

CATEGORIA 1

INTELIGÊNCIA ARTIFICIAL NA GESTÃO METROFERROVIÁRIA: TRANSFORMANDO DADOS EM INFORMAÇÕES DE ALTO VALOR

1. INTRODUÇÃO

A transformação de dados em informação vem ganhando cada vez mais importância no contexto empresarial atual, na indústria de capital intensivo esse tema assume uma importância ainda maior, devido aos elevados ganhos de desempenho financeiro e operacional que podem ser obtidos.

O desenvolvimento da computação e das redes de informação aumentou de forma exponencial a quantidade de dados disponíveis, para que estes dados efetivamente possam gerar valor é essencial que as perguntas corretas sejam feitas, e é neste contexto que este trabalho se encaixa.

A proposta deste trabalho é utilizar ferramentas da teoria da decisão e modelagem matemática para tratar dados de confiabilidade de um sistema metroferroviário, estes dados, juntamente com outros dados operacionais do sistema

serão transformados em informações gerenciais, como o custo material e de recursos humanos necessários em um determinado espaço de tempo, estas informações possuem um alto valor para definir estratégias de engenharia de sistemas e de gestão da manutenção, permitindo uma visão global do estado atual e permitindo avaliar e decidir entre diferentes opções de investimento ou ações que possam elevar o desempenho operacional do sistema.

Na sessão de introdução deste trabalho fazemos uma breve fundamentação teórica do assunto, de forma a proporcionar uma maior compreensão do trabalho desenvolvido.

1.1. Inteligência artificial:

Estamos vivenciando a quarta revolução industrial, impulsionada pelo desenvolvimento de tecnologias avançadas, como a Inteligência Artificial. A Inteligência artificial permite que as máquinas realizem tarefas intelectuais, utilizando ferramentas que utilizam o que se considera *inteligência* (LUDERMIR, 2021).

O fato que está acelerando as aplicações de Inteligência Artificial para usos cotidianos é o desenvolvimento e popularização das comunicações em rede, a redução dos custos e o aumento da capacidade de processamento distribuída em vários equipamentos, permitindo por exemplo que hoje tenhamos tradutores multilíngues instantâneos, como no caso do Google Translator, ou aplicativos que dinamizam a interação entre homem e máquina, como a Siri da Apple, ou a Alexa da Amazon. Estes

mesmos elementos também favorecem a disponibilização de dados em alta escala, elemento essencial para desenvolvimento e implantação de sistemas com inteligência artificial.

As ferramentas para implementação de inteligências artificiais já existem há vários anos, no caso do nosso trabalho construímos uma solução utilizando redes Bayesianas, a origem desta técnica remonta a solução do problema das sete pontes de Königsberg, apresentado por Euler em 1736, dando a origem a teoria dos grafos; e com o trabalho do Reverendo Thomas Bayes sobre a doutrina das probabilidades, apresentado em 1763, em 1950 Alan Turing questiona em seu artigo "Computing Machinery and Intelligence" a possibilidade de computadores "pensarem"; esses foram alguns dos pesquisadores que lançaram as bases teóricas para o desenvolvimento das ferramentas de inteligência artificial, revolucionando diversas áreas da ciência, da medicina à teologia.




Figura 01 – O problema das pontes de Königsberg (LOPES, 2015)

A figura 01 apresenta o mapa que dá origem ao problema de Königsberg: seria possível atravessar as sete pontes, passando apenas uma vez por cada uma delas? Podemos notar que o problema de Königsberg é muito semelhante aos problemas de otimização de rotas e carregamentos logísticos.



$$p(H|E) = \frac{p(H) \times p(E|H)}{p(E)}$$

Figura 02 – Reverendo Bayes e a forma simplificada de seu teorema.

O teorema de Bayes permite relacionar probabilidades de ocorrências entre eventos, onde $p(H)$ e $P(E)$ são as probabilidades de ocorrência dos eventos H e E ; $p(H|E)$ e $p(E|H)$ representam as verossimilhanças entre estas probabilidades, ou seja, a probabilidade de ocorrência dos eventos H ou E , dados que os eventos H ou E ocorreram previamente.

Em termos práticos isso significa que podemos utilizar probabilidades de eventos para inferir a probabilidade de ocorrência de outros eventos relacionados, este teorema também permite relacionar probabilidades extraídas de dados brutos com probabilidades subjetivas, como a opinião de especialistas por exemplo.

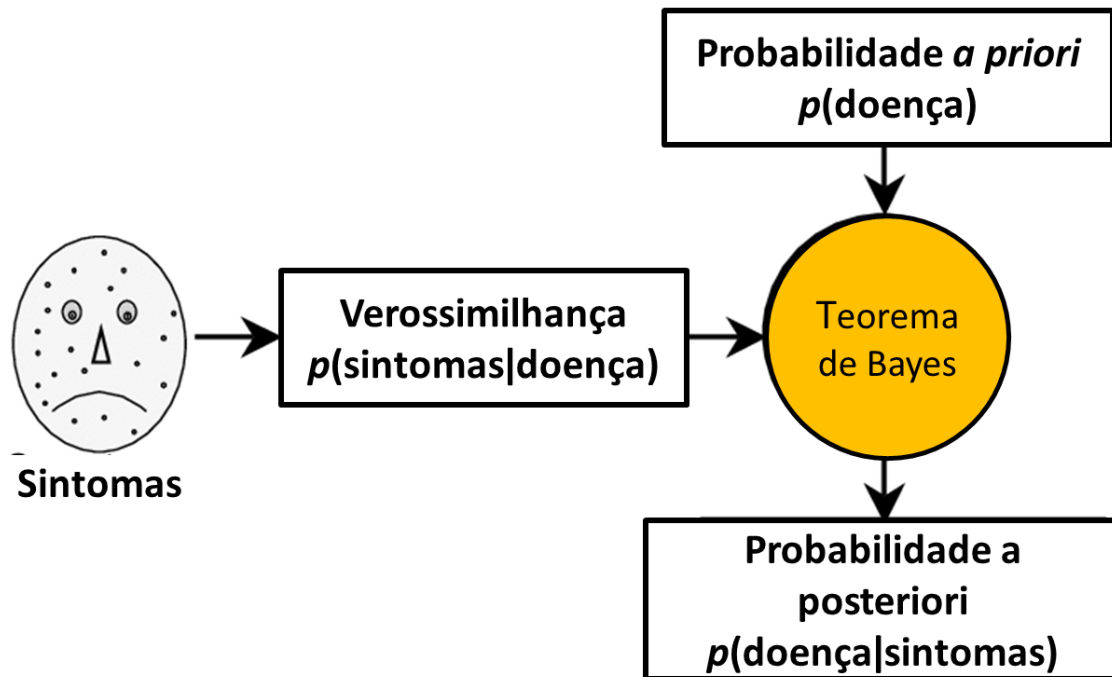


Figura 03 – Exemplo da aplicação de redes Bayesianas no diagnóstico de doenças

(STONE, 2015)

Na figura 03 temos um exemplo de como redes bayesianas podem ser aplicadas no diagnóstico de doenças, no modelo proposto a partir da probabilidade de ocorrência da doença $p(\text{doença})$, e da verossimilhança entre estes sintomas que é a probabilidade do paciente apresentar a doença na presença destes sintomas, com estes dados é possível determinar a probabilidade de este paciente estar doente. Este é um uso comum das redes bayesianas, em modelos mais complexos é possível utilizar variáveis como resultados de exames e histórico do paciente para um diagnóstico com maior precisão. Estes modelos podem ser transformados em softwares, que alimentados com dados de pacientes fornecem informações que auxiliam o médico nas decisões por

tratamentos ou solicitação de exames, constituindo uma importante ferramenta de inteligência artificial.

