

Combining Maximum Likelihood Estimation and LSTM Neural Network to Forecast Reliability Distributions: A Study Based on Real Data from the Sugar-Energy Sector

Guilherme Hering Scavariello, Ailson Renan Santos Picanço e Cristiano Torezzan

Abstract—The recent advances in reliability engineering and assets management allow industries to use advanced mathematical and statistical techniques to improve their maintenance strategies. Conversely, many of these methods requires the previous knowledge of the failure history for the assets, which are not always available. This study shows that is possible to support maintenance management decisions providing the distributions for assets with known and unknown failures history. The approach combines maximum likelihood estimation with a LSTM neural network to find and predict optimal reliability and failure distributions for data actual assets data and failures history. It is shown as an efficient and probably useful approach for practical business situations in the results section.

Index Terms—reliability, RCM, engineering, maintenance, MLE, maximum likelihood estimation, neural network, keras, tensorflow, LSTM, asset, management, industry.

I. INTRODUÇÃO

O aumento da complexidade dos sistemas produtivos requer o aprimoramento de técnicas de gestão com a busca contínua de informações para fundamentar as decisões empresariais. Os sistemas de medição de desempenho (SMDs) possuem papel central no gerenciamento das operações, principalmente num contexto cada vez mais conectado de informação em tempo real, cujos impactos potencialmente se estendem para toda a cadeia de produção [1].

No gerenciamento de manutenção industrial, a coleta e apuração dos dados é um ponto crítico para a medição de desempenho. A falta de informação e de dados confiáveis é um desafio importante, que vem sendo estudado ao longo do tempo [2] e considerado uma das principais causas para o insucesso na implementação em sistemas de manutenção industrial [3], [4].

O monitoramento das falhas de ativos físicos é um dos principais objetivos da área de manutenção [5], com destaque para a estimativa de confiabilidade de equipamentos, isto é, a probabilidade deste desempenhar as suas funções conforme o especificado em seu ciclo de vida [6]. Todavia, há situações do cotidiano organizacional que exigem ações concretas de manutenção sem que se tenha um histórico adequado de falhas.

Nestes casos é desejável que se tenha algum método para estimar a curva de confiabilidade.

Existem ainda especificidades ambientais, estruturais ou da própria manufatura que podem tornar a estimação da probabilidade de falha uma tarefa não trivial e os dados reais podem se desviar das curvas teóricas esperadas. Na indústria de energia eólica, por exemplo, a temperatura média e a umidade interferem na falha dos componentes fundamentais das turbinas [7] e [6], bem como na indústria marítima a composição físico-química das águas navegantes influenciam nas avarias dos cascos dos navios [8].

Estudos mostram que a estimativa por máxima verossimilhança, ou *maximum likelihood estimation* (MLE), trata-se de uma combinação de técnicas popular no campo estatístico pelo seu uso para estimar curvas e parâmetros que representam o comportamento de modelos probabilísticos [9] [10], e considerada também como uma abordagem eficiente e prática para estimar parâmetros de distribuições de vida útil [11].

Modelos de predição (determinísticos e probabilísticos) são extensivamente analisados e discutidos em um artigo sobre tendências futuras para gestão da manutenção de ativos [12]. Também foi alvo de estudo, já no horizonte de aprendizado de máquina, estratégias combinando técnicas de manutenção preditiva com algoritmos de classificação aplicados por redes neurais: Em [13], é apresentada uma estratégia combinando técnicas de manutenção preditiva com algoritmos de classificação aplicados por aprendizado de máquina. Em outro estudo, os autores confirmam através dos resultados que foi possível utilizar redes neurais para prever falhas e estabelecer estratégias de manutenção para otimizar a disponibilidade de motores, utilizando dados de sensores de vibração [14].

Os estudos supracitados compartilham da necessidade de registros históricos para estimação das curvas de confiabilidade e predição de falhas para suportar direcionamentos e decisões estratégicas. Nesse contexto, este trabalho investiga o uso de inteligência artificial para estimar distribuições ótimas de confiabilidade e taxas de falhas para ativos físicos de um determinado conjunto sem a necessidade de um histórico de falhas para todos os equipamentos do conjunto.

A partir de uma base de dados reais, coletados do sistema de gestão integrado de um grupo privado de indústrias do setor sucroenergético, propõe-se o uso de um modelo de rede neural recorrente com arquitetura LSTM (*Long Short-Term Memory*) para estimar a curva, e seus respectivos parâmetros,

Guilherme H. Scavariello, Faculdade de Ciências Aplicadas da UNICAMP - Universidade de Campinas. São Paulo, Brasil.

Ailson R. S. Picanço, ITA - UNIFESP. São Paulo, Brasil.

Cristiano Torezzan, Faculdade de Ciências Aplicadas da UNICAMP - Universidade de Campinas. São Paulo, Brasil.

que melhor se ajusta ao comportamento dos equipamentos sem histórico de falhas. O objetivo é alcançado pelo aprendizado a partir de estimativas de curvas de confiabilidade em equipamentos similares, realizadas utilizando a máxima verossimilhança, ou *maximum likelihood estimation* (MLE).

As demais seções do artigo estão organizadas da seguinte forma: Seção II, onde é definida uma proposta de modelo para estimação de curvas de confiabilidade; Seção III, onde é relatada a implementação e testes do modelo com base em dados reais do setor sucroenergético; Seção IV, referente aos resultados e discussões e Seção V, conclusão.

II. UM MODELO PARA ESTIMAÇÃO DE CURVAS DE CONFIABILIDADE

A. Manutenção na Indústria 4.0

A indústria vive sua quarta revolução e direciona seus investimentos em tecnologias capazes de monitorar condições e especificidades em tempo real para evitar falhas e melhorar o tempo de operação dos ativos. A tecnologia tem se desenvolvido significativamente para minimizar taxa de falhas, todavia, o desgaste faz parte da natureza dos equipamentos e de seus componentes [15].

