

Construção de um modelo de simulação integrada com ontologias para Manutenção Prescritiva

Mariana Teixeira Rosalin da Silva¹, Henrique Costa Marques²

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

Resumo – Este artigo fornece estudos para apoio a criação de frameworks de manutenção prescritiva abordando a dificuldade encontrada pela falta de dados formalizados que dificulta a aplicação de conjuntos de regras e a execução de medidas de manutenção baseadas em dados. A falta de estruturação adequada dos dados torna difícil o desenvolvimento de abordagens automatizadas e eficientes para solucionar problemas de manutenção.

Uma solução adotada é a utilização de abordagens semânticas, por meio de ontologias. Ao modelar o domínio em um nível conceitual, as ontologias permitem estabelecer relações e lógica de decisão para conduzir soluções de manutenção prescritivas de forma automatizada. Essa abordagem fornece uma estrutura coerente e consistente para os dados, facilitando a sua compreensão e manipulação. A utilização de ontologias possibilita uma representação formal dos dados, permitindo a criação de frameworks mais eficientes para a manutenção prescritiva.

O uso de uma solução de integração de um modelo de simulação com ontologia de modo simultâneo traria ganhos significativos a comunidade acadêmica, pois é possível obter benefícios em termos de compreensão aprofundada dos dados, automação das medidas de manutenção prescritiva e eficiência na criação de frameworks para solucionar problemas de manutenção.

Palavras-Chave – Ontologia, Simulação, Manutenção 4.0

I. INTRODUÇÃO

A revolução da Indústria 4.0 (I4.0) traz um grande potencial para aumentar a eficiência das atividades de manutenção através da automação dos processos de planejamento, que são tradicionalmente realizados por humanos. No entanto, a manutenção prescritiva, apesar de suas vantagens, enfrenta desafios adicionais quando se trata de replanejamento em tempo real. Isso é devido a falhas inesperadas em sistemas, a falta de sensores, a ausência de uma curva de degradação conhecida ou a necessidade de um tratamento especial para o componente quando ocorre uma falha [9].

A manutenção prescritiva é uma forma avançada de manutenção preventiva que envolve o conhecimento antecipado das causas da degradação do sistema, das tarefas necessárias para a manutenção e dos recursos a serem utilizados [1]-[2]. Ser capaz de identificar o motivo, o momento ideal, e como ter um controle completo do sistema, otimizando processos, estabelecendo indicadores e gerando listas de tarefas e pedidos de recursos com antecedência, para evitar paradas não planejadas até o momento ideal.

Tal capacidade de fazer uso de automação de sistemas de apoio à decisão e trazer o conhecimento do especialista de planejamento para um sistema informatizado constitui tarefa de interesse deste artigo. O presente trabalho fornece um experimento com o uso de ontologias de operações, RAMS (*reliability, availability, maintainability, and safety*) e manutenção integrada em um modelo de simulação baseado em eventos discretos para coletar dados relevantes do sistema, como o tempo médio entre falhas, o tempo médio de reparo, o

tempo médio de espera na fila de manutenção, entre outros indicadores de desempenho. Esses dados podem ajudar a avaliar o desempenho do sistema de manutenção e identificar oportunidades de melhoria, bem como o apoio à decisão para planejamento de tarefas de manutenção, sendo peça fundamental para que a manutenção prescritiva seja desenvolvida. A partir do estabelecimento de um estudo de caso do setor aeronáutico ontologias são definidas e buscas semânticas realizadas na base de dados de conhecimento, mostrando o potencial do estabelecimento das relações entre os conceitos e regras que norteiam as buscas e permitam extrair da base de dados os elementos chave a constituírem um plano de manutenção prescritivo.

O artigo está estruturado da seguinte maneira. A Seção 2 descreve a contextualização do problema da manutenção, a Seção 3 detalha a proposta da solução e o uso de ontologias com SPARQL cuja documentação consta em [20], a Seção 4 retrata a discussão dos resultados encontrados e como pode ser usada em diversos contextos. A Seção 5 traz a conclusão e trabalhos futuros.

II. CONTEXTUALIZAÇÃO FRAMEWORKS DE MANUTENÇÃO

Os *frameworks* para manutenção prescritiva são conjuntos de diretrizes, abordagens e metodologias utilizadas para implementar estratégias de manutenção preditiva, que visam prever falhas em equipamentos ou sistemas antes que elas ocorram e tomar medidas corretivas adequadas.