As ferramentas de inteligência artificial possuem aplicações em diversas áreas do conhecimento. A capacidade de processar grandes quantidades de dados e a possibilidade de incorporar a opinião de especialistas aos modelos tornam estas ferramentas ótimas opções para a construção de ferramentas de suporte a decisão, como no exemplo da Figura 03, onde temos uma rede Bayesiana simples que transforma dados do paciente e de probabilidade em informações de suporte a decisões médicas.

O propósito deste trabalho é apresentar uma ferramenta de inteligência artificial utilizando uma rede Bayesiana, que relaciona dados de confiabilidade de equipamentos com probabilidades relacionadas ao impacto operacional em um sistema metroferroviário, fornecendo informações de custos de manutenção e impactos operacionais estimados através da opinião de especialistas; estas informações serviram de suporte a decisões na gestão da manutenção e operação do sistema.

1.2. Suporte a decisão: Transformando dados em informação

Muitas vezes a diferença entre dados e informação não é bem compreendida, desta forma, a fim de clarificar qual a função de um sistema de suporte a decisão vamos definir estes termos, definindo também os elementos que compõem um sistema de suporte a decisão.

Dados: Observações documentadas de determinado fenômeno, estes podem ser obtidos pela mera observação do fenômeno ou através de processos de medição, com a posterior documentação destas medições. Para serem úteis estes dados precisam ser armazenados, sendo o armazenamento em meios digitais o mais utilizado atualmente. É importante ressaltar que dados não tem nenhuma utilidade quando analisados de forma desestruturada, ou seja, eles não transmitem nenhuma informação se não forem analisados de forma estruturada; os dados precisam de um contexto para poderem se transformar em informação.

Informação: É a ordenação e organização de dados de forma a transmitir significado e compreensão dentro de determinado contexto, ou seja, um conjunto estruturado de dados que fornece elementos inteligíveis, informações, a partir dos dados.




Figura 04 - A contextualização dos dados possibilita que estes forneçam informação

1.3. Sistemas de suporte a decisão

Alguns autores sugerem pirâmides para ilustrar a relação entre dados e informação, e a sua importância no apoio a decisão, vamos utilizar a pirâmide proposta por Stefanini em 2015, com adaptação do autor para indicar a relação entre *volume de dados e valor das informações*:



Figura 05 – Pirâmide de transformação de dados

A pirâmide propõe uma transformação dos dados em informação, e esta informação aliada ao conhecimento compõem as base da Decisão, também notamos que a pirâmide sugere uma diminuição no volume de elementos com o aumento de seu valor, ou seja, uma grande quantidade de dados pode ser transformada em uma quantidade menor de informações, porém com alto valor agregado.

Esta é a função de um sistema de suporte a decisão, reunir dados e transformá-los em informação, esta informação aliada ao conhecimento dos profissionais de gestão é a base de apoio a decisão.

No sistema proposto neste trabalho parte do conhecimento está agregado ao sistema de apoio, na forma de opiniões de especialistas, este fato o torna um sistema que simula uma inteligência artificial, simulando a forma como estes especialistas analisariam estes dados, e fornecendo as informações que darão suporte a decisão.

1.4. Como dados se transformam em informação?

Para que os dados possam ser transformados em informação é necessária uma modelagem do processo que vai estruturar e contextualizar os dados de forma que eles possam ser transformados em informação.

O processo de modelagem permite criar modelos matemáticos que representam os sistemas que estão sob estudo, vários autores propõe em seus trabalhos etapas e processos para realizar a modelagem, na figura 06 temos um processo composto pelas etapas de concepção, implementação e análise, proposto por CHWIF em 2010.

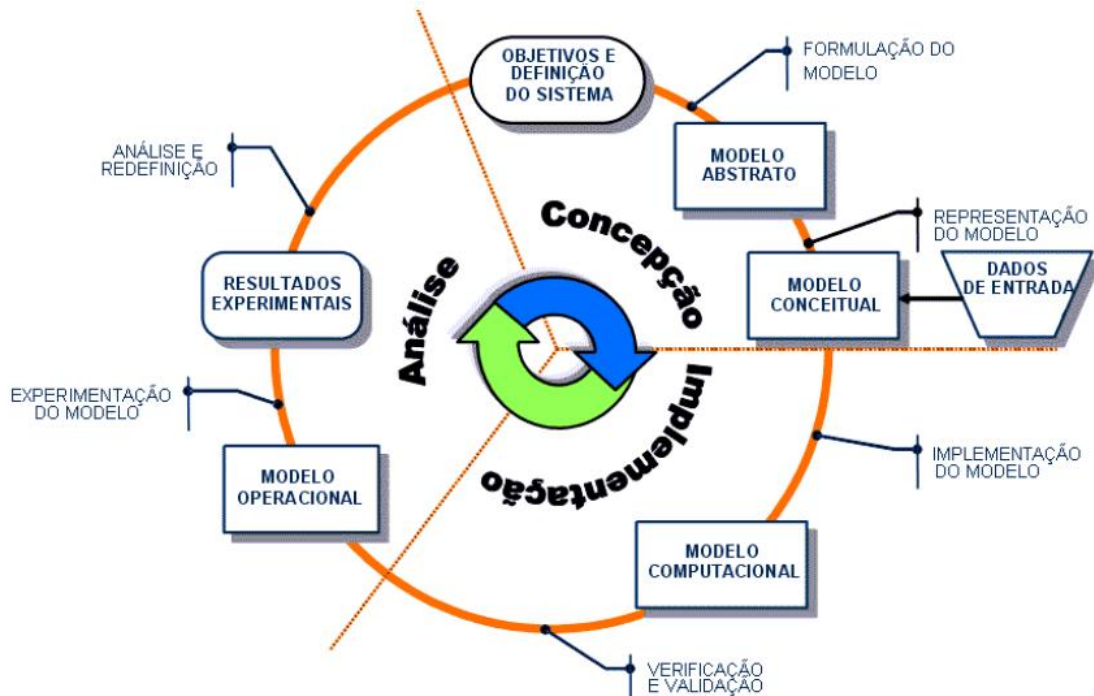


Figura 06 - Método CIA: Concepção, Implementação e Análise (CHWIF 2010)

O processo de modelagem é cíclico, conforme a quantidade de dados disponíveis aumenta os modelos representam melhor a realidade.