Nesse contexto, o uso adequado de técnicas modernas de coleta, análise e processamento de dados pode propiciar aos decisores informações mais precisas, colaborando para o desenvolvimento de estratégias otimizadas de manutenção.

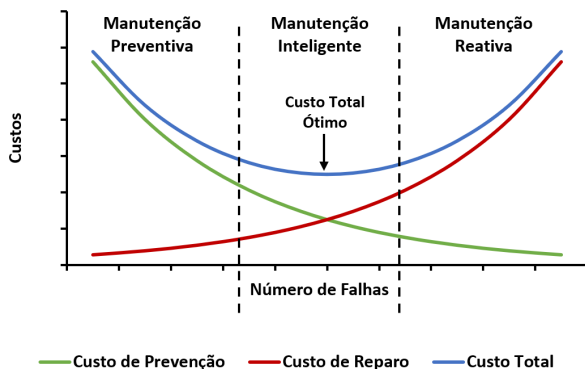


Fig. 1. Custos associados com estratégias de manutenção tradicionais [16].

A Figura 1 ilustra, de forma conceitual, uma visão de custos dividindo as principais estratégias de manutenção utilizadas na prática em três seções: Manutenção Preventiva, Manutenção Reativa e Manutenção Inteligente [16]. Nota-se que uma estratégia majoritariamente preventiva apresenta baixos custos de reparo pois evita a ocorrência de falhas, porém incorre em altos dispêndios em prevenção. Ao mesmo tempo, uma estratégia com foco em atuação reativa ostenta baixos custos de prevenção, entretanto expõe um grande dispêndio para realização de reparos incorridos.

Observa-se, ainda na Figura 1, que estratégias polarizadas (predominantemente preventivas ou reativas) minimizam os custos de reparo ou os custos de prevenção, mas não os custos totais incorridos. Nesse sentido, nota-se pela seção Manutenção Inteligente que encontrar a estratégia para obter

o custo total ótimo representa o grande desafio das indústrias, pois depende não somente do modelo adequado para suas particularidades (como as características dos equipamentos e funções do processo produtivo), mas também do conhecimento dos dados sobre os ativos físicos, que é o tema de interesse deste artigo.

A Figura 2 mostra a taxa de falha para um ativo hipotético, ilustrando como é possível estabelecer uma estratégia de manutenção e seu intervalo de frequência. Isso é feito aplicando abordagens de engenharia centrada em confiabilidade e conhecendo a distribuição e os parâmetros que refletem a curva de confiabilidade do equipamento.

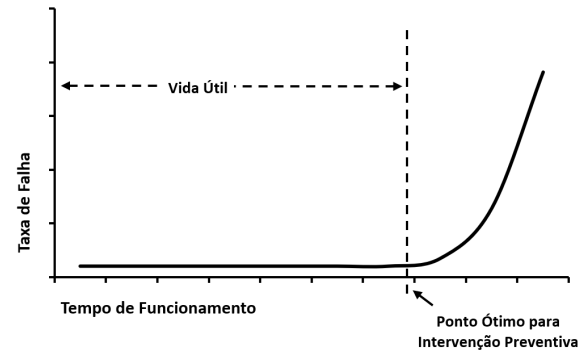


Fig. 2. Curva de taxa de falha para um equipamento ao longo de seu tempo de operação [17].

Apesar da expressiva evolução dos modelos de otimização e das estratégias avançadas para apoio a decisões de manutenção, a estimativa das curvas de confiabilidade ainda depende da existência e da qualidade de dados históricos, que precisam ser devidamente tratados para não incorporar imprecisões indesejáveis nos modelos [4]. Com o objetivo de contribuir para a solução deste complexo desafio propõe-se, a seguir, um modelo para estimar os parâmetros de curvas de confiabilidade para equipamentos com ou sem um histórico de falhas.

B. Uma Abordagem para Estimar Curvas de Confiabilidade

A estimativa por máxima verossimilhança, ou *maximum likelihood estimation* (MLE), trata-se de uma combinação de técnicas extremamente popular no campo estatístico pelo seu uso para estimar curvas e parâmetros que representam o comportamento de modelos probabilísticos [9]. Através dela é possível escolher o melhor conjunto estimado a fim de minimizar a função de log-verossimilhança negativa. Os conjuntos de distribuições e parâmetros são medidos através do critério de informação de Akaike, ou *Akaike information criterion* (AIC), e pelo Critério Bayesiano de Schwarz, ou *Bayesian information criterion* (BIC) [10], a fim de determinar a melhor distribuição e conjunto de parâmetros que representem os registros de entrada. No caso desse estudo, os registros de falha para cada ativo.

A utilização da máxima verossimilhança, no entanto, depende de um conjunto de dados de entrada, que no caso desse estudo trata-se do histórico de falhas. No entanto, na prática, nem todos os equipamentos possuem registros

do histórico de falhas. Dentre as possíveis abordagens para estimar curvas de distribuição, é proposto neste trabalho o uso de redes recorrentes do tipo LSTM (*Long Short-Term Memory*) em função de seus bons resultados na modelagem de séries temporais [18] e de sua capacidade de aprender conexões de longo e curto prazos de um fenômeno.

C. Contribuições Acadêmicas Recentes em Otimização da Manutenção

Além dos trabalhos anteriormente citados, recentes estudos apresentam outras valiosas contribuições sobre o tema pesquisado, com a utilização de modelos matemáticos e computacionais para otimização da manutenção de processos produtivos (Tabela I).

