asp?c=362>>. Acesso em: 22 mar. 2015.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462** - Confiabilidade e manutenibilidade. Rio de Janeiro, nov. 1994.

ABRAMAN - ASSOCIAÇÃO BRASILEIRA DE MANUTENÇÃO. Documento Nacional 2011: a situação da manutenção no Brasil, 2011. Disponível em: <<http://www.abraman.org.br/Arquivos/7/7.pdf>>. Acesso em: 10 abr. 2015.

BARBERÁ, L. *et al.* Advanced model for maintenance management in a continuous improvement cycle: Integration into the business strategy. **International Journal of Systems Assurance Engineering and Management**, v. 3, n. 1, p. 47-63, 2012. <https://doi.org/10.1007/s13198-012-0092-y>

CARVALHO, M. M. D.; PALADINI, E. P. **Gestão da qualidade: teoria e casos**. 2 ed. Rio de Janeiro: Campus, 2012.

CASTRO, D. E. *et al.* Processos de otimização de redes de oficinas de manutenção veicular utilizando técnicas RAM (Reliability, Availability and Maintainability) e o Método de Monte Carlo. *In*: Congresso e Exposição Internacionais SAE Brasil de Tecnologia da Mobilidade, 20., 2011, São Paulo. **Anais...** São Paulo, SAE Brasil, 2011. p. 1-10.

CHWIF, L.; MEDINA, A. C. **Modelagem e simulação de eventos discretos: teoria e aplicações**. 3 ed. São Paulo: Edição do Autor, 2010.

FARIA, P. H. L.; RIBEIRO, J. L. D.; VIANA, J. L. D. Modelo de simulação para captura e aproveitamento de ociosidade para manutenção em sistemas de expedição de minérios. **Produção Online**, v. 16, n. 4, p. 1142-1171, 2016. <http://dx.doi.org/10.14488/1676-1901.v16i4.1990>

FOGLIATTO, Flávio Sanson; RIBEIRO, José Luis Duarte. **Confiabilidade e manutenção industrial**. São Paulo: Campus Elsevier, 2009.

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.

GURGUR, C. Z.; JONES, M. Capacity factor prediction and planning in the wind power generation industry. **Renewable Energy**, v. 35, n. 12, p. 2761-2766, 2010. <https://doi.org/10.1016/j.renene.2010.04.027>

HAIGH, T.; PRIESTLEY, M.; ROPE, C. Los Alamos Bets on ENIAC: Nuclear Monte Carlo Simulations, 1947–1948. **IEEE Annals of the History of Computing**, p. 42-63, 2014. <https://doi.org/10.1109/MAHC.2014.40>

HALL, Nicholas G. Project Management: recent developments and research opportunities. **Journal of Systems Science and Systems Engineering**, v. 21, p. 129-143, 2012. <https://doi.org/10.1007/s11518-012-5190-5>

HAMMERSLEY, J. M.; HANDSCOMB, D. C. **Monte Carlo Methods**. Londres: Methuen & Co Ltd, 1964. <http://dx.doi.org/10.1007/978-94-009-5819-7>

HORNGREEN, C. T.; DATAR, S. M.; RAJAN, M. **Costs Accounting: a managerial emphasis**. Upper Saddle River: Pearson Prentice Hall, 2012.

HU, J. *et al.* Life prediction of steam generator tubing due to stress corrosion crack using Monte Carlo Simulation. **Nuclear Engineering and Design**, v. 241, n. 10, p. 4289-4298, 2011. <https://doi.org/10.1016/j.nucengdes.2011.08.016>

JIANG, X. *et al.* Evaluation of path-history-based fluorescence Monte Carlo method for photon migration in heterogeneous media. **Optics Express**, v. 22, n. 26, p. 1162-1168, 2014. <https://doi.org/10.1364/OE.22.031948>

KARDEC, A.; NASCIF, J. **Manutenção: função estratégica**. 4 ed. Rio de Janeiro: Qualitymark, 2013.

LARUCCIA, M. M. *et al.* Gerenciamento de Projetos em Pesquisa e Desenvolvimento. **Revista de Gestão e Projetos**, São Paulo, v. 3, n. 3, p. 109-135, 2012. <https://doi.org/10.5585/gep.v3i3.82>

LISITSIN, V. A.; PORWAL, A.; MCCUAIG, T. C. Probabilistic Fuzzy Logic Modeling: Quantifying Uncertainty of Mineral Prospectivity Models Using Monte Carlo Simulations. **Mathematical Geosciences**, v. 46, n. 6, p. 747-769, 2014. <https://doi.org/10.1007/s11004-014-9534-1>

MARTINS, Roberto Antonio; MELLO, Carlos Henrique Pereira; TURRIONI, João Batista. **Guia para elaboração de monografia e TCC em Engenharia de Produção**. São Paulo: Atlas, 2014.

METROPOLIS, N. The Beginning of the Monte Carlo Method. **Los Alamos Science**, p. 125-130, 1987. Disponível em: <<http://library.lanl.gov/cgi-bin/getfile?00326866.pdf>>. Acesso em: 24 mar. 2015.

METROPOLIS, N.; ULAM, S. The Monte Carlo Method. **Journal of the American Statistical Association**, v. 44, n. 247, p. 335-341, 1949. <https://doi.org/10.1080/01621459.1949.10483310>

MONTEIRO, C. A.; SANTOS, L. S. D.; WERNER, L. Simulação de Monte Carlo em decisão de investimento para implantação de projeto hospitalar. *In*: Encontro Nacional de Engenharia de Produção, 32., 2012, Bento Gonçalves. **Anais Eletrônicos...** Bento Gonçalves: ABEPRO, 2012. p. 1-12.