Para um melhor entendimento do tema vamos resumir os processos do método CIA:

Concepção: Definição do objetivo do modelo a ser construído, sua abstração (comparação com ferramentas matemáticas que possam representar o comportamento do sistema), isto permite a elaboração de um modelo conceitual.

Implementação: Construção do modelo em um software de simulação, e sua verificação e validação utilizando dados reais ou experimentais do sistema.

Análise: Criação de um modelo operacional, em ambientes de simulação ou criando softwares dedicados, sua experimentação no mundo real, analisando seu desempenho e redefinindo suas funcionalidades quando necessário.

1.5. Distribuições de probabilidade

A distribuições de probabilidade são funções matemáticas que descrevem a probabilidade de ocorrência de determinadas variáveis, na figura 07 temos um exemplo de distribuição de uma variável discreta (variável não contínua):

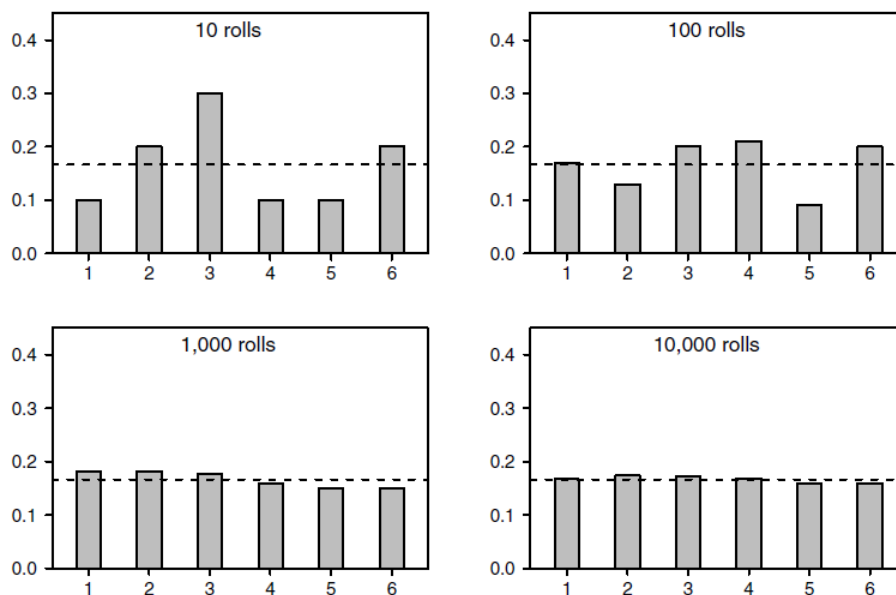


Figura 07 - Distribuições de probabilidade de resultados no lançamento de um dado

honesto, com 10, 100, 1000 e 10000 lançamentos (BOLSTAD, 2017, p.85)

Na figura 07 notamos que cada valor possível de resultado para o lançamento de um dado não viciado, assume determinada probabilidade de ocorrência, no caso do lançamento de um dado honesto as probabilidades de ocorrência de cada face é de $1/6$,

o que faz que um grande número de lançamentos assuma uma distribuição uniforme. Esta distribuição é importante para o modelamento de fenômenos puramente aleatórios, veremos alguns exemplos adiante neste trabalho.

As distribuições de probabilidade também podem representar variáveis contínuas, isto é, variáveis que podem assumir infinitos valores dentro de um intervalo amostral; como por exemplo a distribuição do peso corporal dos indivíduos de uma determinada população, ou a distribuição de temperaturas em determinado local ao longo de 24 horas.




Figura 08: Função de distribuição de probabilidades de uma variável contínua com distribuição normal (BUSSAB, W. 2010)

No exemplo da figura 08 temos uma distribuição normal; uma grande variedade de fenômenos físicos pode ser descrita com esta distribuição, a área sob a curva indica a

probabilidade de ocorrência de determinado intervalo de valores, como exemplificado na figura 09:




Figura 09: Representação das probabilidades em uma curva de distribuição normal

(MOORE, 2007)

A apresentação das características da curva normal é importante neste trabalho para introduzir o conceito de distribuição de probabilidades de uma variável contínua. São conceitos importantes para compreender como é construído um modelo matemático.

1.6. Distribuição de Weibull

A distribuição de Weibull é uma distribuição de probabilidades proposta por Waloddi Weibull em 1951, esta distribuição tem vital importância na engenharia e na confiabilidade, é uma distribuição matematicamente simples, podendo ser definida por apenas dois parâmetros (usualmente denota-se β como parâmetro de forma e η como parâmetro de escala), é uma distribuição bastante flexível e capaz de representar o comportamento de diversos sistemas complexos.

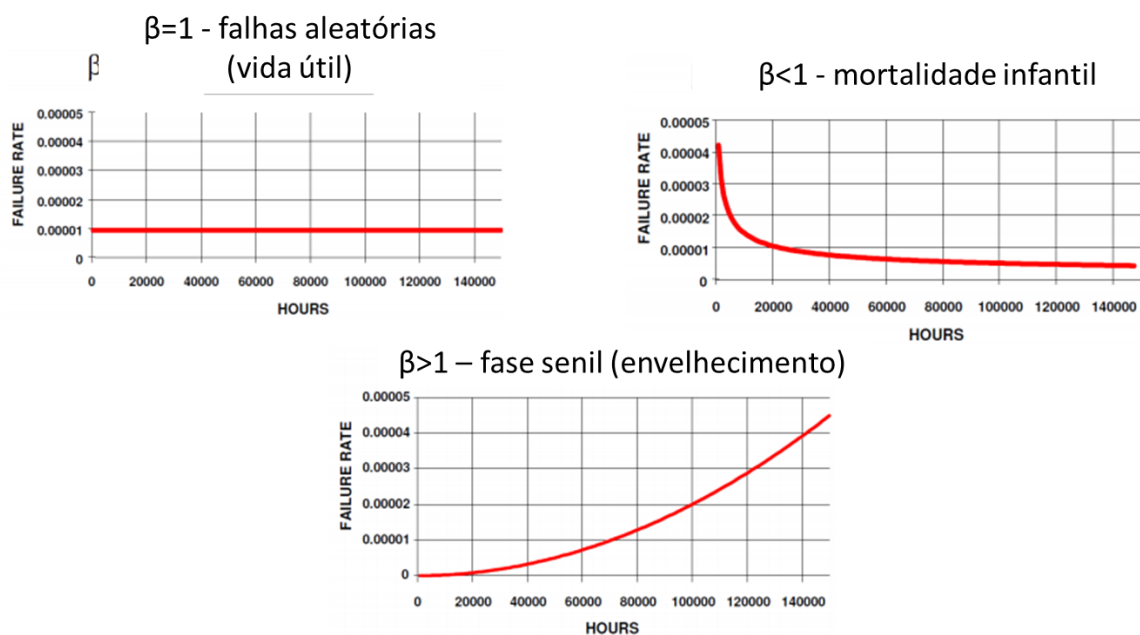


Figura 10: Exemplos da distribuição Weibull com diferentes valores de β

Na figura 10 temos exemplos da distribuição Weibull com diferentes valores de β , a análise de um sistema ou componente utilizando a distribuição Weibull podemos definir em qual etapa da vida útil o componente se encontra, possibilitando construir a

curva da banheira que caracteriza o comportamento deste componente durante sua vida útil, conforme representado na figura 11.