Esses *frameworks* geralmente envolvem os seguintes componentes:

- Monitoramento - coleta contínua de dados e informações sobre o desempenho dos equipamentos, utilizando sensores, sistemas de monitoramento remoto ou outras tecnologias;
- Análise de dados - aplicação de técnicas analíticas e algoritmos avançados para extrair informações relevantes dos dados coletados, identificando padrões, anomalias e tendências;
- Modelagem e previsão - construção de modelos preditivos com base nos dados coletados, que permitem prever o comportamento futuro dos equipamentos e identificar possíveis falhas ou problemas iminentes;
- Diagnóstico - interpretação dos resultados da análise de dados e modelos preditivos para identificar a causa raiz das falhas potenciais e determinar ações corretivas adequadas; e
- Recomendações de manutenção - com base nas informações obtidas, os *frameworks* para manutenção prescritiva fornecem recomendações precisas e específicas sobre as medidas de manutenção a serem tomadas, como substituição de peças, reparos ou intervenções preventivas.

Esses arcabouços computacionais são aplicados em diversos setores, como indústria, manufatura, energia, transporte e saúde, permitindo otimizar a disponibilidade, confiabilidade e eficiência dos equipamentos, além de reduzir custos operacionais e evitar paradas não planejadas.

Como cada sistema possui características próprias não há uma solução algorítmica para a prescrição que seja apta a solucionar todos os tipos de degradação de ativos. Portanto, há que se desenvolver uma solução que seja adaptável a diversos contextos. Desta forma, os *frameworks* para manutenção prescritiva precisam ser dinâmicos e adaptativos, ou seja, é necessário construir uma solução para modularização desses *frameworks* para torná-los holísticos e serem capazes de resolver problemas de vários tipos de demandas para os diferentes ativos e recursos disponíveis ou a serem alocados, usando uma mesma classe de algoritmos para diferentes frotas e diferentes sistemas complexos.

Consequentemente, é necessário tornar esses frameworks parametrizáveis para que atenda diversos contextos, seja um ambiente de linha de produção de aeronaves, gerenciamento de manutenção de aeronaves comerciais ou até mesmo uma linha de produção automotiva. Modularizar *frameworks* é garantir uma ampla aplicabilidade da abordagem proposta para diversos contextos da indústria [3].

De acordo com [10]-[11], este problema já está apontado na literatura em ambos os *frameworks* de manutenção prescritiva cuja aplicação é restrita, reforçando a necessidade em criar um modelo que permita se tornarem mais genéricos em suas aplicações.

III. PROPOSTA DA SOLUÇÃO

Dentre as diversas formas de se buscar a dinamicidade dos arcabouços para suporte à manutenção prescritiva este trabalho procura obter a adaptação aos diversos contextos a partir da descrição via ontologias de domínio. Os arcabouços procuram definir algoritmos de otimização que recebem parâmetros dos ativos e da capacidade de manutenção que uma determinada organização possui. Ao termos diferentes níveis de maturidade de máquinas, diferentes modelos de operação e diferentes estruturas de manutenção fica claro que tais algoritmos não conseguem se adaptar de maneira fácil.

A proposta de solução constrói o contexto via ontologias e permite que o algoritmo seja usado em mais de um contexto ao extrair as informações e trabalhá-las de forma a enviar corretamente cada parâmetro à interface de entrada. Este trabalho, no entanto, não entrará no detalhe de um algoritmo de otimização, permanecendo na esfera da descrição do contexto fazendo uso da captura dos dados via simulação por evento discreto. Desta forma, será proposto uma sombra digital para elucidar a forma como a ontologia é usada para a geração dos parâmetros de operação de um cenário e é enviada a um simulador que irá exemplificar a operação de diversas máquinas em diferentes contextos, permitindo que um futuro algoritmo de otimização faça uso dos eventos gerados e possa promover uma maior eficiência na alocação de recursos humanos e materiais no agendamento de tarefas de manutenção.

A. Ontologia para definição do Contexto (SPMontology)

O uso de ontologias é fundamental para que se obtenha modelos otimizados, com regras, mapeamento do domínio do objeto de estudo e os conceitos de interesse. Neste caso, o principal problema enfrentado pelos *frameworks* desenvolvidos é fornecer os meios para passar da coexistência à interoperabilidade e cooperação de diferentes contextos dentro do mesmo ambiente. E de fato, diferentes pesquisadores [12]-[13]-[14]-[15] concordam que a engenharia de ontologias é reconhecida como a tecnologia chave para lidar com isso.