TABELA I
TRABALHOS RECENTES EM OTIMIZAÇÃO DA
MANUTENÇÃO.

| Autores | Contribuição |
|--------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Schenkelberg et al (2020) [19] | Defende um modelo baseado em DBN (<i>Dynamic Bayesian Networks</i>) para prever o impacto econômico das intervenções de manutenção como perfil de escolha estratégica naquelas mais eficientes. |
| Kang & Soares (2020) [20] | Constrói um modelo de manutenção por oportunidade que considera a incerteza proveniente da acuracidade da intervenção e das condições ambientais. |
| Amrina et al (2020) [21] | Desenvolve um modelo multicritério baseado em lógica <i>fuzzy</i> para análise performática da função manutenção à partir de indicadores chave (KPIs) no contexto industrial. |
| Syamsundar et al (2021) [22] | Apresenta modelos de manutenção preventiva e corretiva para avaliação da efetividade de políticas de manutenção, com a variação de parâmetros e condições nos modelos de otimização de custos e disponibilidade. |
| Nili et al (2021) [23] | Os autores desenvolvem uma interface integrada de simulação de eventos discretos com algoritmo genético para um modelo de otimização de manutenção em condição de elevadas restrições. Propõe sequenciamento de atividades, levantamento de criticidade e identificação de restrições não aparentes em sistemas complexos. |
| Mena et al (2021) [24] | Apresenta um modelo de otimização de operações de manutenção preventiva, baseada em oportunidade utilizando programação inteira mista. Trás uma abordagem que considera sazonalidade de processos produtivos, riscos e condições ambientais como fatores de incerteza. |
| Wang & Miao (2021) [25] | Formula um modelo de otimização da manutenção preventiva com o balanceamento de um sistema semi-markoviano, com diferentes parâmetros e gradações de falhas. |

Os trabalhos apresentados na Tabela I são contemporâneos e retratam abordagens distintas para os desafios da otimização da manutenção industrial seja ela preventiva, corretiva ou preditiva. Mas todos pressupõem a existência de um conjunto de dados robustos como entrada dos modelos. Em [21] e [23] se destaca a necessidade do tratamento e avaliação dos dados para garantir a efetividade das formulações desenvolvidas. Todavia, o que fazer quando o conjunto de informações é escasso ou inexistente? Nisto, debruça-se a principal contribuição do trabalho ao propor uma abordagem de aprendizado de redes neurais, com dados provenientes de equipamentos similares, com histórico.

D. Rede Neural LSTM com Múltiplos Critérios de Saída

Redes recorrentes podem, em princípio, usar suas conexões de retorno para armazenar representações de eventos de entrada recentes na forma de ativações (“memória de curto prazo”, contrariamente à “memória de longo prazo” usualmente incorporada por pesos que mudam lentamente). Tal

fato é potencialmente significativo para diversas aplicações, incluindo a modelagem de series temporais, o processamento de falas, controle não Markoviano e até composições musicais [26].

Após a divisão do conjunto de dados nos vetores X (entradas) e Y (saídas), a informação deve ser categorizada para os dados do tipo texto. Ao preparar conjuntos de dados para aplicação de aprendizagem de máquina, os dados de texto devem ser tratados. Uma das técnicas, a ser aplicada quando tais dados de texto representam categorias (que retrata o modelo desse artigo), se constitui na transformação das categorias em valores numéricos ou binários.

Como os dados categóricos na aplicação desse artigo não apresentam uma relação de escala, o método mais apropriado é o de transformar as categorias usando a técnica de Codificação Distribuída, ou *One-hot encoding*. Esse tipo de vetorização considera um vocabulário de tamanho N e atribui um índice i para cada um dos *tokens* do vocabulário. Assim, cada *token* é representado por um vetor de tamanho N, em que todas as posições desse vetor são preenchidas com zeros, exceto a posição i (correspondente a posição do *token* em questão) que será preenchida com valor 1. Logo, cada *token* será representado por um vetor de tamanho fixo (tamanho do vocabulário) [27]. A técnica envolve em representar, por exemplo, categorias através de vetores binários contendo um valor para cada possível categoria. Sendo assim, para cada variável do tipo texto que representa uma categoria, temos um número “1” para a categoria representada, e números “0” para todas as outras possíveis categorias.

A diferenciação de uma rede neural como profunda ou superficial não possui limites claramente e universalmente estabelecidos pelos especialistas da área [28], mas a maior parte dos pesquisadores concorda que redes neurais profundas envolvem mais de duas camadas ocultas em sua arquitetura. [29] Como não há convenção clara sobre o tema, a arquitetura de rede neural proposta no artigo é caracterizada como rede neural LSTM, sem incluir em sua nomenclatura a caracterização como rasa ou profunda.

A abordagem proposta é representada sucintamente, de maneira ilustrativa, na Figura 3. A classificação estruturada de um conjunto de ativos, as definições de estratégias adotadas individualmente e seus respectivos históricos de ordens de manutenção são coletados e higienizados (removendo duplicidades, registros indesejados, inconsistentes ou incorretos utilizando técnicas computacionais e análises qualitativas). Os dados resultantes são submetidos a estimativas de máxima verossimilhança e rede neural LSTM, dependendo da presença ou não de histórico de falhas em cada ativo, obtendo-se um novo conjunto de dados, para cada item, das distribuições de confiabilidade e seus parâmetros ótimos, principal objetivo do artigo. O processo descrito acima é detalhado na seção III.

III. METODOLOGIA DE IMPLEMENTAÇÃO DO MODELO E TESTES COM BASE EM DADOS REAIS DO SETOR SUCROENERGÉTICO

O modelo proposto foi validado com base em dados reais, coletados do sistema de gestão integrado de um grupo privado




Fig. 3. Fluxograma representativo da abordagem proposta.

de indústrias do setor sucroenergético. Entretanto, as tabelas, gráficos e bases de dados exibidas foram anonimizados com a utilização de nomenclaturas ilustrativas para atender à política de privacidade de conteúdo intelectual da organização privada.

Na sequência desta seção apresenta-se os principais passos realizados para a obtenção das curvas, iniciando pela tarefa de coleta e tratamento dos dados. O intuito desta descrição detalhada é não apenas possibilitar a reprodução dos resultados, mas também permitir que todas as fases importantes do trabalho sejam compreendidas para que o resultado possa ser utilizado e replicado para abordagens aderentes.

