



ConBREpro

XV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Estudo de Caso: Gêmeo Digital de Molde de Vulcanização de Pneus

Diego Nascimento Faury

Estudante do Bacharelado em Ciência e Tecnologia – Universidade Federal do ABC

Ugo Ibusuki

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas - Universidade Federal do ABC

Erik Gustavo del Conte

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas - Universidade Federal do ABC

Resumo: Este relatório apresenta um estudo de caso sobre a aplicação do Gêmeo Digital em moldes de vulcanização de pneus, com foco na melhoria da manutenção preditiva e redução de custos produtivos. A proposta inclui uma arquitetura em camadas composta por data analytics, simulação, fábrica digital e serviços em nuvem, integrando sensores e algoritmos de aprendizado de máquina para monitorar variáveis críticas em tempo real. O estudo, realizado em parceria com uma fabricante de pneus do Grande ABC, busca demonstrar a viabilidade técnica da solução para prever falhas, otimizar a vida útil dos moldes e aumentar a eficiência do processo.

Palavras-chave: Gêmeo Digital, Vulcanização de Pneus, Manutenção preditiva, Data Analytics, Fábrica Digital.

Case Study: Digital Twin of Tire Vulcanization Mold

Abstract: This report presents a case study on the application of the Digital Twin in tire vulcanization molds, focusing on improving predictive maintenance and reducing production costs. The proposal includes a layered architecture composed of data analytics, simulation, digital factory, and cloud services, integrating sensors and machine learning algorithms to monitor critical variables in real time. The study, conducted in partnership with a tire manufacturer from the Greater ABC region, aims to demonstrate the technical feasibility of the solution to predict failures, optimize mold lifespan, and increase process efficiency.

Keywords: Digital Twin, Tire Vulcanization, Predictive Maintenance, Data Analytics, Digital Factory.

1. Introdução

Diante dos desafios estratégicos enfrentados pela indústria automotiva nacional, em especial os elevados custos associados ao uso de moldes importados para a vulcanização de pneus e o aumento das importações de pneus prontos, este relatório alinha-se ao programa Mover (Mobilidade Verde e Inovação) com o propósito de fortalecer a cadeia produtiva por meio de inovação tecnológica e práticas sustentáveis. Ao mesmo tempo em que busca assegurar a qualidade final dos pneus e impulsionar o mercado nacional, a proposta apresentada visa reduzir custos produtivos e aumentar a competitividade da indústria, focando em soluções que integrem monitoramento contínuo e ações proativas de manutenção. Esse enquadramento responde à crescente demanda por desempenho e

durabilidade dos produtos (FERREIRA, 2018) e ao imperativo de tornar os processos industriais mais eficientes e ambientalmente responsáveis.

Como ferramenta central para alcançar esses objetivos, propõe-se a adoção do Gêmeo Digital aplicado aos moldes de vulcanização. Nesta abordagem, o Gêmeo Digital atua como um suporte à manutenção preditiva, permitindo o monitoramento em tempo real de variáveis críticas do processo (temperatura, pressão, tensões mecânicas, estado superficial, entre outras) e a integração desses dados a modelos analíticos e de simulação. A capacidade de transformar medições contínuas em diagnósticos e recomendações operacionais possibilita intervenções programadas antes da ocorrência de falhas, reduzindo retrabalhos, paradas não planejadas e desperdícios de material, impactos diretamente relacionados à eficiência econômica e ambiental da planta. Nesse sentido, justifica-se a realização deste estudo pelo potencial de reduzir a dependência de moldes importados, otimizar recursos produtivos e alinhar a manufatura nacional às práticas emergentes de sustentabilidade e inovação digital.

O conceito de Gêmeo Digital, formalizado inicialmente por Grieves (2003) e amadurecido nas décadas subsequentes, refere-se a uma réplica virtual de um ativo físico que é continuamente alimentada por dados operacionais, permitindo simular cenários futuros e suportar decisões operacionais e estratégicas. Essa réplica bidirecional conecta o mundo físico e o virtual, recebendo sinais por meio de sensores e, quando apropriado, enviando comandos ou ajustes ao equipamento. Conforme apontado por Parrott e Warshaw (2017), gêmeos digitais capacitam organizações a “experimentar o futuro” por meio de simulações hipotéticas, antecipando falhas e aumentando tanto a eficiência quanto a segurança das operações. No contexto mais amplo da Indústria 4.0, e em discussão com os princípios emergentes associados à Indústria 5.0, a abordagem está alinhada a metas de resiliência, economia circular e sustentabilidade, na medida em que promove monitoramento em tempo real e manutenção preditiva, evitando que o desgaste dos ativos se traduza em defeitos nos produtos finais (KARKARIA et al., 2024).