Para definição dos objetos, classes, atributos e relacionamentos das ontologias foram coletadas informações com base em uma companhia aérea da aviação comercial brasileira e de uma empresa de fabricação de aviões militares, comerciais e executivos. Também foram realizadas pesquisas e entrevistas com especialistas das áreas de manutenção e operações. Para elaboração da ontologia de RAMS foi baseada no estudo do modelo CRIS (OSA-EAI) especificado pelo MIMOSA (*Machinery Information Management Open Systems Alliance*) [16].

Na literatura podemos encontrar algumas aplicações no uso de ontologias para a melhoria da eficiência da manutenção. Os autores na referência [4] apresentam uma extensa revisão da literatura sobre as abordagens de web semântica e grafos de conhecimento para I4.0, versando sobre diferentes perspectivas como padronizações, manufatura, gestão de cadeia de fornecimento e manutenção preditiva. O modelo generalizado de ontologia apresentado em [4] tem como base a arquitetura de referência RAMI4.0 para I4.0 e explora os conceitos e relações entre áreas da fabricação e manutenção como data/hora, localização, sensoramento, equipamentos, produtos, processos e instalações.

Também no domínio de manutenção na indústria em [5] foi desenvolvido um grafo de conhecimento de falhas, o SemKoRe. São modelados na ontologia os conceitos de Falhas e Máquina para auxiliar na manutenção e habilitar a resolução de falhas com base no histórico de falhas.

O trabalho deste artigo difere dos mencionados por estabelecer a aplicação ao domínio do hangar de manutenção 4.0 em conjunto com os eventos decorrentes da operação da frota, como falhas não planejadas e planejadas em um sistema de simulação para apoio à decisão. Nesta seção são descritas as três ontologias desenvolvidas no projeto: Operações, RAMS e Manutenção, apontadas no trabalho do framework descrito em [10]. Denominamos de *Smart Prescriptive Maintenance Ontology* (SPMO).

Cada ontologia contempla classes, subclasses, atributos e seus relacionamentos:

- Operações: Classificado com informações de atividades, possuem Init Date, End Date, Activity Time e Location Start e Location End;
 - RAMS: Classificado com informações de registro de ativos, condição, manutenção e informações de confiabilidade entre sistemas, possuem Agent, Segment, Asset, Health, Remaining Life, Event, Manufacturer, Model, Maintenance Plan, Work Request e Work Order;
- e

- **Manutenção:** Classificado com informações do hangar/oficinas de manutenção, equipe de manutenção e suprimentos, possuem Materials, Purchase Order, Inventory, Service Provider e Man Power Shift, Specialty e Man Power Available.

B. Implementando o modelo de simulação

Utilizando a modelagem de simulação baseada em eventos discretos, pretendemos avaliar e otimizar o desempenho de estratégias de manutenção, identificar gargalos, estimar tempos de parada e avaliar o impacto de diferentes políticas de manutenção em um ambiente controlado. Portanto, essa técnica permite uma melhor gestão da manutenção e ajuda a maximizar a disponibilidade e confiabilidade dos ativos [17]-[18].

Os componentes essenciais do modelo, foram especificadas conforme demonstrado na Tabela I. A modelagem de simulação baseada em eventos discretos é adequada para representar sistemas dinâmicos onde as mudanças ocorrem em momentos discretos no tempo. Nesse caso, cada evento seria uma mudança significativa no sistema, como a detecção de uma falha em uma peça, o início de uma manutenção programada ou a chegada de uma aeronave à fila de manutenção. Ao utilizar essa abordagem, é possível modelar cada componente/ativo da aeronave, como as peças individuais, os sistemas, os subsistemas e a aeronave como um todo.

A quantidade de horas de voo/tempo de atividade é simulada através do avanço do tempo na simulação, considerando a taxa de uso da aeronave ou máquina. A detecção de falhas nas peças é modelada com base em probabilidades ou distribuições estatísticas que representam a taxa de falhas esperada para cada peça/ativo.

As paradas para manutenção programada são agendadas com base em intervalos de tempo pré-determinados ou em critérios específicos, como um número mínimo de horas de voo alcançadas. A fila de manutenção do hangar é modelado como uma estrutura de dados que registra as aeronaves que aguardam atendimento e a ordem de capacidade para a realização da manutenção, podendo ser distribuído em mais de um hangar conforme o parâmetro informado para o simulador.