A. Coleta de Dados

Duas bases de dados foram coletadas do Sistema de gestão integrado do grupo de indústrias privado, objeto desse estudo:

- 1) Lista de Ativos industriais e respectivos detalhes (para o presente estudo, foi coletada uma lista de 462 equipamentos, contendo suas identificações e características de aplicação);
- 2) Lista de ordens de manutenção executadas nos Ativos da lista supracitada (7896 ordens de manutenção para o presente estudo).

B. Preparação dos Dados

A coletânea de dados deve ser preparada para as próximas etapas. Essa preparação foi realizada seguindo os procedimentos citados abaixo:

1) *Seleção de Ativos Industriais*: A coletânea de dados foi classificada por localização geográfica da planta, marca, modelo, tipo de equipamento, ID (identificação do local de instalação do ativo), idade e estratégia de manutenção adotada atualmente.

Um exemplo da classificação estruturada dos ativos é dado abaixo, na Tabela II.

TABELA II
AMOSTRA DA CLASSIFICAÇÃO DE ATIVOS.

| Planta | Modelo | Marca | Tipo | ID | Idade (anos) | Estratégia |
|--------|--------|---------|---------|-----------|--------------|------------|
| A | A | Maker A | BOMBA | A-I-PP01 | 25 | Preventiva |
| A | A | Maker A | BOMBA | A-I-PP02 | 12 | Preventiva |
| B | B | Maker B | BOMBA | B-I-PP01 | 10 | Preventiva |
| B | B | Maker B | ESTEIRA | B-I-CON02 | 10 | Corretiva |
| B | C | Maker B | ESTEIRA | B-I-CON03 | 8 | Corretiva |
| B | C | Maker B | ESTEIRA | B-I-CON04 | 8 | Corretiva |
| C | D | Maker C | ESTEIRA | C-I-CON01 | 10 | Preventiva |
| C | D | Maker C | ESTEIRA | C-I-CON02 | 10 | Preventiva |
| C | D | Maker C | ESTEIRA | C-I-CON03 | 10 | Preventiva |

2) *Histórico de Manutenção*: Como um dos objetivos do presente estudo é o de encontrar a melhor sugestão de distribuição para a confiabilidade dos ativos, foi necessário selecionar somente as ordens de manutenção que tratam-se de intervenções corretivas e necessitam de parada do equipamento para execução (sejam estas planejadas ou não), ou seja, que ocasionaram interrupção nas funções do equipamento. Caso contrário, as taxas de falha seriam não confiáveis. Daqui em diante, essas ordens de manutenção serão chamadas de falhas.

TABELA III

AMOSTRA DO HISTÓRICO DE ORDENS DE MANUTENÇÃO ANTES DA HIGIENIZAÇÃO DOS DADOS. A COLUNA 'ID' REFERE-SE A UM CÓDIGO DE IDENTIFICAÇÃO DO EQUIPAMENTO ONDE A MANUTENÇÃO FOI EXECUTADA.

| Ordem | Data | ID | Custos (R\$) | Tipo |
|---------|------------|-----------|--------------|-----------|
| 1000008 | 02/06/2020 | A-I-PP01 | 114,02 | Imediata |
| 1000029 | 21/05/2020 | A-I-PP02 | 540,12 | Planejada |
| 1000030 | 20/05/2020 | B-I-PP01 | 345,35 | Imediata |
| 1000031 | 20/05/2020 | B-I-CON02 | 737,25 | Planejada |
| 1000033 | 19/05/2020 | B-I-CON03 | 2.079,12 | Planejada |
| 1000035 | 15/05/2020 | B-I-CON04 | 70,00 | Planejada |
| 1000039 | 13/05/2020 | C-I-CON01 | 2.366,99 | Imediata |
| 1000040 | 12/05/2020 | C-I-CON02 | 633,19 | Imediata |
| 1000042 | 11/05/2020 | C-I-CON03 | 471,9 | Planejada |

Outro objetivo da presente abordagem é o funcionamento em diferentes formatos e tipos de modelos de dados, portanto um procedimento de higienização de dados foi elaborado e executado. As ordens de manutenção que seguem os seguintes critérios foram filtradas e removidas do histórico de manutenção, amostrado na Tabela III, pelo seguinte processo de higienização:

- Ordens de manutenção sem custo realizado associado.
- 1.223 ordens de manutenção identificadas como ordens para realização de análise de vibração.
- 1.161 ordens de manutenção identificadas como ordens para realização de *checklist* ou inspeções visuais.
- Toda ordem manutenção corretiva planejada com um custo associado muito baixo.
- Ordens de manutenção que foram registradas no mesmo dia. É assumido que tais ordens referem-se provavelmente à mesma ocorrência de falha. Especialmente considerando que o intervalo mínimo de tempo considerado no presente estudo se dá em dias.
- Através de aplicações de mineração de texto, ou *text mining*, combinado com uma avaliação qualitativa dos resultados, foi possível identificar, removendo da relação de falhas as seguintes ordens de manutenção:
 - 2.388 ordens equivocadamente aplicadas em ativos diferentes do ativo preenchido no campo apropriado, dentro do documento do sistema.
 - Ordens de manutenção relacionadas a atividades que não incorrem em falha do equipamento ou execução de um reparo no mesmo.

As etapas e os critérios utilizados no processo de higienização supracitado, assim como todos os parâmetros utilizados no presente artigo, podem ser ajustados ou personalizados para

funcionar com diferentes tipos de dados e objetivos de negócio. Por isso, é essencial conhecer e considerar as características individuais do segmento ou indústria na qual estão sendo aplicados os métodos desse estudo.