Este relatório apresenta um estudo de caso na indústria de pneus do Grande ABC, no qual se propõe um Gêmeo Digital para moldes de vulcanização e se define uma arquitetura integrada composta por módulos de data analytics, simulação, fábrica digital e serviços em nuvem. A proposta fundamenta-se em referências contemporâneas sobre gêmeos digitais e em técnicas de aprendizado de máquina aplicadas à manutenção preditiva, além de incorporar a análise das falhas e dos problemas específicos dos moldes que motivaram o estudo. Nos capítulos seguintes descrevem-se a metodologia adotada, os procedimentos de coleta de dados e modelagem, a arquitetura técnica sugerida e as potenciais implicações operacionais e ambientais da adoção do Gêmeo Digital, atendendo tanto o rigor técnico quanto à relevância prática para a cadeia produtiva local. Assim, o objetivo deste estudo é desenvolver e avaliar uma proposta de Gêmeo Digital aplicada aos moldes de vulcanização de pneus, demonstrando sua viabilidade técnica para manutenção preditiva e otimização da vida útil dos moldes.

2. Referencial Teórico

2.1 Conceito de Gêmeo Digital

Um gêmeo digital é uma representação virtual precisa de um ativo físico único, que reflete suas características, condições e comportamento ao longo de todo o seu ciclo de vida (GRIEVES, 2014). Essa réplica conecta de forma bidirecional os mundos físico e virtual, recebendo dados em tempo real por meio de sensores instalados no equipamento e, simultaneamente, enviando comandos e ajustes que podem influenciar diretamente o ativo físico. A abordagem contemporânea o define como um sistema ciberfísico dinâmico, fortemente integrado aos conceitos de Indústria 4.0 e Indústria 5.0.

Por meio da coleta massiva de dados e do uso de ferramentas avançadas de análise, o gêmeo digital viabiliza o monitoramento de condições operacionais, o diagnóstico de falhas, a previsão de defeitos e a prescrição automatizada de ações corretivas. Essa capacidade se torna ainda mais relevante pela possibilidade de realizar simulações e testes virtuais em tempo real, o que permite a experimentação sem necessidade de interromper a produção (ABISSET-CHAVANNE et al., 2024). Em síntese, o gêmeo digital se consolida como uma plataforma sólida para análise e otimização da manufatura orientada por dados, possibilitando o acompanhamento contínuo do desempenho dos ativos, a antecipação de falhas e a adaptação dos processos com base em evidências operacionais.

3. Metodologia

3.1 Materiais e Métodos

Este artigo adota uma abordagem qualitativa e aplicada, configurando-se como um estudo de caso exploratório realizado em parceria com uma fabricante de pneus do Grande ABC, vinculada ao projeto Tire-Tooling Benchmark. A metodologia foi estruturada em quatro etapas: revisão bibliográfica, elaboração de formulários, coleta de respostas junto à equipe técnica e descrição sistemática do processo.

A fase inicial consistiu em um levantamento bibliográfico sobre o processo de vulcanização de pneus e os procedimentos técnicos relacionados ao manuseio e manutenção de moldes. As buscas foram realizadas em bases como Google Acadêmico e Semantic Scholar, priorizando publicações recentes e diretamente ligadas ao setor de ferramentaria para embasar a análise.

Na sequência, foram elaborados dois formulários direcionados à equipe técnica da empresa parceira, compostos por questões abertas e fechadas. O primeiro buscou mapear os principais problemas enfrentados durante a instalação e uso dos moldes, enquanto o segundo teve como objetivo validar e quantificar os achados iniciais. A amostra contemplou supervisores com experiência prática, possibilitando captar tanto aspectos técnicos quanto operacionais do processo.

Com base nas respostas obtidas, estruturou-se uma descrição detalhada das etapas de instalação e utilização dos moldes, articulada aos problemas mais recorrentes relatados pelos profissionais. Esse material foi consolidado em um guia técnico preliminar, que organiza os pontos críticos da instalação e destaca recomendações práticas para melhorar a durabilidade dos moldes e a eficiência da operação.