TABELA I – PARÂMETROS DE ENTRADA PARA SIMULAÇÃO

Entidade	Atributo	Valor (Exemplo)
Operações	Trecho de Voo / Etapas de fabricação (Voos / Fabricação)	40 trechos de voos diários / 7 processos por operação
	Quantidade de Segmentos (Aeronaves / Máquinas)	30
RAMS	Ativo (Peça / Equipamento)	ENGINE CFM56 / Fresadora CNC Fooke
	Agendador de Tarefas (Eventos de Falhas)	Sobrecarga do motor / Interrupção da máquina
	Agendador de Tarefas (Tarefas de Manutenção Programada)	Inspeções das válvulas / Inspeção de Ferramentas de Corte
Manutenção	Disponibilidade de Recursos (Slots / Mão de obra)	3

Podemos observar na Tabela I que as entradas podem ser parametrizadas para os diferentes cenários propostos neste trabalho.

É importante ressaltar que a modelagem de simulação permite a adaptação do modelo às características específicas do sistema de manutenção de ativos que se deseje simular.

C. Integração entre o modelo de simulação e as ontologias com SPARQL (SPMontology.API)

Para integração das ontologias ao simulador foi necessária a criação de uma API (Application Programming Interface) capaz de realizar a troca de informações em tempo real. Para o servidor foi escolhido o Apache Jena Fuseki [19] que é um servidor SPARQL que permite consultar ontologias RDF (Resource Description Framework) usando a linguagem de consulta SPARQL [20]. A consulta é capaz de extrair informações como instâncias, relacionamentos, propriedades e outros itens de interesse. Fornece um ambiente de servidor para armazenar e consultar grafos RDF, permitindo a execução de consultas, updates, inserções e deleções em várias ontologias, através de um conjunto de dados previamente configurado, arquitetura exibida na Fig. 1.

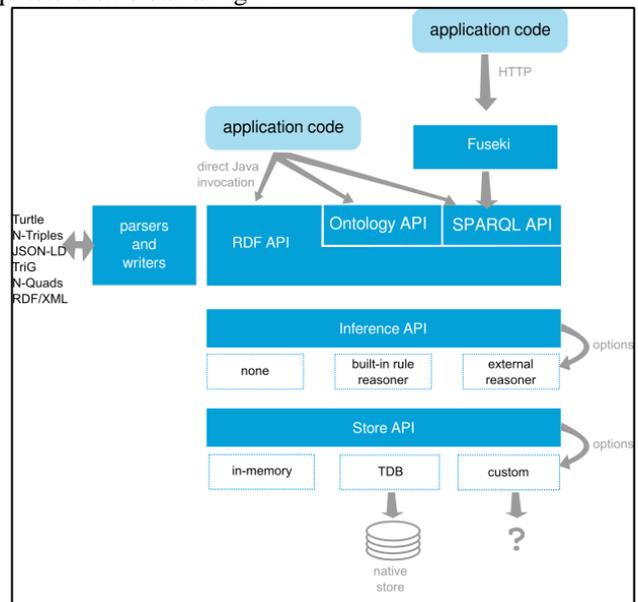


Fig. 1. Jena Architecture Overview. Fonte: [21].

D. O Simulador (SPMSimulator)

Após especificado o modelo de simulação, a criação do modelo ontológico e os métodos da API de integração os componentes foram incorporados a uma ferramenta de simulação desenvolvida em .NET C#, chamada SPMSimulator, para que possa receber os parâmetros de entrada para simulação de dois estudos de casos de diferentes contextos:

- Hangar de manutenção de linha
- Linha de produção de aeronaves

A ferramenta de simulação foi preparada para testar o funcionamento da estrutura ontológica através de *reasoner* (mecanismo de inferência) as regras especificadas na ontologia (SPMO), e processar os resultados de tempo de falha, tempo de reparo e tempo de disponibilidade dos ativos de cada segmento (aeronave ou máquina) da operação, alterando em tempo real o estado atual do segmento conforme as paradas de manutenção seja por falhas e/ou programação planejada e tempo de espera na fila. Dessa forma, será capaz de registrar eventos e prover insumos da condição dos ativos para suportar

a gestão da manutenção. A Fig. 2 mostra a simulação de um cenário de operação de voo com 30 aeronaves ou segmentos simultaneamente, que sofrem panes de forma aleatória caracterizando as paradas para manutenção em um hangar de manutenção de linha, onde no centro é exposto o modelo de simulação implementado para este cenário de interesse, no qual as entidades percorrem durante simulação, as tabelas na parte inferior representam os dados carregados das ontologias e na parte superior os comandos de parametrização do simulador.