TABELA IV
AMOSTRA DE HISTÓRICO DE ORDENS DE MANUTENÇÃO
APÓS HIGIENIZAÇÃO DE DADOS.

| Ordem | Data | ID | Custos | Tipo |
|---------|------------|-----------|----------|-----------|
| 1000008 | 02/06/2020 | A-I-PP01 | 114,02 | Imediata |
| 1000029 | 21/05/2020 | A-I-PP02 | 540,12 | Planejada |
| 1000030 | 20/05/2020 | B-I-PP01 | 345,35 | Imediata |
| 1000031 | 20/05/2020 | B-I-CON02 | 737,25 | Planejada |
| 1000033 | 19/05/2020 | B-I-CON03 | 2.079,12 | Planejada |
| 1000039 | 13/05/2020 | C-I-CON01 | 2.366,99 | Imediata |
| 1000040 | 12/05/2020 | C-I-CON02 | 633,19 | Imediata |

O procedimento de higienização acima foi aplicado no conjunto amostrado na Tabela III, obtendo o conjunto de ordens de manutenção higienizado apresentado em amostra na Tabela IV. A quantidade de ordens de manutenção diminuiu de um número inicial de 7896 para 1482.

Para converter os dados extraídos do sistema de gestão integrado para um conjunto de dados na linguagem de programação *Python*, funções de análise e manipulação de dados da biblioteca *Pandas* foram utilizadas.

Outra etapa realizada, que é por muitas vezes negligenciada ou subestimada, é a conversão e padronização dos tipos de variáveis e formatos de dados. Por exemplo, as datas tiveram de ser convertidas para o formato universal (o formato originalmente utilizado no sistema era um padrão do próprio sistema, que não foi reconhecido imediatamente pela função de importação da biblioteca *Pandas*), para que assim pudesse ser utilizado sistemicamente em funções e cálculos em *Python*.

C. Processamento de Dados

A lista de ordens de manutenção preparada no item ‘B’ foi transformada em grupos, segregando os equipamentos pela identificação de seu local de instalação (ID) em um único registro que contenha:

- ID do equipamento;
- o número de falhas de cada equipamento;
- um vetor contendo as datas de cada falha do respectivo equipamento;
- um vetor contendo o cálculo do intervalo entre as falhas.
 - Este cálculo foi realizado declarando uma data de início de operação para os Ativos industriais, e calculando a partir deste os intervalos entre cada registro de falhas na lista de ordens de manutenção preparada no item ‘B’.

O novo conjunto de dados originado pela aplicação das etapas citadas acima foi mesclado com o conjunto de ativos do item ‘A’, relacionando todos os dados necessários em um único conjunto de dados. A razão de concentrar todas as informações num único conjunto visa facilitar a aplicação de técnicas estatísticas e modelos de aprendizado de máquina.

Outra etapa com possibilidade de aplicação nesse estudo, seria a redução da quantidade de registros no novo conjunto,

por exemplo, agrupando os ativos industriais por subconjuntos de marca e modelo, desconsiderando outros atributos como a localização da planta onde o ativo está instalado e a idade de cada equipamento. Tal abordagem pode ser utilizada como um contorno para melhorar a precisão do método da máxima verossimilhança, especialmente se o registro de falhas por equipamento for pobre. Caso a amostra de falhas coletadas contenha um número suficiente de registros de falhas por ativo industrial, esse tratamento não seria necessário, pois poderia diminuir a qualidade do aprendizado de máquina, a ser aplicado posteriormente.

A última ação do processamento desse novo conjunto de dados, antes da aplicação do método da máxima verossimilhança, foi de remover todos os equipamentos com menos de 3 registros de falhas. Para aplicar a estimativa por máxima verossimilhança, devemos possuir para cada registro (cada equipamento) um número de falhas que seja minimamente igual ao número de parâmetros das distribuições em que o método será aplicado, caso contrário os dados seriam insuficientes para a estimativa [30].

TABELA V
ESTRATÉGIAS DE CODIFICAÇÃO DISTRIBUÍDA PARA CADA
ATIVO DA TABELA II.

| ID | Estratégia Corretiva | Estratégia Preventiva |
|-----------|----------------------|-----------------------|
| A-I-PP01 | 0 | 1 |
| A-I-PP02 | 0 | 1 |
| B-I-PP01 | 0 | 1 |
| B-I-CON02 | 1 | 0 |
| B-I-CON03 | 1 | 0 |
| B-I-CON04 | 1 | 0 |
| C-I-CON01 | 0 | 1 |
| C-I-CON02 | 0 | 1 |
| C-I-CON03 | 0 | 1 |

Por exemplo: se a coluna “estratégia” da Tabela 1 fosse submetida à técnica de Codificação Distribuída, o registro do tipo texto que representava qual a estratégia para cada ativo seria substituída pelo conjunto de valores apresentado na Tabela V.

Os vetores X (entradas) e Y (saídas) tiveram seus registros não numéricos submetidos à Codificação Distribuída e foram separados, de forma aleatória, mantendo 80% dos registros como dados de treinamento e 20% como dados de teste. Assim, foi possível experimentar o modelo simulando uma situação de inexistência do histórico de falhas para 20% dos equipamentos, e posteriormente comparar os resultados da estimativa por rede neural (com a ausência dos históricos de falhas) em relação aos resultados da estimativa por máxima verossimilhança, realizados sobre o histórico real.

A arquitetura da rede neural LSTM foi otimizada por meio de uma metodologia empírica, inspirada em *grid search*, orientada para a redução do erro logarítmico quadrático médio em relação ao custo computacional de processamento. Para tanto, foram executadas diversas alternativas de construções para a arquitetura do modelo variando parâmetros, neurônios e combinações de camadas.

Para o problema em estudo, os melhores resultados foram obtidos utilizando uma camada de Memória de Curto e Longo

Praço (LSTM, ou *Long Short-Term Memory*) com 512 neurônios e função de ativação ReLU. Além disso, a rede também possui uma camada *Dropout* de 0,2 e uma camada *Dense* de saída com um otimizador Adam orientado pela função de erro logarítmico quadrático médio e taxa de aprendizagem 0,001. Em todos os modelos testados, utilizou-se o limite de 100 iterações para a aprendizagem.