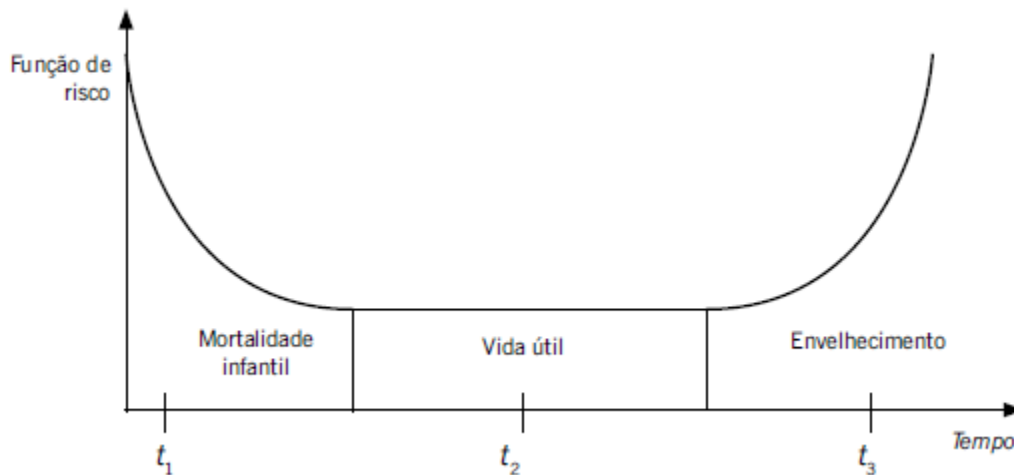


Figura 11: Curva da banheira (FOGLIATTO, 2009)

A figura 11 ilustra a curva da banheira, que expressa a taxa de risco (também conhecida como taxa de falhas) de determinado componente ou sistema ao longo da sua vida útil, detalhamos as fases de vida abaixo:

- **Mortalidade infantil:** fase onde o componente apresenta falhas no início da vida, normalmente ocorrem devido a falhas de projeto, falhas de material, falhas de instalação, ou falhas humanas na implantação do sistema.
- **Vida útil:** fase da vida onde o componente apresenta falhas aleatórias e em sua maioria naturais ao uso do componente.
- **Fase de envelhecimento:** fase onde ocorrem problemas ligados ao envelhecimento do sistema ou componente, como desgaste por exemplo.

Neste trabalho utilizamos a distribuição Weibull para modelar os componentes de um sistema de portas do trem e estimar a probabilidade destes componentes apresentarem falha durante determinado intervalo de operação (missão).

Na sessão seguinte apresentamos o diagnóstico que levou a elaboração do sistema de apoio a decisão proposto neste trabalho.

2. DIAGNÓSTICO

Para o desenvolvimento deste trabalho decidimos utilizar os dados de falha do sistema de portas de uma das frotas de trem do Metrô de SP.

Optamos pelo sistema de portas devido ao alto impacto que este sistema tem na operação Metroferroviária. Segundo Connor, 2011, os sistemas de portas representam apenas 3% do custo do trem, porém são responsáveis por até 25% das interferências operacionais. As características que fazem das portas equipamentos tanto operacionais quanto de segurança ajudam a explicar os elevados impactos que falhas neste sistema provocam na operação.

Os trens somente comandam tração e partem da estação quando é detectado o fechamento e travamento de todas as portas do trem, o sistema de um único trem pode operar até 10 mil aberturas e fechamentos em um único mês, é razoável que este sistema concentre grande parte das falhas do material rodante, representando tradicionalmente cerca de 50% de todas as falhas.

Para a modelagem matemática do sistema de portas foi utilizada uma massa de dados referente a cinco anos de operação de 23 trens com sistema de porta idêntico (trens da mesma frota), cada item da massa de dados possuía os seguintes parâmetros:

- Componente
- Data e hora da ocorrência
- Quilometragem
- Local de ocorrência da falha (Via ou Pátio)
- Nível da falha (Grave ou leve)

A massa de dados foi utilizada para modelar o comportamento dos componentes do sistema e estimar a probabilidade de fatores que podem causar menor ou maior interferência operacional.

Para o tratamento dos dados foi utilizado um software estatístico comercial, que oferece funções para a análise de distribuições de probabilidade, e permite o levantamento destas curvas mesmo com dados incompletos (dados censurados).

Também é importante ressaltar que foram adotadas algumas premissas para a realização deste trabalho, sendo que as mais importantes são a adoção de dados censurados a direita (foi utilizada a massa de dados que já existia sobre o sistema) e foi considerado que todos os componentes não são reparáveis (são substituídos na ocorrência da falha). Este tipo de simplificação é comum no processo de modelagem,

são premissas que simplificam o processo de análise e possibilitam percorrer o ciclo CIA (citado na introdução) mais vezes e com maior rapidez.

Com o uso do software estatístico levantamos a curva dos componentes, a fim de verificar se a distribuição Weibull poderia ser utilizada em sua representação matemática:

Probability plot – Componente A




Figura 12 – Verificação da adequação dos dados do componente A

Na figura 12 temos um gráfico de verificação da distribuição de probabilidade de um componente do sistema (Componente A), a análise mostra que os dados seguem em 95% da vezes um distribuição Weibull de 2 parâmetros; o software também fornece o valor dos parâmetros, permitindo avaliar em qual fase da vida o componente se

encontra, e possibilita calcular as probabilidades de falha durante determinado período de operação.

Taxa de falhas – Componente A




Figura 13 – Gráfico representando a taxa de falhas do componente A

Na figura 13 está representada a curva de taxa de falhas do componente A, com um valor β de 0,92 podemos supor que este componente está deixando a fase de mortalidade infantil e entrando em uma fase de ocorrência de falhas aleatórias, em menor número e com maior intervalo; o componente está atingindo a maturidade. É importante frisar que esta é uma análise de dados brutos, não sendo levados em conta

27ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
8º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



informações como retrabalhos ou modificações, porém este parâmetro permite estimar com precisão o comportamento do sistema para os fins propostos neste trabalho.

A análise de dados revelou que 24 de 26 componentes mapeados seguem a distribuição de Weibull; outros três componentes como trilhos de portas e vidros estão sujeitos a uma distribuição uniforme.