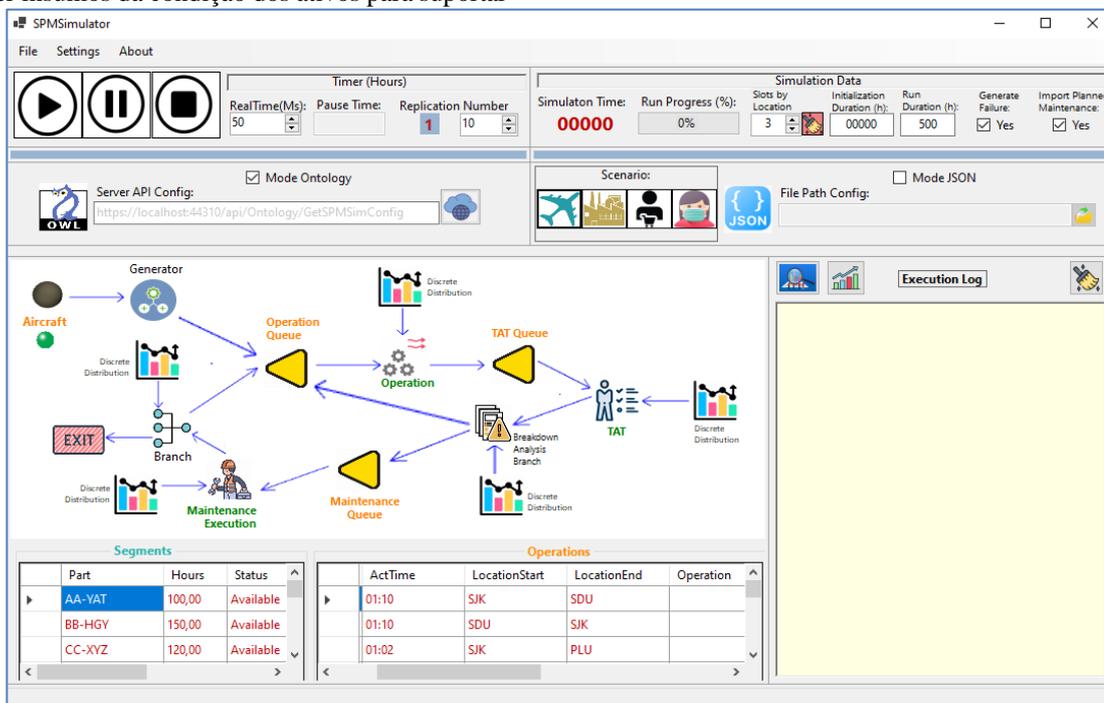


Fig. 2. Interface do SPMSimulator simulando hangar de manutenção de linha. Fonte: O autor

IV. RESULTADOS E DISCUSSÕES

Nesta seção avaliamos o potencial das ontologias criadas com propósito de inferir conhecimentos dos principais requisitos de manutenção que precisam ser atendidos pelos mantenedores para a frota de aeronaves.

A preparação de dados e análise da ontologia contou com a utilização do sistema Protégé [6] da universidade de Stanford. Para as consultas foram utilizados a linguagem SPARQL [20] desenvolvido pelo W3C (World Wide Web Consortium) e baseada na especificação OWL 2 de Manchester com exemplos de aplicação em [7]-[8].

Por meio das simulações é possível obter o tempo médio entre falhas, o tempo médio de reparo, o tempo médio de espera na fila de manutenção, tempo de inatividade da aeronave até o retorno a operação, usando como base informações disponíveis das ontologias para alimentar o modelo de simulação.

Também é possível atualizar as ontologias de acordo com os resultados obtidos durante a simulação, neste trabalho demonstramos o status das aeronaves exibindo em um painel conforme Fig. 2.

Além disso, foi possível obter através das consultas SPARQL, requisitos como os dados de operação da malha aérea (vide Tabela II), o histórico de eventos de falhas (vide

Tabela III), as próximas manutenções preventivas, previstas pelos fabricantes das aeronaves (vide Tabela IV), que servem de insumo para a execução da simulação.

TABELA II – DADOS DA MALHA DE VOO POR AERONAVE

Activity Time	Location Start	Location End	Date Time Start	Date Time End	Segment
02:45	AJU	GRU	22/05/2024 15:25	22/05/2024 18:10	PP-LAT
01:45	BSB	VCP	22/05/2024 20:40	22/05/2024 22:25	PR-AZL
01:35	VCP	BSB	22/05/2024 13:10	22/05/2024 14:45	PR-AZL
01:10	FLN	CGH	22/05/2024 12:05	22/05/2024 13:15	PP-GGY

TABELA III – HISTÓRICO DE EVENTOS DE FALHAS DOS ATIVOS

Asset Name	Segment	Event Type	Event Start	Event Description	MTR
Honeywell GTCP36-100 APU	PP-GGY	Failure Effects	23/05/2024 13:11	Superaquecimento	2 hours
ENGINE CFM56	PP-LAT	Abnormal Situation	23/05/2024 17:47	Sobrecarga no Motor	10 hours