D. Implementação Computacional

Usando as funções de ajuste da biblioteca gratuita *Reliability* para *Python*, a estimativa por máxima verossimilhança foi aplicada em cada ativo industrial do conjunto obtido ao final do item 'C'. Através da ordenação dos conjuntos e parâmetros de distribuição utilizando o critério Bayesiano de Schwarz, foi possível determinar a distribuição e estimar os parâmetros que melhor representam as funções de confiabilidade e falha para cada ativo com histórico de falhas conhecido.

Os dados de regressão de múltiplos resultados para ativos sem histórico de falha foram previstos pelo modelo de rede neural de Memória de Curto e Longo Prazo (LSTM, ou *Long Short-Term Memory*) utilizando a API de redes neurais profundas *Keras*, parte integrante da biblioteca gratuita *TensorFlow* [26].

As funções desenvolvidas e implementadas no presente artigo estão disponíveis no repositório gratuito *GitLab* [31].

IV. RESULTADOS E DISCUSSÕES

Aplicando o modelo proposto em cada ativo industrial do conjunto de dados, foi possível obter um vetor contendo a melhor distribuição e os respectivos parâmetros segundo a ordenação pelo Critério Bayesiano de Schwarz. Uma das execuções dessa abordagem é exemplificada na Tabela VI e na Figura 4. O ativo selecionado para ilustração dos resultados foi uma turbina a vapor.

TABELA VI

RESULTADOS DA APLICAÇÃO DA ESTIMATIVA POR MÁXIMA VEROSSIMILHANÇA PARA UM DETERMINADO ATIVO.

| Distribuição | Alpha | Beta | Gamma | Mu | Sigma | Lambda | AIC | BIC |
|----------------|--------|------|-------|------|-------|--------|-------|-------|
| Gamma_3P | 302,07 | 0,22 | 9,00 | | | | 66,47 | 41,29 |
| Weibull_3P | 23,36 | 0,32 | 9,00 | | | | 68,01 | 42,84 |
| Exponential_1P | | | | | | 0,01 | 56,67 | 54,94 |
| Lognormal_2P | | | | 3,58 | 1,21 | | 61,89 | 55,11 |

A Rede Neural LSTM com Múltiplos Critérios de Saída foi aplicada ao conjunto de dados. Após os ajustes para melhorar a assertividade da rede, os resultados obtidos são exibidos na Figura 5.

O erro logarítmico quadrático médio para os resultados apresentados acima foi de 0,5599; O erro para a primeira tentativa de arquitetura do presente artigo foi de 69042,5547. Apesar de não haver uma convenção de um intervalo de erro aceitável para classificar como eficiente ou não uma rede neural [32], foi tomado como critério de parada o momento em que o incremento do custo computacional ou o tempo de processamento não apresentava mais melhorias significativas no resultado.

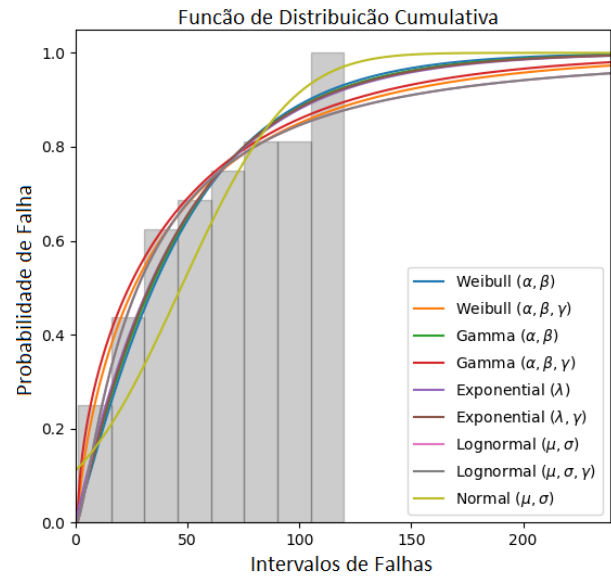


Fig. 4. Gráfico de histograma da estimativa por máxima verossimilhança tentando ajustar os melhores parâmetros para cada distribuição em um determinado ativo.

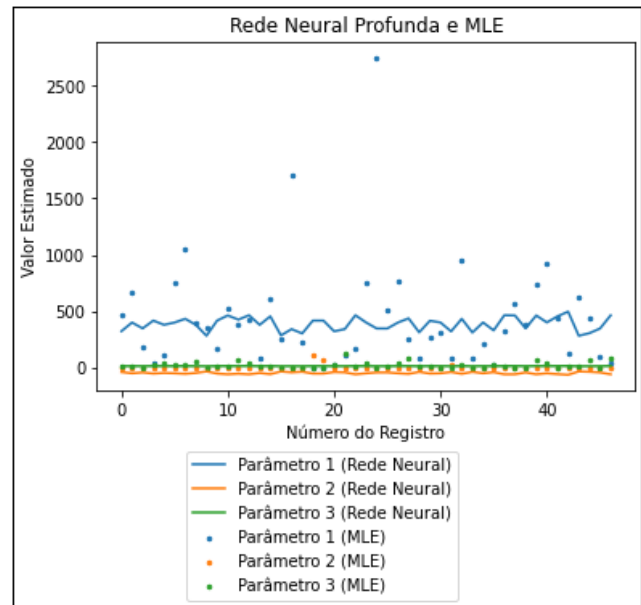


Fig. 5. Predição por redes neurais (linhas), comparados com os resultados da estimativa por máxima verossimilhança (pontos). Cada item do eixo 'Número do Registro' representa um equipamento do conjunto de teste.

