



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:
Limitações e possibilidades**



ADOÇÃO DE *BIG DATA ANALYTICS* CONTRIBUI COM A ABORDAGEM DE *LEAN MANUFACTURING*

ROBSON MARINHO DE BRITO - robicello@gmail.com - Centro Universitário da
Fundação Educacional Inaciana “Padre Sabóia de Medeiros” – FEI

MARCOS GERALDO GOMES – mggomes1970@gmail.com – Centro Universitário da
Fundação Educacional Inaciana “Padre Sabóia de Medeiros” – FEI

GERALDO CARDOSO DE OLIVEIRA NETO – geraldo.prod@gmail.com –
Universidade Federal do ABC – UFABC

ÁREA: 1. *ENGENHARIA DE OPERAÇÕES E PROCESSOS DA PRODUÇÃO*
SUBÁREA: 1.1 - *GESTÃO DE SISTEMAS DE PRODUÇÃO E OPERAÇÕES*

RESUMO: Este estudo investiga as contribuições da aplicação do *Big Data Analytics* com o uso em *Python* para a abordagem *lean manufacturing*. O método usado foi aplicação de técnicas de estatística descritiva e multivariada em *Python* para analisar falhas em um *big data*, identificando padrões de falhas, como desgaste de ferramentas, problemas de dissipação de calor, falhas de energia, sobrecargas e falhas aleatórias. A conclusão do estudo destaca a necessidade de ferramentas de processamento de dados avançadas para lidar com a grande quantidade de dados gerados na produção. O uso de *Big Data Analytics* e *Python* mostrou-se uma ferramenta imprescindível para o gerenciamento eficaz de dados e criação de relatórios gerenciais, particularmente no contexto do *Lean Manufacturing*, considerando que a redução de desperdícios é fundamental. Constatou-se que os sensores instalados nos equipamentos permitiram monitorar e prever falhas em tempo real, demonstrando a eficácia dessas tecnologias. A integração e automação de estratégias de *Big Data Analytics* com *Inteligência Artificial* contribuem para o controle da cadeia produtiva, melhorando os resultados econômicos obtidos na produção.

PALAVRAS-CHAVES: *Big Data Analytics*; Estatística Descritiva; Análise Multivariada; *Lean Manufacturing*.

1. INTRODUÇÃO

O Lean Manufacturing é um dos sistemas de produção mais conhecidos no mundo. É o sucesso japonês obtido em sua utilização que fez com que esse modelo fosse transmitido e adaptado para diversos países, incluindo o Brasil. Esse modelo revolucionou a forma de organizar o trabalho, levando o Japão ao ranking das principais economias mundiais (BÉNDEK, 2016).

A absorção do sistema Lean Manufacturing por parte das empresas ocorreu devido aos problemas que estas encontravam em seu processo produtivo. Para ganhar competitividade frente aos seus concorrentes, as empresas buscavam reduzir custos, melhorar a qualidade de seu produto e fazer crescer sua produtividade, sem nunca deixar de atender às necessidades de seus consumidores (DOS SANTOS et al, 2021).

A busca por uma melhor maneira de gerenciar a manufatura é antiga. Nos anos 70, com a indústria americana em situação vulnerável e o Japão colocando vários produtos no mercado a um preço mais competitivo, estudiosos americanos começaram a entender que esse sucesso vinha do modelo de fabricação japonesa, e não somente pelo seu baixo custo de produção, mas especialmente devido a sua pouca incidência de defeitos, grande confiabilidade e durabilidade (HAYES et al, 1996). Esse modelo ficou conhecido como Lean Manufacturing ou Toyota Production System (DOS SANTOS et al, 2021).

Apesar dos diversos estudos realizados sobre o Lean Manufacturing, a tecnologia evolui constantemente, o que significa que novas ferramentas e aplicações continuam surgindo. Neste contexto, surge a Quarta Revolução Industrial, denominada Indústria 4.0, com novas propostas de integração da metodologia Lean com ferramentas como o Big Data Analytics e Inteligência Artificial, sendo este um assunto estudado e aplicado em diversas pesquisas acadêmicas e profissionais.