NIGRO, E. *et al.* Probabilistic approach for failure assessment of steel structures in fire by means of plastic limit analysis. **Fire Safety Journal**, v. 68, p. 16-29, 2014. <https://doi.org/10.1016/j.firesaf.2014.05.020>

ORCESI, A. D.; FRANGOPOL, D. M. Optimization of bridge maintenance strategies based on structural health monitoring information. **Structural Safety**, v. 33, n. 1, p. 26-41, 2011. <https://doi.org/10.1016/j.strusafe.2010.05.002>

PAI, A.; RANE, S. Development and implementation of maintenance management module of enterprise resource planning in maintenance of power plant. **International Journal of System Assurance Engineering and Management**, v. 5, n. 4, p. 534-543, 2013. <https://doi.org/10.1007/s13198-013-0203-4>

PAULI, S.; KOHLER, M.; ARBENZ, P. A fault tolerant implementation of multi-level Monte Carlo methods. **Advances in Parallel Computing**, v. 25, p. 471-480, 2014. <https://doi.org/10.3929/ethz-a-009922757>

PEIRAVI, A. Estimation of Expected Lifetime and Reliability During Burn in and Field Operation Using Markov Chain Monte Carlo Simulations. **Applied Sciences Journal**, v. 4, n. 6, p. 748-754, 2008.

PERES, C. R. C.; LIMA, G. B. A. Proposta de modelo para controle de custos de manutenção com enfoque na aplicação de indicadores balanceados. **Gestão & Produção**, São Carlos, v. 15, n. 1, p. 149-158, 2008. <http://dx.doi.org/10.1590/S0104-530X2008000100013>

PRIESOL, J. *et al.* Quantitative analysis of cathodoluminescence phenomena in InGaN/GaN QW by Monte Carlo method. **Applied Surface Science**, n. 269, p. 155-160, 2013. <https://doi.org/10.1016/j.apsusc.2012.09.158>

REIS, A. C. B.; COSTA, A. P. C. S.; ALMEIDA, A. T. D. Diagnóstico da gestão da manutenção em indústrias de médio e grande porte da região metropolitana de Recife. **Produção**, v. 23, n. 2, p. 226-240, 2013. <http://dx.doi.org/10.1590/S0103-65132012005000079>

SANTOS, N. A.; SELMITTO, M. A. Estratégia de manutenção e aumento da disponibilidade de um posto de compressão de gases na indústria petrolífera. **Produção Online**, v.16, n. 1, p. 77-103, 2016. <http://dx.doi.org/10.14488/1676-1901.v16i1.1905>

SANTOS, V. N. *et al.* Electrochemical and Monte Carlo studies of self-assembled trans-[Fe(cyclam)(NCS)₂]⁺ complex ion on gold surface as electrochemical sensor for nitric oxide. **Electrochimica Acta**, n. 91, p. 1-10, 2013. <https://doi.org/10.1016/j.electacta.2012.11.132>

SARAIVA JUNIOR, A. F.; RODRIGUES, M. V.; COSTA, R. P. D. Simulação de Monte Carlo Aplicada à Decisão de Mix de Produtos. **Produto & Produção**, v. 11, n. 2, p. 26-54, 2010.

SEILA, A. F. Spreadsheet simulation. In: Winter Simulation Conference, 2004, Washington. **Proceedings of the 2004 Winter Simulation Conference**. Washington: IEEE Press, 2004. p. 41-48. <http://dx.doi.org/10.1109/WSC.2004.1371300>

STEVENSON, W. J. **Operations management**. 11. ed. New York: McGraw-Hill-Irwin, 2011.

SYLVESTER, G. A. **Monte Carlo**: aplicacion en las empresas y en las fuerzas armadas. 1 ed. Asunción: Universidade Nacional de Asunción, 1970.

TEODORO FILHO *et al.* Modelo para determinar as quantidades em estoque de peças sobressalentes em uma planta de geração de energia. **Produção Online**, v.17, n. 3, p. 828-856, 2017. <http://dx.doi.org/10.14488/1676-1901.v17i3.2549>

TINGA, T. Application of physical failure models to enable usage and load based maintenance. **Reliability Engineering and System Safety**, v. 95, n. 10, p. 1061-1075, 2010. <https://doi.org/10.1016/j.ress.2010.04.015>

VAN HORENBEEK, A.; PINTELON, L.; MUCHIRI, P. Maintenance optimization models and criteria. **International Journal of Systems Assurance Engineering and Management**, v. 1, n. 3, p. 189-200, 2010. <https://doi.org/10.1007/s13198-011-0045-x>

WANG, W. *et al.* Monte Carlo simulation of primary recrystallization and annealing twinning. **Acta Materialia**, n. 81, p. 457-468, 2014. <https://doi.org/10.1016/j.actamat.2014.08.032>

ZHOU, Y. *et al.* Latent degradation indicators estimation and prediction: A Monte Carlo approach. **Mechanical Systems and Signal Processing**, v. 25, n. 1, p. 222-236, 2011. <https://doi.org/10.1016/j.ymsp.2010.08.012>



Artigo recebido em: 06/12/2017 e aceito para publicação em: 12/02/2019
DOI: <http://dx.doi.org/10.14488/1676-1901.v19i1.3091>