A. Discussões

Dado que a estimativa por máxima verossimilhança é baseada em um histórico de falhas conhecido, e trata-se de um método amplamente conhecido e utilizado no campo da manutenção centrada em confiabilidade, seus resultados foram utilizados como dados de treinamentos para o modelo de rede neural desenvolvido. Na Figura 5 é possível perceber graficamente a diferença dos parâmetros estimados pela rede neural e dos obtidos através da estimativa por máxima verossimilhança. Especialmente em relação ao parâmetro 1, observa-se que

foi possível demonstrar que a abordagem pode ser utilizada em situações práticas para prever a distribuição estatística de falhas para ativos com histórico desconhecido, apesar de existir oportunidade para o refinamento da arquitetura proposta nesse artigo melhorando a precisão dos resultados.

Ao final da aplicação, o estudo mostrou que foi possível utilizar uma abordagem de rede neural aplicada sobre um conjunto de dados estatísticos gerados através da aplicação e ordenação de uma estimativa por máxima verossimilhança, a fim de prever o tipo de distribuição e seus parâmetros que representariam melhor o comportamento de confiabilidade de múltiplos equipamentos com um histórico de falhas desconhecido.

Apesar da abordagem proposta necessitar de aprendizado através de dados técnicos e histórico de falhas de equipamentos similares, a relevância e significância da mesma é ratificada pois apresenta uma alternativa viável e complementar em relação à abordagem tradicional (Não seria possível propor curvas de confiabilidade para equipamentos sem histórico apenas através da estimativa por máxima verossimilhança).

Os dados utilizados no estudo foram anonimizados e estão disponíveis no repositório gratuito GitLab. [31] A seção III, onde a implementação do modelo é detalhada, foi desenvolvida com base nos dados dessa segunda aplicação.

V. CONCLUSÃO

Neste trabalho utilizou-se um modelo de rede neural recorrente, com arquitetura LSTM (*Long Short-Term Memory*), para estimar a curva, com seus respectivos parâmetros, que melhor se ajusta a um dado histórico de falhas de equipamento. O modelo foi implementado utilizando bibliotecas de código aberto em linguagem *Python* e testado com base em dados reais, coletados do sistema de gestão integrado de um grupo privado de indústrias do setor sucroenergético.

Comparando os resultados da abordagem com os dados de teste (a rede neural LSTM contra a abordagem por máxima verossimilhança), os mesmos mostram que o modelo proposto é eficiente para identificar uma curva de falha com os respectivos parâmetros, com resultados similares a abordagem tradicional de estimativa por máxima verossimilhança para dados de teste, mas com a grande vantagem da possibilidade de sua aplicação em equipamentos sem histórico de falhas (um cenário que não poderia ser tratado pela abordagem tradicional).

Como desdobramento desse estudo, pode-se considerar a utilização de validação cruzada *k-fold* para redes neurais com múltiplos critérios de saída visando reduzir eventuais vieses no aprendizado. Além disso, os resultados computacionais obtidos podem ser comparados com as distribuições teóricas previstas. Outra possibilidade seria de expandi-lo obtendo sugestões de um modelo híbrido que combine estimativas de confiabilidade com modelos de previsão e otimização de custos, compondo um *framework* completo de decisão de estratégia de manutenção.

Por fim, conclui-se que os resultados obtidos permitem ao tomador de decisão (geralmente o gestor de negócio responsável pela estratégia de manutenção) customizar curvas de falhas para cenários particulares e definir estratégias de

manutenção na prática, porém não devem ser utilizados na orientação de tomadas de decisão de maneira isolada. O artigo também demonstra que a confiabilidade dos resultados pode ser melhorada e consolidada através uma pesquisa aplicada.