Um dos principais objetivos da Indústria 4.0 é alcançar uma melhor eficiência em sua cadeia de valor através de inovações no processo de fabricação (BEN-DAYA et al, 2019). Assim, o benefício proposto pela 4ª revolução industrial pode ser maior, já que os lucros podem ser maximizados devido ao seu formato flexível e customizável (SCHMIDT et al., 2015). Isso ocorre principalmente pelo motivo de que a Indústria 4.0 visa ser um mecanismo inteligente para a manufatura, apoiada pela utilização massiva de dados para a indústria. Outro exemplo é a utilização de sensores e Inteligência Artificial (IA), onde diversas máquinas e equipamentos podem atingir autonomamente e aprender por si mesmas (*machine*

learning) com o objetivo de aperfeiçoar a manufatura, através do controle em tempo real de sua produção e dos produtos manufaturados (JAVAID et al., 2021; VAIDYA et al., 2018).

Esse desenvolvimento se deve à possibilidade de instalação de sensores no maquinário da fábrica. Esses sensores, pequenos dispositivos que detectam estímulos de entrada na máquina e respondem a um sinal que pode ser medido podem ser utilizados para monitorar o desempenho e prevenir falhar de máquinas e equipamentos, proporcionando melhor produtividade e confiabilidade (JAVAID et al., 2021).

Com a implementação de sensores nas máquinas, uma grande quantidade de dados é gerada. Assim, meios de administrar esses dados devem ser empregados. Neste ponto, o Big Data Analytics surge como solução para esse gerenciamento, pois é utilizada para coletar, examinar e analisar grandes bancos de dados com o objetivo de ajudar as empresas na percepção de tendências, padrões e comportamentos (COURSERA, 2022). Já o Big Data está ligado a uma grande quantidade de dados que são difíceis de analisar devido à sua variabilidade e complexidade (LAVALLE et al., 2010).

Atualmente, uma das principais ferramentas utilizadas para essa análise é a linguagem de programação Python. Através da análise dos dados gerados, padrões antes ocultos podem ser desvendados. Também podem ser analisadas tendências de mercado, preferências dos clientes e correlações de parâmetros diferentes (LAVALLE et al., 2010).

Ao coletar e analisar grandes volumes de dados de sensores e máquinas, as empresas podem identificar e eliminar desperdícios, otimizar o uso de recursos e melhorar a eficiência operacional. As ferramentas de Big Data permitem a detecção precoce de falhas e anomalias, possibilitando ações corretivas antes que se tornem problemas maiores, reduzindo paradas não planejadas (SHAHIN et al., 2023). Além disso, a análise de dados também facilita a previsão de demandas, ajustando a produção para evitar excesso ou falta de estoque (LI et al., 2022). Com essas capacidades, Big Data Analytics suporta a filosofia Lean de melhoria contínua e maximização do valor.

Contudo, para uma análise correta da grande quantidade de informações geradas pelo Big Data Analytics, é necessário desenvolver novas capacidades que tragam facilidades para esse processo. Assim, surge o Business Intelligence, ferramenta que está conectada ao processo da tomada de decisão, baseado pela integração dos recursos com os dados da organização (TAVERA ROMERO et al., 2021), já que no mundo atual, esses dados constituem-se em ativos valiosos para a empresa (DJERDJOURI, 2019). Sua utilização é necessária, justamente pela sua capacidade de desenvolver a tomada de decisão utilizando softwares computacionais (LABEDZKA, 2018).

Nesse estudo, a análise realizada utilizou a ferramenta Python, através do Google Colab, para conseguir processar os dados disponibilizados pelo banco de dados. Com isso, este estudo investiga as contribuições da aplicação do Big Data Analytics com o uso em Python para a abordagem lean manufacturing. É esperado que esse artigo seja útil para compreensão de como novas ferramentas podem auxiliar no processo de gestão da produção e como elas podem contribuir com o campo acadêmico no desenvolvimento de novas aplicações.