3.2 Etapas da Pesquisa

A primeira etapa consistiu na revisão bibliográfica, que reuniu trabalhos acadêmicos, artigos científicos e relatórios industriais sobre vulcanização e uso de moldes, fornecendo os parâmetros de referência para o estudo. A segunda etapa envolveu a elaboração e aplicação dos formulários junto à equipe técnica, permitindo compreender de forma estruturada as dificuldades enfrentadas e os problemas mais frequentes na rotina de instalação e manutenção. Na terceira etapa, os dados coletados foram analisados, organizando os problemas identificados em categorias como desgaste, falhas de vedação e ajustes de pressão e temperatura. Essa sistematização possibilitou identificar quais fatores têm maior impacto sobre o desempenho dos moldes.

Por fim, a quarta etapa reuniu os resultados da análise em um fluxo sequencial das atividades de instalação, desde a preparação do molde até os cuidados necessários para sua conservação ao longo do uso. Esse fluxo serviu de base para propor recomendações específicas que podem orientar treinamentos internos e padronizar procedimentos operacionais, reduzindo falhas recorrentes e aumentando a confiabilidade do processo de vulcanização.

4. Arquitetura de Solução: Data Analytics, Simulação e Nuvem

Esta seção apresenta a arquitetura de solução proposta para o gêmeo digital dos moldes de vulcanização, dividida em três camadas complementares: Data Analytics, Simulação e Serviços em Nuvem. Cada subseção detalha os componentes principais, desde os sensores e bancos de dados utilizados para coleta e tratamento de sinais até as ferramentas de simulação avançada e a infraestrutura em nuvem que garante coleta, processamento e visualização de dados em tempo real. Com esse arranjo, busca-se conectar de forma natural o mundo físico ao virtual, antecipando problemas no molde, ajustando parâmetros de operação e viabilizando ações de manutenção preditiva antes que ocorra qualquer interrupção no processo.

4.1 Data Analytics

Nesta etapa, capturam-se em tempo real grandezas críticas do processo de vulcanização (temperatura, pressão, tensões mecânicas, fluxo de resfriamento e características de superfície) por meio de sensores especializados. Os sinais são filtrados, organizados em séries temporais e armazenados em banco de dados otimizado, servindo de base para algoritmos preditivos que antecipam a formação de rebarbas e a progressão de corrosão.

- a) Sensor de temperatura por resistência (RTD): instalado em pontos críticos do molde para medir temperatura e evitar superaquecimento localizado, alimentando modelos preditivos de desgaste térmico;
- b) Sensor de pressão hidráulica: registra a pressão de fechamento da prensa, detectando picos que geram rebarba e auxiliando no ajuste de limites operacionais;
- c) Transdutor de deformação (strain gauge): monitora tensões mecânicas no molde, identificando esforços excessivos capazes de causar fissuras ou desvio de perfil;
- d) Câmera de visão tridimensional: captura imagens de rugosidade e rebarbas a cada ciclo, fornecendo dados para algoritmos de visão computacional que identificam defeitos superficiais;
- e) Concentrador de dados IoT com protocolo MQTT: coleta sinais dos sensores e os transmite ao servidor por meio do protocolo de mensagens MQTT (Message Queuing Telemetry Transport), que garante comunicação rápida e confiável com baixa latência. Os dados são então processados em Python, tanto em streaming (tempo real) quanto em batch (modo acumulado), alimentando os modelos preditivos;
- f) Banco de dados de séries temporais: armazena registros históricos otimizados para consultas por janela de tempo, suportando re-treinamento incremental de modelos de previsão.

4.2 Simulação

Constrói-se um modelo virtual do molde e do material de borracha utilizando técnicas de Inteligência Artificial para simular o comportamento térmico e mecânico do sistema. A abordagem permite a execução de simulações acopladas de transferência de calor e análise estrutural, avaliando perfis de temperatura e tensões a cada ciclo. Em seguida, modelos substitutos baseados em aprendizado de máquina reproduzem esses resultados com baixa latência, possibilitando testar virtualmente diferentes ajustes de cura e pressão de fechamento antes da aplicação no processo real.