REFERÊNCIAS

- [1] M. Lopes and R. Martins, "Mapping the impacts of industry 4.0 on performance measurement systems," *IEEE Latin America Transactions*, vol. 1000, no. 4807, pp. 1912–1923, 2021.
- [2] M. Rodrigues and K. Hatakeyama, "Analysis of the fall of tpm in companies," *Journal of Materials Processing Technology*, vol. 179, p. 276–279, 10 2006.
- [3] K.-A. Nguyen, P. Do, and A. Grall, "Joint predictive maintenance and inventory strategy for multi-component systems using birnbaum's structural importance," *Reliability Engineering & System Safety*, vol. 168, pp. 249–261, 2017. Maintenance Modelling.
- [4] E. Ruschel, E. A. P. Santos, and E. de Freitas Rocha Loures, "Industrial maintenance decision-making: A systematic literature review," *Journal of Manufacturing Systems*, vol. 45, pp. 180–194, 2017.
- [5] G. Gupta and R. Mishra, "A swot analysis of reliability centered maintenance framework," *Journal of Quality in Maintenance Engineering*, vol. 22, pp. 130–145, 05 2016.
- [6] J. Igba, K. Alemzadeh, I. Anyanwu-Ebo, P. Gibbons, and J. Friis, "A systems approach towards reliability-centred maintenance (rcm) of wind turbines," *Procedia Computer Science*, vol. 16, pp. 814–823, 2013. 2013 Conference on Systems Engineering Research.
- [7] J. Izquierdo, A. C. Márquez, J. Uribetxebarria, and A. Erguido, "On the importance of assessing the operational context impact on maintenance management for life cycle cost of wind energy projects," *Renewable Energy*, vol. 153, pp. 1100–1110, 2020.
- [8] M. Abbas and M. Shafiee, "An overview of maintenance management strategies for corroded steel structures in extreme marine environments," *Marine Structures*, vol. 71, p. 102718, 2020.
- [9] A. Dhar and V. Minin, "Maximum likelihood phylogenetic inference," *Encyclopedia of Evolutionary Biology*, 12 2016.
- [10] E. A. Mohammed, C. Naugler, and B. H. Far, "Chapter 32 - emerging business intelligence framework for a clinical laboratory through big data analytics," in *Emerging Trends in Computational Biology, Bioinformatics, and Systems Biology*, pp. 577–602, Elsevier Inc, 2015.
- [11] NIST/SEMATECH, *e-Handbook of Statistical Methods*, 2013.
- [12] M. Abbas and M. Shafiee, "An overview of maintenance management strategies for corroded steel structures in extreme marine environments," *Marine Structures*, vol. 71, 5 2020.
- [13] M. Paolanti, L. Romeo, A. Felicetti, A. Mancini, E. Frontoni, and J. Loncarski, "Machine learning approach for predictive maintenance in industry 4.0," Institute of Electrical and Electronics Engineers Inc., 8 2018.
- [14] G. S. Sampaio, A. R. de Aguiar Vallim Filho, L. S. da Silva, and L. A. da Silva, "Prediction of motor failure time using an artificial neural network," *Sensors*, vol. 19, p. 4342, Oct. 2019.
- [15] D. Chan and J. Mo, "Life cycle reliability and maintenance analyses of wind turbines," *Energy Procedia*, vol. 110, pp. 328–333, 2017. 1st International Conference on Energy and Power, ICEP2016, 14-16 December 2016, RMIT University, Melbourne, Australia.
- [16] P. Tchakoua, R. Wamkeue, M. Ouhrouche, F. Hasnaoui, T. A. Theubou Tameghe, and G. Ekemb, "Wind turbine condition monitoring: State-of-the-art review, new trends, and future challenges," *Energies*, vol. 7, pp. 2595–2630, 04 2014.
- [17] M. Wiseman, "Real meaning of the six rcm curves." <https://www.livingreliability.com/en/posts/real-meaning-of-the-six-rcm-curves/>, 2011.
- [18] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, pp. 1735–80, 12 1997.
- [19] K. Schenkelberg, U. Seidenberg, and F. Ansari, "Analyzing the impact of maintenance on profitability using dynamic bayesian networks," *Procedia CIRP*, vol. 88, pp. 42–47, 2020.
- [20] J. Kang and C. G. Soares, "An opportunistic maintenance policy for offshore wind farms," *Ocean Engineering*, vol. 216, p. 108075, Nov. 2020.
- [21] E. Amrina, I. Kamil, and D. Aridharma, "Fuzzy multi criteria approach for sustainable maintenance performance evaluation in cement industry," *Procedia Manufacturing*, vol. 43, pp. 674–681, 2020.
- [22] A. Syamsundar, V. Naikan, and S. Wu, "Estimating maintenance effectiveness of a repairable system under time-based preventive maintenance," *Computers & Industrial Engineering*, vol. 156, p. 107278, June 2021.

- [23] M. H. Nili, H. Taghaddos, and B. Zahraie, "Integrating discrete event simulation and genetic algorithm optimization for bridge maintenance planning," *Automation in Construction*, vol. 122, p. 103513, Feb. 2021.
- [24] R. Mena, P. Viveros, E. Zio, and S. Campos, "An optimization framework for opportunistic planning of preventive maintenance activities," *Reliability Engineering & System Safety*, vol. 215, p. 107801, Nov. 2021.
- [25] J. Wang and Y. Miao, "Optimal preventive maintenance policy of the balanced system under the semi-markov model," *Reliability Engineering & System Safety*, vol. 213, p. 107690, Sept. 2021.
- [26] O. Yorkinov, "Multioutput regression example with keras lstm network in python." https://www.datatechnotes.com/2019/12/multi-output-regression-example-with_24.html, 2019.
- [27] E. Paiva, A. Paim, and N. Ebecken, "Convolutional neural networks and long short-term memory networks for textual classification of information access requests," *IEEE Latin America Transactions*, 2021.
- [28] S. Sugiyam, *Human Behavior and Another Kind in Consciousness*. IGI Global, 2019.
- [29] J. Schmidhuber, "Deep learning in neural networks: an overview," *Neural Netw*, vol. 61, pp. 85–117, Jan 2015.
- [30] M. Reid, "Reliability - a python library for reliability engineering." <https://reliability.readthedocs.io/en/latest/index.html>, 2020.
- [31] G. Scavariello, "Repositório: Combinação da estimativa por máxima verossimilhança com uma rede neural profunda." GitLab Project ID: 25750333, 2021.
- [32] G. Singh Jammal, *A Cognitive IoE (Internet of Everything) Approach to Ambient-Intelligent Smart Space*. PhD thesis, 2019.



Guilherme Hering Scavariello possui graduação em Engenharia de Manufatura pela UNICAMP (2015) e MBA em Gerenciamento de Projetos pela Fundação Getúlio Vargas (2017). Atualmente exerce a função de engenheiro de manutenção sênior no setor sucroenergético e cursa o mestrado no programa de Engenharia de Produção e Manufatura, na área de Pesquisa Operacional, da UNICAMP - Universidade Estadual de Campinas. <http://lattes.cnpq.br/0102116187507472>



Ailson Renan Santos Picanço é graduado em Engenharia de Produção pela UEPA, Mestre em Engenharia de Produção e de Manufatura, na área de Pesquisa Operacional, pela Universidade Estadual de Campinas e Doutor em Pesquisa Operacional pelo Programa ITA/Unifesp. Possui experiência em modelagem matemática, métodos quantitativos de apoio à decisão, programação linear e programação inteira-mista. Desenvolve pesquisas na área de engenharia de confiabilidade, simulação de eventos discretos, modelagem matemática e Lean Manufacturing. <http://lattes.cnpq.br/3070913718574346>



Cristiano Torezzan é doutor em Matemática Aplicada pela Unicamp e atua como docente na Faculdade de Ciências Aplicadas da mesma Universidade. É membro fundador do Centro de Pesquisa Operacional da Unicamp e seus temas de pesquisa concentram-se nas áreas de Pesquisa Operacional e Teoria de Informação, com ênfase em modelagem matemática, análise de dados, apoio à decisão multicritério e métodos matemáticos para inteligência artificial. <http://lattes.cnpq.br/1314550908170192>