2. REVISÃO DA LITERATURA

2.1 Big Data Analytics com uso de estatística descritiva e multivariada

Big Data Analytics refere-se ao processo de coletar, organizar e analisar grandes volumes de dados para extrair informações valiosos que apoiam a tomada de decisões estratégicas (NAVQI et al., 2021). Esses dados, caracterizados pelo seu alto volume, variedade e velocidade, são provenientes de diversas fontes, como sensores industriais, transações de mercado e interações online. A importância de Big Data Analytics reside na sua capacidade de revelar padrões ocultos, tendências e correlações que seriam impossíveis de detectar por métodos tradicionais, oferecendo às organizações uma vantagem competitiva significativa.

No contexto industrial, a utilização de Big Data Analytics é essencial para otimizar processos, prever falhas e melhorar a eficiência operacional (WANG et al., 2022). Ferramentas de Big Data permitem a análise em tempo real de dados coletados de equipamentos e sistemas de produção, facilitando a implementação de uma gestão de produção enxuta e reduzindo o tempo de inatividade não planejado.

A integração de Big Data Analytics com técnicas de estatística descritiva e multivariada potencializa ainda mais sua eficácia. A estatística descritiva é usada para resumir e descrever as principais características dos dados, oferecendo uma visão geral clara do desempenho operacional e das tendências de falhas. Já a análise multivariada permite explorar as relações entre múltiplas variáveis simultaneamente, identificando padrões complexos e interações que podem influenciar a performance dos equipamentos e processos (TABACHNICK; FIDELL, 2018).

Essa combinação de abordagens fornece uma base robusta para a tomada de decisões informadas, permitindo às empresas adotar uma postura além da reatividade aos problemas à medida que estes surgem, também antecipando e prevenindo falhas antes que elas ocorram.

Assim, Big Data Analytics, aliado à estatística descritiva e multivariada, torna-se uma ferramenta indispensável para a gestão eficiente e a melhoria contínua em ambientes industriais (BELHADI et al., 2020).

2.2 Abordagem Lean Manufacturing

Lean Manufacturing é uma abordagem sistemática para a produção que visa maximizar o valor para o cliente, minimizando desperdícios. Originado no Sistema Toyota de Produção, o conceito de Lean Manufacturing se baseia em cinco princípios fundamentais: definição de valor do ponto de vista do cliente, identificação do fluxo de valor, criação de um fluxo contínuo, estabelecimento de um sistema *pull* baseado na demanda do cliente e busca contínua pela melhoria (KUMAR et al., 2022).

A abordagem Lean se concentra na eliminação de desperdícios em todas as formas, incluindo excesso de produção, tempo de espera, transporte desnecessário, excesso de processamento, inventário excessivo, movimentação desnecessária e defeitos (LEKSIC et al., 2020). Ao identificar e remover esses desperdícios, as empresas podem melhorar a eficiência, reduzir custos e aumentar a satisfação do cliente.

Na prática, Lean Manufacturing envolve a implementação de várias ferramentas e técnicas, como o mapeamento do fluxo de valor, a produção just-in-time (JIT), o kanban, o kaizen e o 5S. Essas ferramentas ajudam a visualizar o fluxo de produção, estabelecer processos eficientes, melhorar a qualidade e promover uma cultura de melhoria contínua (PALANGE; DHATRAK, 2021).

A integração de Big Data Analytics no contexto do Lean Manufacturing pode potencializar significativamente esses princípios e práticas. Ao fornecer dados detalhados e insights em tempo real, Big Data Analytics ajuda a identificar rapidamente fontes de desperdício e ineficiências (GUPTA et al., 2020). Isso permite ajustes mais precisos e oportunos, facilitando a implementação de um fluxo contínuo e a resposta rápida às mudanças na demanda do cliente.