- a) Modelo CAD/CAE: corresponde à construção digital tridimensional do molde e da borracha utilizada no processo, realizada em softwares de engenharia. Essa representação serve de base para as simulações térmicas e mecânicas, permitindo avaliar virtualmente o comportamento do sistema antes da aplicação prática;

- b) Simulação térmica transiente: análise da distribuição de temperatura ao longo do tempo durante os ciclos de vulcanização. Essa simulação identifica regiões do molde sujeitas a aquecimento excessivo e auxilia na definição de estratégias de resfriamento mais eficientes;
- c) Simulação estrutural estática: avaliação das tensões mecânicas que ocorrem no fechamento da prensa. Seu objetivo é prever áreas do molde onde podem surgir deformações, trincas ou formação de rebarbas, devido ao esforço repetido durante o processo produtivo;
- d) Modelo substituto (surrogate model): rede neural treinada para replicar os resultados das simulações térmicas e estruturais com alta velocidade. Funciona como uma “versão acelerada” do simulador tradicional, permitindo testes quase instantâneos com base nos dados operacionais reais;
- e) Orquestração em Python + interface de requisições web (API RESTful): automação do fluxo de dados entre o ambiente físico e o ambiente de simulação. Os parâmetros coletados no chão de fábrica são enviados automaticamente ao simulador, e os resultados retornam integrados ao gêmeo digital, permitindo ajustes rápidos no processo.

4.3 Serviços em Nuvem

Implementa-se uma infraestrutura de Internet das Coisas (IoT) baseada em MQTT e plataforma na nuvem para coleta e armazenamento de dados, complementada por funções sem servidor que realizam pré-processamento e detecção de anomalias em tempo real. Dashboards interativos fornecem visualização de indicadores de desgaste, e interfaces de programação (API RESTful) viabilizam a emissão remota de comandos ao equipamento, promovendo intervenções corretivas imediatas.

- a) Plataforma de Internet das Coisas (IoT) com protocolo MQTT: recebe dados dos sensores de forma contínua e eficiente, garantindo estabilidade e rapidez mesmo em ambientes industriais. O protocolo MQTT permite comunicação leve e confiável entre os dispositivos e os servidores;
- b) Funções sem servidor (serverless): executam automaticamente o pré-processamento dos dados e identificam falhas em tempo real, sem necessidade de servidores fixos. Adaptam-se conforme a quantidade de dados recebidos;
- c) Banco de dados de séries temporais em nuvem: armazena dados organizados por ordem de tempo, facilitando consultas rápidas e análises de tendências sobre o desempenho e desgaste dos moldes;
- d) Ambiente de contêineres com orquestração: executa modelos preditivos em módulos isolados que podem ser atualizados ou multiplicados conforme a demanda, garantindo eficiência e segurança nas simulações;
- e) Painel web de monitoramento: apresenta gráficos e alertas personalizáveis sobre o estado dos moldes e riscos de falha, auxiliando a equipe na tomada de decisões rápidas e embasadas;
- f) Interface web de comandos (em Python): permite que o sistema envie ordens automáticas ao equipamento, como ajustar a temperatura ou pausar o ciclo, integrando análise de dados com ações práticas no chão de fábrica.

5. Estudo de Caso: Gêmeo Digital dos Moldes de Vulcanização

Na indústria de pneus do ABC Paulista, identificou-se que o principal fator de degradação dos moldes de vulcanização é a formação de rebarbas e a corrosão superficial, resultante de procedimentos de limpeza e falta de manutenção preventiva. Por exemplo, a aplicação incorreta de jato de gelo seco (demasiado próxima ou omissiva em pontos críticos)

intensifica o ataque químico, criando degraus e rebarbas no molde. Tais imperfeições são transferidas às carcaças dos pneus, prejudicando sua vida útil. Além disso, a ausência de periodicidade fixa para o retratamento cromado (normalmente feito após falhas críticas, cerca de 13.000 ciclos) acelera a degradação. Variações errôneas de temperatura e pressão durante a vulcanização também podem causar deformações e redução das propriedades elásticas do produto final. Esses problemas resultam em desempenho inferior e maior risco de falhas na operação. Diante desse cenário, o gêmeo digital dos moldes surge como ferramenta de monitoramento avançado para antecipar o desgaste e otimizar a manutenção.

Nesta seção, inspirada em abordagens recentes da literatura (Aheleroff et al., 2021; Karkaria et al., 2024; Tota et al., 2023), detalha-se como cada etapa da arquitetura (capítulo 4.1) é empregada na prática para criar um ciclo contínuo de coleta de dados, simulação e ação corretiva. O objetivo é transformar medições e simulações em intervenções práticas antes que ocorram falhas.