TABELA IV – MANUTENÇÕES PREVISTAS PARA O MODELO DA AERONAVE

Asset Name	Unit Type	Execution Time	Segment	Task	MTTR
ENGINE CFM56	Hours	24	PP-LAT	Inspeções das válvulas	2 hours
Honeywe II APU	Hours	32	PP-GGY	Substituição de filtros	3 hours

Pode-se observar que esta abordagem habilita a junção de informações entre os conceitos de operações e requisitos da manutenção e em uma única consulta. Possibilitando a

obtenção de outros indicadores capazes de orientar a tomada de decisões estratégicas, melhorar a alocação de recursos, planejar manutenções preventivas e reduzir custos operacionais.

Outro ganho observado foi que mesmo alterando os dados da ontologia de hangar de manutenção aeronáutica para uma linha de produção que usa máquinas em sua operação e outros tipos de ativos, foi possível simular e obter os mesmos indicadores para o novo cenário, confirmando a interoperabilidade proposta, conforme demonstrado na Fig.4.

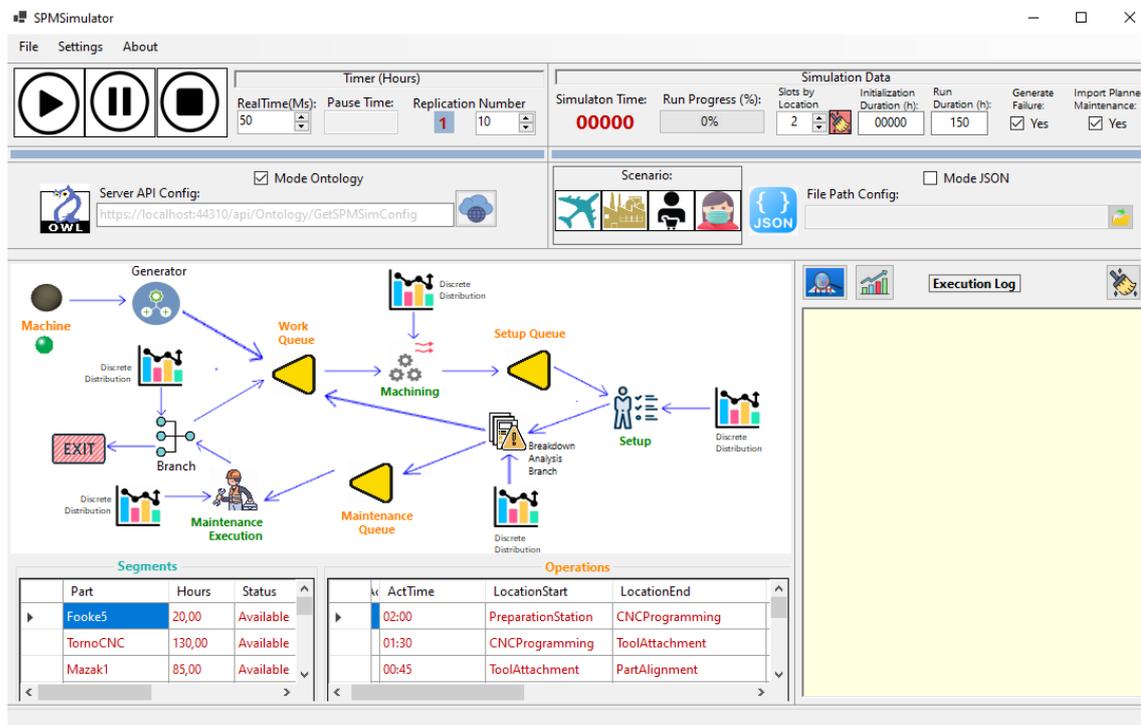


Fig. 4. Simulação usando ontologia para uma linha de produção. Fonte: O autor

Para a simulação com o SPMO carregado de dados de uma linha de produção as consultas SPARQL retornaram as informações de tempo de ciclo das máquinas (vide Tabela VI), o histórico de eventos de falhas (vide Tabela VII), as próximas manutenções preventivas das máquinas (vide Tabela VIII), que servem de insumo para a execução da simulação.