Este fato já pode ser considerado uma transformação de dados em informação, após a análise de especialistas concluiu-se que a distribuição uniforme das falhas se deve ao fato de estes componentes estarem sujeitos a ações externas aleatórias, como o emperramento por corpos estranhos, no caso dos trilhos de porta; ou ações de vandalismo, no caso dos vidros; é uma informação que pode levar a decisões de investimento que evitem estas causas específicas, como o redesenho dos trilhos ou blindagem de vidros com películas antivandalismo por exemplo. Ressaltamos estes dois casos apenas para fins ilustrativos, a proposta é que o sistema processe a massa de dados sem a necessidade de análises de elevada complexidade como estas.

Os outros parâmetros que alimentam o sistema de suporte a decisão proposto são o nível das falhas (grave ou leve) que fornecem um indicativo da interferência que podem gerar no sistema, e o local onde ocorrem; a massa de dados fornece as probabilidades simples para estas ocorrências; e a avaliação destas probabilidades por especialistas estima o impacto operacional que estas ocorrências podem gerar. A análise também leva em conta informações de distribuição dos trens na operação comercial, representando probabilidades que não dependem do desempenho do equipamento,

mas são características de demandas de transporte do sistema, como a quantidade de trens por faixas horárias e dias da semana.

3. ANÁLISE DOS RESULTADOS

Como resultado deste trabalho foi desenvolvido um modelo bayesiano para os componentes do sistema de portas dos trens da frota proposta. A função do modelo é processar dados de falha e transformar estes dados em informação úteis para a gestão do sistema metroferroviário. Na figura 14 representamos um modelo reduzido com apenas dois componentes para facilitar a análise.

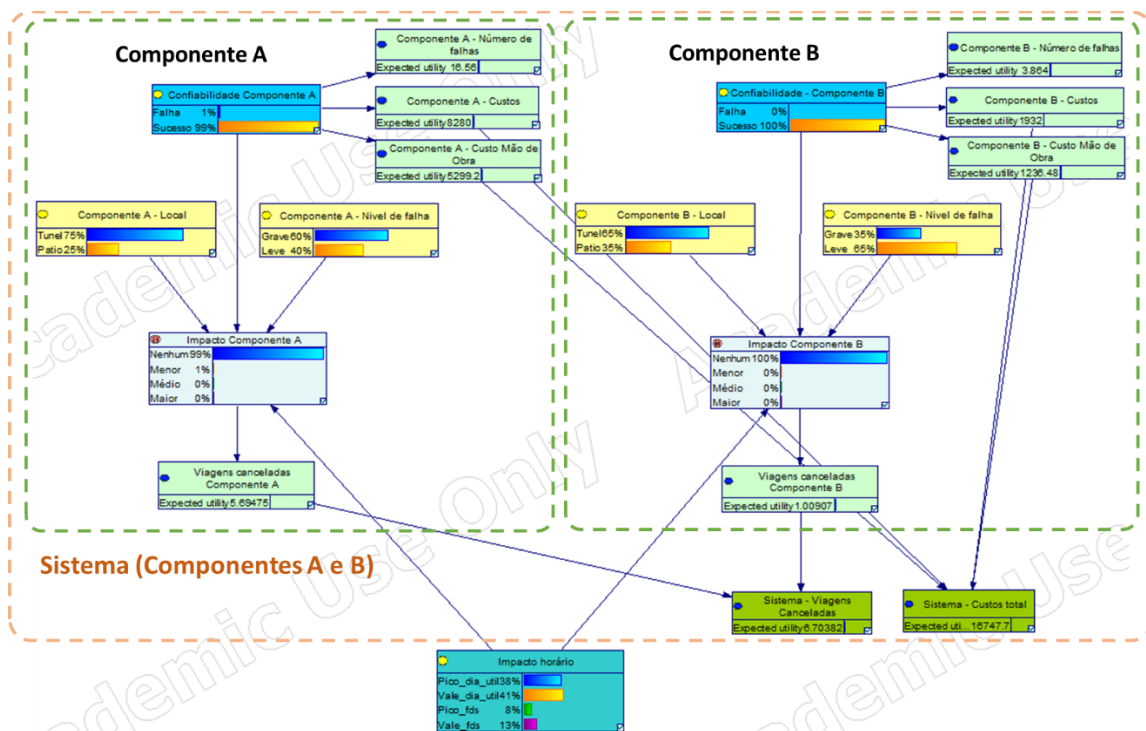


Figura 14 – Simplificação do modelo proposto

O modelo proposto possui nós para entrada de dados e nós que fornecem informações, identificamos estes nós na figura XX, que representa os nós de um componente do sistema modelado:

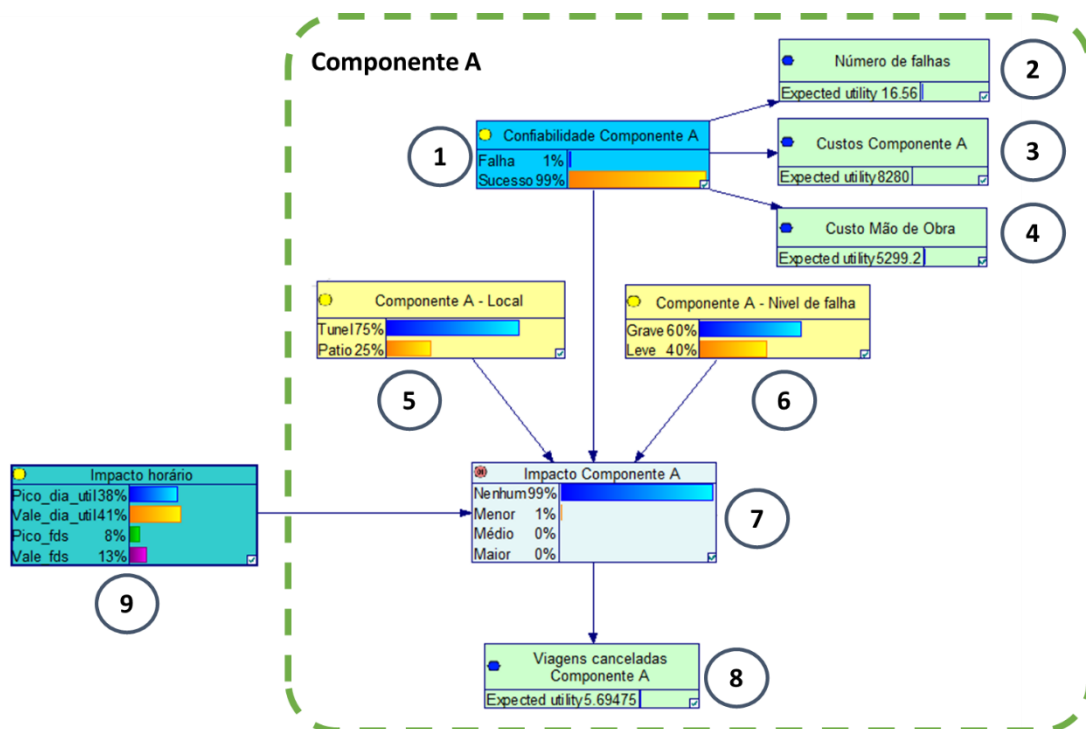


Figura 15 – Nós de entrada de dados e saída de informação

Nó (1) – Entrada de dados: Nó de confiabilidade do componente: representam a confiabilidade dos componentes em uma missão de um ano, são estimados através de distribuições de probabilidade.