5.1 Coleta e Modelagem

a) Leitura de sensores: sensores de temperatura (RTD), pressão hidráulica, deformação (strain gauge) e câmeras 3D capturam dados em cada ciclo e os enviam pelo concentrador IoT via MQTT (4.1.e);

b) Pré processamento e balanceamento: funções sem servidor limpam os dados de ruído e outliers e aplicam SMOTE (Synthetic Minority Oversampling Technique), recurso que cria exemplos sintéticos para equilibrar a raridade de casos de falha crítica, evitando viés na modelagem (4.3.b);

c) Cálculo do Indicador de Desgaste do Molde (IDM): um modelo de Random Forest gera o IDM, indicador numérico que reflete o nível instantâneo de desgaste do molde, combinando todas as variáveis tratadas;

d) Armazenamento: todos os dados brutos, pré processados e os valores de IDM são gravados no banco de séries temporais (4.1.f), garantindo histórico completo e suporte a retraining incremental dos modelos.

5.2 Simulação e Previsão

a) Simulações físicas: os valores de temperatura e pressão medidos são enviados ao software CAD/CAE (4.2.a) por meio de uma interface Python + API (4.2.e). Executam-se simulações de transferência de calor (4.2.b) e análise estrutural estática (4.2.c) que produzem mapas de temperatura e tensões detalhados para o ciclo atual;

b) Modelo substituto (surrogate model): rede neural treinada para imitar os resultados das simulações físicas em milissegundos, permitindo obter rapidamente estimativas de calor e stress sem rodar o solver completo (4.2.d);

c) Projeção de desgaste com TFT: usa-se o modelo preditivo Temporal Fusion Transformer, capaz de capturar dependências temporais complexas e múltiplas fontes de incerteza, para projetar a evolução do IDM ao longo dos próximos ciclos (4.3.d);

d) Cálculo do Remaining Mold Potential (RMP): com base na projeção do IDM, define-se o RMP como a margem de vida útil remanescente antes do comprometimento do molde. Esse indicador orienta o momento ideal para intervenção e é usado para acionar alertas (4.3.d).

5.3 Automação e Ação


a) Detecção de anomalias: funções sem servidor monitoram IDM e RMP em tempo real, disparando alertas automáticos no painel de monitoramento (4.3.b, 4.3.e);

- b) Comandos corretivos: ao identificar risco iminente (RMP abaixo do limiar), a interface Python emite ordens ao concentrador IoT (4.3.f), como reduzir setpoint de temperatura ou pausar o ciclo, evitando deterioração adicional;
- c) Manutenção preditiva: com base na curva de degradação projetada pelo TFT e no valor de RMP, o sistema agenda automaticamente retratamentos cromados ou inspeções antes que ocorram falhas críticas;
- d) Retroalimentação contínua: após cada intervenção, novos valores de IDM e RMP são incorporados ao banco de séries temporais (4.1.f), refinando o treinamento do TFT e do modelo substituto, consolidando o ciclo de melhoria constante.

Com essa metodologia, o gêmeo digital passa a oferecer visibilidade contínua sobre o estado dos moldes, transformando dados brutos em decisões operacionais. A combinação de coleta em tempo real, simulações práticas e automação de intervenções permite não apenas reduzir paradas não planejadas, mas também estender a vida útil dos moldes e elevar a qualidade final dos pneus.

A Figura 1 apresenta o processo de instalação dos sensores e integração de dados para a criação do gêmeo digital do molde.

Figura 1 – Processo de instalação do gêmeo digital do molde



Fonte: Elaboração própria (2025)

6. Conclusões

A adoção do gêmeo digital, conforme descrito, oferece benefícios práticos relevantes. Primeiramente, possibilita a previsão antecipada de defeitos superficiais. Graças à integração de sensores dimensionais, de deformação e de rugosidade com o modelo virtual, será possível estimar o RMP e antecipar o surgimento de degraus e rebarbas antes que comprometam o produto. A geração de intervalos de confiança pelo TFT permite definir margens de segurança operacional, reduzindo o risco de produção de pneus fora de especificação e garantindo maior consistência na qualidade.

Em segundo lugar, espera-se viabilizar o agendamento proativo da manutenção, substituindo a lógica corretiva. Por meio dos dashboards interativos e das simulações online, que projetam a degradação do molde sob diferentes regimes produtivos, as equipes poderão programar intervenções no momento ideal, com base no valor do IDM e no RMP, reduzindo custos com paradas não planejadas, retrabalhos e desperdícios de material. Além disso, a arquitetura em nuvem e o processamento sem servidor permitem escalar esse serviço de forma flexível, abrindo caminho para um modelo de Gêmeo Digital em que o fabricante dos moldes oferece monitoramento contínuo, relatórios de vida útil e suporte preditivo como diferencial competitivo.