TABELA VI – DADOS DO TEMPO DE CICLO DAS MÁQUINAS

Activity Time	Location Start	Location End	Date Time Start	Date Time End	Segment
70:00	PreparationStation	CNC Programming	02/05/2024 06:00	02/05/2024 04:00	Fooke5
40:00	Part Alignment	Rough Machining	02/05/2024 06:00	02/05/2024 22:00	Haas ST

TABELA VII – HISTÓRICO DE EVENTOS DE FALHAS DAS MÁQUINAS

Asset Name	Segment	Event Type	Event Start	Event Description	MTTR
Torno CNC Haas ST-20Y	Haas ST	Failure Effects	03/05/2024 10:42	Superaquecimento	10 hours

Fresadora CNC Fooke	Fooke5	Failure Mode	04/05/2024 15:22	Problemas com o sistema de refrigeração	4 hours
---------------------	--------	--------------	------------------	---	---------

TABELA VIII – MANUTENÇÕES PREVENTIVAS DAS MÁQUINAS

Asset Name	Unit Type	Execution Time	Segment	Task	MTTR
Fresadora CNC Fooke de 5 eixos	Hours	32	Haas ST	Lubrificação	3 hours

V. CONCLUSÃO

Com a estruturação das ontologias propostas foi possível realizar a representação do conhecimento e realizar inferência entre os elementos de domínios diferentes. Somando-se ao uso de consultas SPARQL em simulações por eventos discretos haverá diversos benefícios, como:

- **Interoperabilidade:** As ontologias proporcionam uma representação padronizada e semântica dos conceitos e relações no domínio da Manutenção 4.0. Facilitando a interoperabilidade entre sistemas e aplicações, permitindo que diferentes fontes de dados e ferramentas sejam integradas de forma mais eficiente.
- **Padronização de dados:** As ontologias fornecem uma estrutura comum para modelar e organizar os dados relevantes da simulação. Isso ajuda a padronizar a representação dos dados, garantindo a consistência e a reutilização em diferentes contextos. Com a padronização de dados, é mais fácil realizar análises comparativas e obter ideias consistentes a partir das simulações;
- **Consultas avançadas:** O uso de consultas SPARQL permite realizar consultas complexas e flexíveis nos dados modelados pela ontologia. Permitindo recuperar informações específicas, fazer agregações, filtrar dados e realizar inferências sobre as relações entre os conceitos.
- **Descoberta de conhecimento:** As ontologias e consultas SPARQL permitem explorar o conhecimento contido nos dados da simulação. Por meio de inferências e relações semânticas definidas na ontologia, é possível descobrir novos padrões, identificar relações ocultas e fazer análises mais sofisticadas. Contribuindo a tomada de decisão na Manutenção 4.0; e
- **Flexibilidade e escalabilidade:** O uso de ontologias e consultas SPARQL oferece flexibilidade e escalabilidade às simulações por eventos discretos. A ontologia pode ser expandida e atualizada conforme novos conceitos e relações surgem no contexto da Manutenção 4.0.

Em resumo, essas vantagens contribuem para uma análise mais aprofundada e eficaz dos resultados da simulação, fornecendo ideias valiosas para aprimorar as operações de manutenção e tomadas de decisão no contexto da Manutenção 4.0. A ontologia pode ser usada por ferramentas automatizadas para melhorar os serviços avançados como buscas na Web e gerenciamento de conhecimento, podendo ser expandida para outros contextos da indústria.

As ontologias propostas podem ser utilizadas para aplicações no hangar 4.0 em apoio à decisão de planejadores e gestores de manutenção.

Como trabalhos futuros podemos citar:

- Incluir novas ontologias relacionando diferentes contextos, por exemplo, na área de engenharia civil;
- Incluir novas regras, para abordar alocação de recursos e mão de obra disponível por especialidade; e
- Aprimorar o simulador para obter novos indicadores de saúde das aeronaves e ativos.
- Implementar coleta de dados em tempo real através de sensores para alimentar o modelo ontológico com dados reais.