Nó (2) – Informação: Nó de informação, fornece a estimativa do número de falhas esperada para a missão determinada no cálculo de confiabilidade.

Nó (3) - Informação: Nó de informação, fornece a estimativa dos custos de substituição dos componentes que apresentarão falhas.

27ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
8º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Nó (4) - Informação: Nó de informação, fornece a estimativa dos custos de mão de obra de manutenção para substituição de componentes defeituosos.

Nó (5) – Entrada de dados: Nó com a probabilidade de ocorrência da falha (ou detecção) na via comercial ou pátio, é estimada utilizando probabilidade clássica.

Nó (6) - Entrada de dados: Nó com a probabilidade da falha com impacto grave/leve na via comercial ou pátio, é estimada utilizando probabilidade clássica.

Nó (7) – Entrada de dados: Nós com probabilidades subjetivas obtidas a partir de opiniões de especialistas; representam a probabilidade de ocorrência da falha em determinado componente *dados determinados locais e gravidade*, causarem interferência na operação comercial.

Nó (8) - Informação: Nó de informação, fornece uma estimativa do número de viagens que serão canceladas devido a falhas no componente.

Nó (9) – Entrada de dados: Este nó representa a distribuição da circulação de trens por faixa horária, a missão é determinada em quilometragem percorrida portanto esta distribuição reflete a quantidade de falhas esperada para cada faixa horária; esta informação combinada com as probabilidades de falha compõem o cálculo da interferência operacional estimada.



Figura 16 – Nós de informação do sistema

Os nós 10 e 11 são nós de informação que concentram as informações dos componentes A e B que formam o sistema, o sistema completa possui nós que fornecem a informação de impactos e custos para a somatória de componentes do sistema modelado.

3.1. Entrada de dados e Informações de suporte a decisão

Na fase de construção do modelo a entrada de dados no sistema é feita manualmente, devendo ser automatizada posteriormente, através de softwares dedicados ou por meio do próprio software de modelagem, com isto o processo de análise do dados é automatizado com isso o sistema pode processar dados e fornecer informações em tempo real.

O sistema fornece quatro tipos diferentes de informação, abaixo exemplificamos como estas informações podem ser utilizados no suporte a decisão.

Componente A - Número de falhas Expected utility 16.56	2
Componente A - Custos Expected utility 8280	3
Componente A - Custo Mão de Obra Expected utility 5299.2	3
Viagens canceladas Componente A Expected utility 5.69475	8

Figura 17 – Informações fornecidas para cada componente do modelo

Nó (2) - Número de falhas: a informação de número de falhas de determinado componente pode ser utilizada na tomada de decisões de operação, manutenção ou engenharia; podem ser definidas medidas operacionais como novos procedimentos para atuação em falhas causadas pelo componente em estudo, a informação pode ser utilizada para o dimensionamento de equipes, ou como decisão de engenharia podem ser analisadas propostas para aumento de desempenho do componente. Como cada decisão tem um custo específico o gestor poderá utilizar a informação do número de falhas previsto para o suporte a decisão.

Nó (3) – Custos: fornece a informação do custo de substituição dos componentes; pode subsidiar a decisão por substituição ou modernização do componente, permitindo comparar o custo de manter o componente em operação e os investimentos para aumento de performance.

Nó (4) – Custos Mão de Obra: informa quanto determinado componente ou sistema consumirá em Hxh das equipes de manutenção, fornece suporte a decisões de dimensionamento de equipes, melhoria de procedimentos, e de forma análoga ao nó (2) também permite avaliar decisões de investimento na melhoria do sistema.

Nó (8) – Viagens canceladas: informa a quantidade de viagens (voltas de trem) que devem ser canceladas devido a interferência operacional prevista devido a falhas naquele componente, fornece a suporte para decisões de implantação de novos procedimentos ou estratégias operacionais.




Figura 18 – Nós 5 e 6 não são dedicados, porém também fornecem informações

Os nós (5) e (6), exibidos na figura 18, são nós de entrada de dados, porém mesmo não sendo dedicados também fornecem informações importantes para a operação do sistema, através dele é possível avaliar a dinâmica das falhas dos componentes, e também visualizar de forma facilitada detalhes como o local de ocorrência das falhas; durante o desenvolvimento deste trabalho a informação da distribuição por local de ocorrência permitiu visualizar oportunidades de diminuição dos impactos operacionais, ao adotar procedimentos que aumentem a detecção de falhas nos pátios e diminuindo o impacto operacional gerado.

3.2. Exemplo prático

Na figura 19 utilizamos valores hipotéticos para exemplificar o funcionamento da solução proposta:

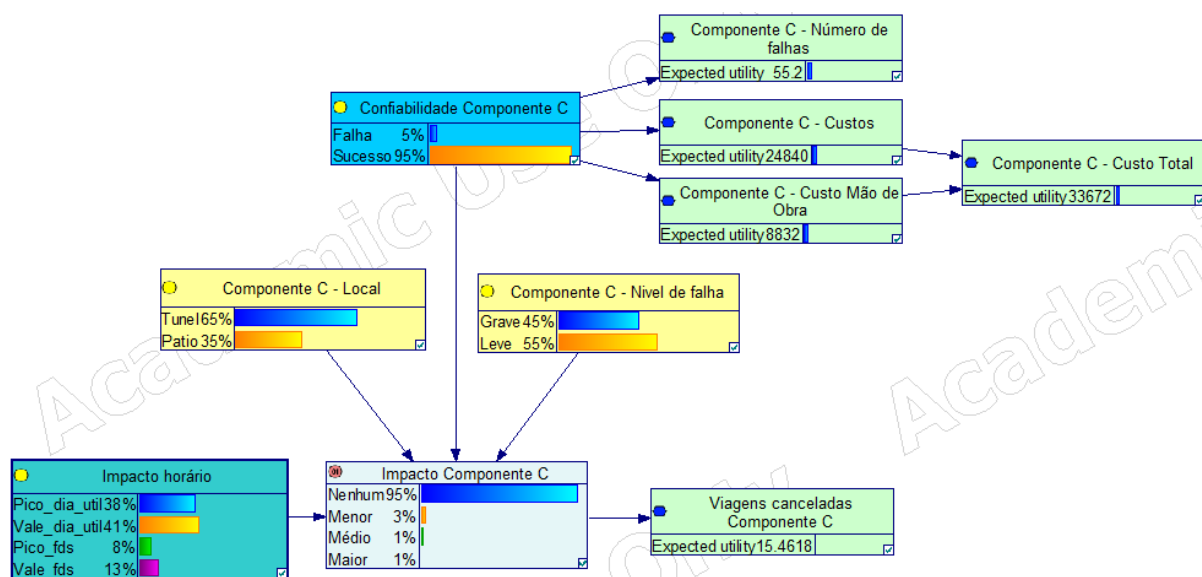


Figura 19 – Modelo alimentado com valores hipotéticos de confiabilidade

Na figura 19 consideremos o Componente C (hipotético), para fins de exemplo de funcionamento do modelo o alimentamos com as seguintes probabilidades:

Confiabilidade do componente C: 85% de chance de sucesso, 15% de chance de falha.