Este estudo indica que a aplicação de gêmeos digitais em moldes de vulcanização, com base em uma arquitetura estruturada de data analytics e computação em nuvem, representa uma oportunidade relevante para aprimorar a gestão de manutenção nesse setor. A literatura aponta que, ao integrar IoT, aprendizado de máquina e modelos virtuais conectados, torna-se possível monitorar o estado dos moldes, antecipar desgastes e planejar intervenções com maior precisão. Modelos do tipo transformer, pré-treinados e

atualizados continuamente, vêm se mostrando superiores às arquiteturas tradicionais de séries temporais, oferecendo maior fidelidade e confiabilidade nas estimativas.

A arquitetura proposta, estruturada em camadas física, digital e cibernética, garante que os dados coletados sejam organizados e analisados de forma a otimizar o processo produtivo. Os resultados do estudo indicam o potencial técnico e os possíveis benefícios da aplicação de gêmeos digitais na indústria de pneus, contribuindo com uma base conceitual que pode orientar futuras implementações alinhadas à manufatura inteligente no Brasil. Embora o foco deste relatório seja os moldes de vulcanização, a abordagem pode ser adaptada a outros contextos industriais que demandem manutenção preditiva.

Apesar dos resultados promissores, é necessário reconhecer algumas limitações da proposta. Entre eles estão dependência da qualidade dos sensores, risco de falsos positivos em detecção de anomalias e deriva dos modelos ao longo do tempo. Para mitigar esses riscos recomenda-se implantar redundância sensorial crítica, políticas claras de governança e qualidade dos dados, ciclos regulares de re-treinamento e validação humana como etapa de verificação antes de ações automáticas. Aspectos de interoperabilidade e segurança cibernética devem ser planejados desde a concepção para viabilizar escalabilidade e proteger ativos e informações sensíveis.

Por fim, recomenda-se validar o gêmeo digital em uma planta piloto, de modo a testar sua aplicabilidade em condições reais de operação. Nessa etapa, devem ser medidos indicadores de parada e consumo, além de conduzida uma análise de custo-benefício para estimar o retorno sobre o investimento. Também se sugere explorar modelos cognitivos capazes de gerar recomendações automáticas, ampliando o potencial preditivo e de suporte à decisão. O avanço dessas iniciativas poderá consolidar práticas inovadoras e sustentáveis, alinhadas ao programa Mover e à busca pela excelência operacional no setor automotivo brasileiro.

Referências

ABISSET-CHAVANNE, E.; COUPAYE, T.; GOLRA, F.; LAMY, D.; PIEL, A.; SCART, O.; VICAT-BLANC, P. A Digital Twin use cases classification and definition framework based on Industrial feedback. 2024.

AHELEROFF, S.; XU, X.; ZHONG, R.; LU, Y. Digital twin as a service (DTaaS) in Industry 4.0: an architecture reference model. 2021.

ANWER, N.; STARK, R.; TAO, F.; ERKOYUNCU, J. Developing and leveraging digital twins in engineering design. 2025.

BERGS, T.; BIERMANN, D.; ERKORKMAZ, K.; M'SAOUBI, R. Digital twins for cutting processes. 2023.

FERREIRA, A. Integração e melhoria de processos na vulcanização de pneus. v. 3, p. 13-27, 2018.

GRIEVES, M. Digital Twin: Manufacturing Excellence through Virtual Factory Replication. Orlando, mar. 2014.

JIN, L.; ZHAI, X.; WANG, K.; ZHANG, K.; WU, D.; NAZIR, A.; JIANG, J.; LIAO, W. Big data, machine learning, and digital twin assisted additive manufacturing: a review. 2024.

KARKARIA, V.; CHEN, J.; LUEY, C.; SIUTA, C.; LIM, D.; RADULESCU, R.; CHEN, W. A Digital Twin Framework Utilizing Machine Learning for Robust Predictive Maintenance: Enhancing Tire Health Monitoring. 2024.

PARROTT, A.; WARSHAW, L. Industry 4.0 and the digital twin. Deloitte University Press, 2017.

D'AMICO, R.; ERKOYUNCU, J.; ADDEPALLI, S.; PENVER, S. Cognitive digital twin: An approach to improve the maintenance management. 2022.

TOTA, R.; FACCHINI, F.; IAVAGNILIO, R. P.; MOSSA, G.; SASSANELLI, C. Digital twin supporting environmental performance evaluation according to ISO certification: an application case in the tire industry. Production & Manufacturing Research, 2023.