- [1] H. C. Marques, F. T. M. Abrahão, and G. C. Rocha, Eds., “MRO 4.0: Mapping Challenges Through the ILS Approach,” in *Applications and Challenges of Maintenance and Safety Engineering in Industry 4.0.*, in *Advances in Civil and Industrial Engineering*. IGI Global, 2020, pp. 213–234. doi: 10.4018/978-1-7998-3904-0.ch012.
- [2] A. Giacotto, H. Costa Marques, E. A. Pereira Barreto, and A. Martinetti, “The Need for Ecosystem 4.0 to Support Maintenance 4.0: An Aviation Assembly Line Case,” *Appl. Sci.*, vol. 11, no. 8, p. 3333, Apr. 2021, doi: 10.3390/app11083333.
- [3] L. A. Hadidi, U. M. A. Turki, and A. Rahim, “Integrated models in production planning and scheduling, maintenance and quality: a review,” *Int. J. Ind. Syst. Eng.*, vol. 10, no. 1, p. 21, 2012, doi: 10.1504/IJISE.2012.044042.
- [4] M. Yahya, J. G. Breslin, and M. I. Ali, “Semantic Web and Knowledge Graphs for Industry 4.0,” *Appl. Sci.*, vol. 11, no. 11, p. 5110, May 2021, doi: 10.3390/app11115110.
- [5] H. Hossayni, I. Khan, M. Aazam, A. Taleghani-Isfahani, and N. Crespi, “SemKoRe: Improving Machine Maintenance in Industrial IoT with Semantic Knowledge Graphs,” *Appl. Sci.*, vol. 10, no. 18, Art. no. 18, Jan. 2020, doi: 10.3390/app10186325.
- [6] M. A. Musen, “The protégé project: a look back and a look forward,” *AI Matters*, vol. 1, no. 4, pp. 4–12, Jun. 2015, doi: 10.1145/2757001.2757003.
- [7] M. Horridge and P. F. Patel-Schneider, “OWL 2 Web Ontology Language Manchester Syntax (Second Edition),” W3C, p. 9, 2012.
- [8] M. Unni and K. Baskaran, “Ontology based Semantic Querying of the Web using Protégé,” *Int. J. Comput. Appl.*, vol. 56, no. 6, pp. 12–16, Oct. 2012, doi: 10.5120/8894-2915.
- [9] S. G. García and M. G. García, “Industry 4.0 implications in production and maintenance management: An overview,” *Procedia Manuf.*, vol. 41, pp. 415–422, 2019, doi: 10.1016/j.promfg.2019.09.027.
- [10] H. Marques and A. Giacotto, “Prescriptive Maintenance: Building Alternative Plans for Smart Operations,” presented at the The 10th Aerospace Technology Congress, October 8-9, 2019, Stockholm, Sweden, Oct. 2019, pp. 231–236. doi: 10.3384/ecp19162027.
- [11] K. Matyas, T. Nemeth, K. Kovacs, and R. Glawar, “A procedural approach for realizing prescriptive maintenance planning in manufacturing industries,” *CIRP Ann.*, vol. 66, no. 1, pp. 461–464, 2017, doi: 10.1016/j.cirp.2017.04.007.
- [12] Q. Z. Yang and Y. Zhang, “Semantic interoperability in building design: Methods and tools,” *Comput.-Aided Des.*, vol. 38, no. 10, pp. 1099–1112, Oct. 2006, doi: 10.1016/j.cad.2006.06.003.
- [13] R. Mizoguchi, “Tutorial on ontological engineering Part 2: Ontology development, tools and languages,” *New Gener. Comput.*, vol. 22, no. 1, pp. 61–96, Mar. 2004, doi: 10.1007/BF03037281.
- [14] M. E. V. Pickler, “Web Semântica: ontologias como ferramentas de representação do conhecimento,” *Perspect. Em Ciênc. Informação*, vol. 12, no. 1, pp. 65–83, Apr. 2007, doi: 10.1590/S1413-99362007000100006.
- [15] S. Heiler, “Semantic interoperability,” *ACM Comput. Surv.*, vol. 27, no. 2, pp. 271–273, Jun. 1995, doi: 10.1145/210376.210392.
- [16] OpenO&MTM, “What is MIMOSA?” Accessed: Jun. 01, 2023. [Online]. Available: <https://www.mimosa.org/>
- [17] B. K. Choi and D. Kang, *Modeling and Simulation of Discrete Event Systems*. Wiley, 2013.
- [18] CHWIF, L.; MEDINA, A.C., *Modelagem e Simulação de Eventos Discretos, Teoria & Aplicações*, 3. ed. São Paulo: Ed. dos Autores, 2010.
- [19] J. J. Carroll, I. Dickinson, C. Dollin, D. Reynolds, A. Seabome, and K. Wilkinson, “Jena: implementing the semantic web recommendations,” in *Proceedings of the 13th international World Wide Web conference on Alternate track papers & posters - WWW Alt. '04*, New York, NY, USA: ACM Press, 2004, p. 74. doi: 10.1145/1013367.1013381.
- [20] Harris S. G., Seabome A., “SPARQL 1.1 Query Language.” <https://www.w3.org/TR/2013/REC-sparql11-query-20130321/> (accessed Jun. 30, 2023).
- [21] Apache Software Foundation. Apache Jena., 2021. Disponível em: <https://jena.apache.org/>>. Acesso em: 21 jun. 2023