Componente C – Local: 65% de chance de a falha acontecer na via (túnel), 35% de chance de a falha acontecer no pátio de manutenção.

Componente C – Nível de falha: 45% de chance de o componente gerar uma falha grave, 55% de chance de provocar uma falha leve.

Impacto horário e Impacto do componente C: distribuição da circulação de trens por faixa horária e análise de especialistas para definir o impacto que pode ser gerado pela falha no componente, dados local e gravidade.

Como resultado o modelo gera algumas informações, para melhor entendimento adicionamos mais um nó de informação ao modelo.

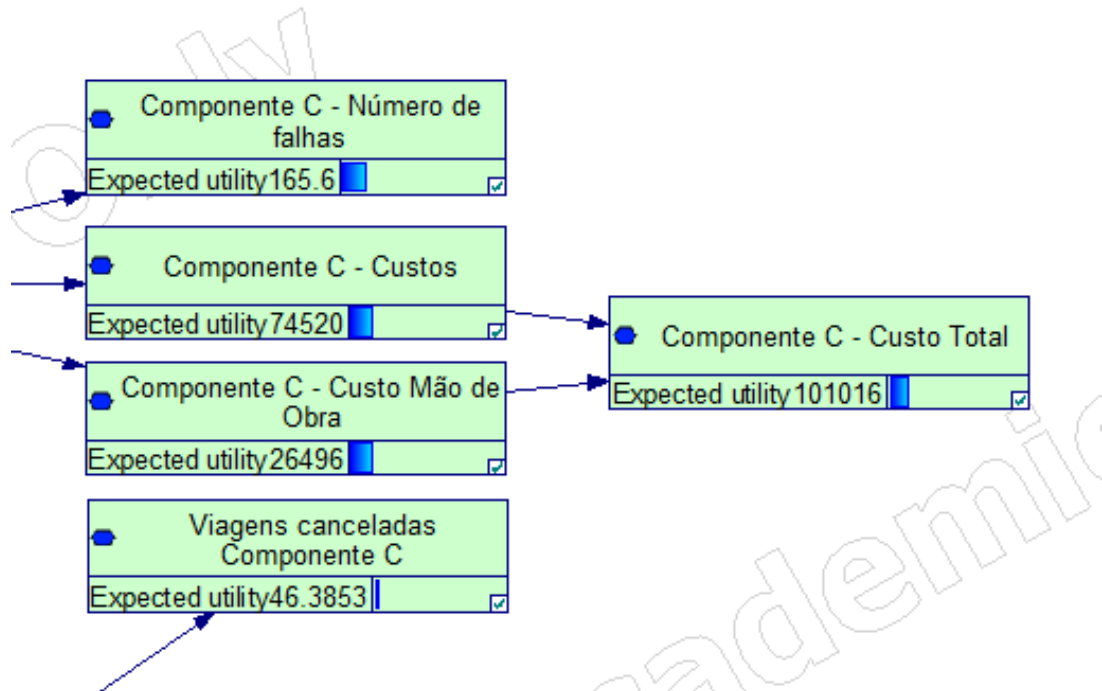


Figura 20 – Nós de informação

Para o exemplo proposto configuramos os nós de informação com valores hipotéticos para o componente e mão de obra; consideramos o custo de R\$ 450,00 para aquisição do componente a ser substituído, e duas horas de trabalho de uma mão de obra com custo total de R\$ 80, incluindo encargos, para a substituição do componente defeituoso. O sistema retornou as seguintes informações:

27ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
8º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Número de falhas: para o valor hipotético de confiabilidade considerado para o componente, este deve apresentar 165 falhas ao longo de um ano de operação; frisamos novamente que são valores hipotéticos para fins de demonstração do modelo.

Custos: o componente deve gerar custos de R\$ 74,5 mil, na aquisição de componentes para substituição dos defeituosos.

Custo da mão de obra: a mão de obra exigida para manter o componente deve gerar R\$ 26,5 mil em custos.

Custo total: o componente deve gerar cerca de R\$ 101 mil em custos de substituição de componentes e mão de obra.

Viagens canceladas: as falhas neste componente devem gerar o cancelamento de cerca de 46 viagens de trem na operação do sistema.

Neste exemplo usamos propositalmente valores hipotéticos exagerados, que representariam um componente já em sua fase senil (fim da vida útil), com o intuito de mostrar de forma clara o funcionamento do sistema de suporte a decisão.

As informações de custos podem ser comparadas com outros custos de mitigação do problema, abaixo seguem alguns exemplos:

Tabela 1 - Soluções propostas

Solução proposta	Investimento	Melhoria de desempenho
Melhorar lubrificação	R\$ 10 mil	Redução de 5% nas falhas
Modernização	R\$ 130 mil	Redução de 10% nas falhas
Novos Procedimentos operacionais	R\$ 30 mil	Redução de 25% nas falhas ocorridas na via

O modelo também pode ser utilizado para avaliar as soluções propostas, na figura 20 vemos o modelo que considera a opção de modernização do componente, e os respectivos impactos no número de falhas, custos e interferências operacionais:

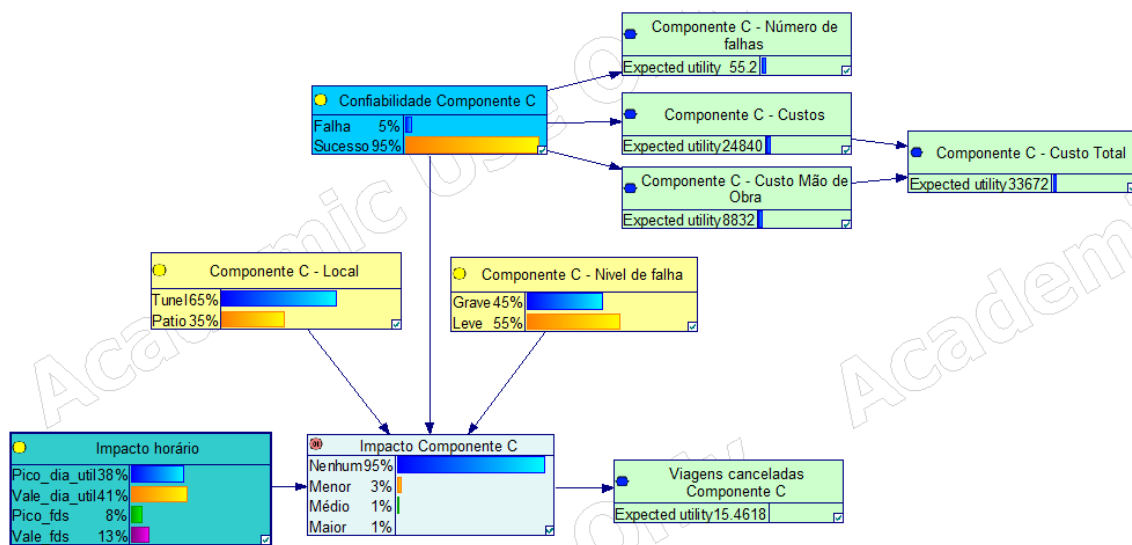


Figura 20 – Modelo considerando a solução de Modernização do componente

Ao alimentar o modelo com as melhorias de desempenho de cada solução é possível avaliar os impactos esperados de cada uma.

Tabela 2 – Ganhos de desempenho esperados

Solução	Nº de Falhas	Custos Totais (R\$ mil)	Interferências operacionais (viagens canceladas)
Situação atual	165	100,1	46
Lubrificação	110 (-33%)	67,3 (-33%)	30,9 (-32%)
Modernização	55 (-66%)	33,6 (-66%)	15,4 (-67%)
Novos Procedimentos operacionais	165 (N/A)	100,1 (N/A)	11,2 (-75%)

Na tabela 2 são exibidos os ganhos em diminuição de custos e melhoria de qualidade operacional percebida (redução do número de viagens canceladas) prevista para cada solução proposta, de posse destas informações o gestor pode tomar a decisão de investimento, visando melhoria de qualidade ou redução de custos (ou ambas). O modelo também permite avaliar o impacto de diferentes ações sobre o sistema, e avaliar o compromisso entre custo e benefício das soluções de forma prática e flexível.

4. CONCLUSÕES

O modelo proposto foi avaliado como diferentes períodos de dados, apresentando uma precisão entre 80% e 95% na previsão do número de falhas. As informações de impacto operacional possuem uma precisão entre 70% e 80%, um valor satisfatório dado que é uma informação baseada em probabilidades subjetivas. A alimentação automática dos dados permite que o modelo analise dados em tempo real, fornecendo informações relativas a custos de manutenção e impacto operacional, cumprindo o objetivo inicial do trabalho.

No início do trabalho não estava previsto que o sistema forneceria outras informações valiosas, como a visualização da distribuição de falhas por local de ocorrência, isto permitiu verificar que outros fatores não diretamente ligados ao equipamento também poderiam influenciar nas interferências operacionais geradas no sistema, uma grata surpresa durante o desenvolvimento do trabalho.

4.1. Trabalhos futuros

Como trabalhos futuros existe a oportunidade de utilizar as distribuições de probabilidade no tratamento de outros dados que alimentam o sistema, espera-se que isto melhore ainda mais o desempenho das previsões. Também se apresenta a oportunidade de alimentar o modelo matemático com outros dados dos componentes do sistema, como medições de vibração ou medições contínuas dos esforços elétricos e mecânicos aplicados nos sistemas em estudo, é uma proposta um pouco mais complexa, mas que permitiria o desenvolvimento de modelos mais avançados, similares a gêmeos digitais, podendo modelar individualmente cada componente, fornecendo um monitoramento preditivo dos equipamentos e suportando a manutenção baseada em condição de componentes.

REFERÊNCIAS BIBLIOGRÁFICAS

FILHO, Valentino Bergamo. Confiabilidade básica e prática. 1.ed. Rio de Janeiro: Editora Edgard Blücher Ltda, 2003

STONE, J. Bayes' Rule: A Tutorial Introduction to Bayesian Analysis. DOI:10.13140/2.1.1371.6801. Sebtel Press, 2013

STEFANINI, Claudio & Cruz; Rodrigo & Piratelli, M. BUSINESS INTELLIGENCE (BI): Um estudo exploratório sobre o uso do BI visando alcançar vantagem competitiva. DOI:10.5748/9CONTECSI2012/RF-594. 9th International Conference on Information Systems and Technology Management, 2012

Definição de IA, TOTUS. Disponível em: <<https://www.totvs.com/blog/inovacoes/o-que-e-inteligencia-artificial/>> Acesso em 15 de jun. de 2021

CHWIF, L.; Pereira, W. ESPECIFICAÇÃO DO MODELO CONCEITUAL EM SIMULAÇÃO DE EVENTOS DISCRETOS: APLICAÇÃO EM UM CASO REAL. XXX ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. São Carlos, 2010

FOGLIATTO, Flávio Sanson; Duarte, José Luis Ribeiro. Confiabilidade e manutenção. 3.ed. Rio de Janeiro. Elsevier, 2009

CASTILLO et al. Bayesian Networks-Based Probabilistic Safety Analysis for Railway Lines. Computer-Aided Civil and Infrastructure Engineering, 31, pg 193 a 218. Department of Applied Mathematics and Computational Sciences, University of Cantabria, 39005 Santander. Spain, 2016.

27ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
8º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



CASTILLO, Calvino & Grande. A Markovian–Bayesian Network for Risk Analysis of High Speed and Conventional Railway Lines. Integrating Human Errors. Computer-Aided Civil and Infrastructure Engineering, 31, pg 681 a 700. Department of Applied Mathematics and Computational Sciences, University of Cantabria, 39005 Santander. Spain, 2016.

CHEMWENO et al. Risk assessment methodologies in maintenance decision making: A review of dependability modelling approaches. Reliability Engineering and System Safety, 173, pg 64 a 77. Center for Industrial Management, KU Leuven, Celestijnenlaan 300A, BE-3001 Heverlee. Belgium, 2018.

BOLSTAD, Willian M., Curran, James M., Introduction to Bayesian Statistics, 3.ed. John Wiley & Sons, Inc., Hoboken, New Jersey, 2017

BUSSAB, Pedro Alberto M.; Bussab, Wilton O.; Estatística Básica, 6. ed. São Paulo, Editora Saraiva, 2010.

MOORE, S. David; Notz, I. William. Statistics: Concepts and Controversies. 7.ed. New York, W. H. Freeman and Company, 2009

LUDERMIR, Teresa B., Valença, Cristine B., Valença, Ivna; Modelos híbridos baseados em redes neurais, lógica fuzzy e busca para previsão de séries temporais, Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Pernambuco, Recife, 2010

LOPES, F. J. A; EULER E AS PONTES DE KÖNIGSBERG. Revista Brasileira de História da Matemática, [S. l.], v. 15, n. 30, p. 23-32, 2020. DOI: 10.47976/RBHM2015v15n3023-32