Assim, a combinação de Lean Manufacturing com Big Data Analytics não só reforça os princípios Lean, mas também permite uma abordagem mais informada e dinâmica para a gestão da produção, resultando em operações mais eficientes e competitivas (GUPTA et al., 2020).

3. METODOLOGIA

A metodologia empregada nesta pesquisa se baseou em duas etapas, sendo a primeira a coleta de dados fornecidos por uma empresa de usinagem e posterior, segunda etapa, análise dos dados para extrair as conclusões de interesse (SAPSFORD, 1996).

3.1 Coleta de dados

Para realizar esta análise, foram utilizadas as informações fornecidas por uma empresa reconhecida por sua alta produção de produtos de usinagem. Esses dados consistem em dez mil produtos fabricados pelas máquinas em seu processo produtivo e organizados em um banco de dados (COXON, 1999) com a seguinte estrutura:

TABELA 1 – Descrição do banco de dados utilizado

Parâmetro	Descrição
UID	Identificador numeral sequencial (de 1 a 10000) para os produtos.
ID do Produto	Distinguindo os produtos em três categorias de acordo com variantes de qualidade: L (low), representando 50% dos produtos produzidos, M (medium) representando 30% dos produtos produzidos e H (high) representando 20% dos produtos produzidos.
Temperatura do ar [K]	Medida em torno da temperatura ambiente média (300 K) e com um desvio padrão de 2 K em torno da média.
Temperatura do processo [K]	Medida com uma média de 10 K acima da temperatura do ar e desvio padrão de 1 K em torno desta média.
Velocidade rotacional [rpm]	Calculada com valores médios referentes a uma potência de 2860 W.
Torque [N.m]	Os valores de torque são normalmente distribuídos em torno de 40 N.m com um $\sigma = 10$ N.m.
Desgaste da ferramenta [min]	As variantes de qualidade H, M e L adicionaram respectivamente 5, 3 e 2 minutos de desgaste da ferramenta utilizada no processo.

Fonte: Elaborado pelos autores (2024).

Existe também um rótulo chamado de “falha de máquina” que indica se a máquina falhou em algum ponto de dados específico.

3.2 Análise de dados

Para esta análise, serão utilizadas a Estatística Descritiva e a Estatística Multivariada, sendo observados os parâmetros envolvidos na metodologia estatística. A Estatística Descritiva pode ser entendida como cálculos estatísticos que têm por objetivo descrever características de uma seleção amostral ou relações existentes entre as variáveis estudadas. Ela resume um conjunto de amostras observadas (BABBIE, 2020). A estatística multivariada aborda as técnicas utilizadas para análise de conjuntos de dados. É útil na análise da

correlação entre diversas variáveis, dependentes e independentes (TABACHNICK; FIDELL, 2018).

Diante disso, ao utilizar a base de dados disponibilizada para análise, foi possível verificar que a falha da máquina pode ocorrer em cinco modos de falha independentes, conforme propõe Matzka (2020): Falha de desgaste da ferramenta (TWF), Falha de dissipação de calor (HDF), Falha de energia (PWF), Falha por sobrecarga (OSF) e Falhas aleatórias (RNF). Os modos de falha serão discutidos nos resultados desse relatório. O desenvolvimento dos gráficos para análise neste relatório foi gerado pela ferramenta Google Colab. A programação utilizada nesta ferramenta foi a linguagem de programação Python, sendo uma linguagem de alto nível, orientada, gratuita e multiplataforma, desenvolvida na década de noventa (DUBOIS et al, 2015). A Ferramenta Colab é disponibilizada pelo Google para aprendizagem dessa linguagem.

4. RESULTADOS

4.1 Análise descritiva

Conforme as análises realizadas na ferramenta Colab, o processo produtivo para a manufatura dos três produtos apresentou 348 falhas na produção dos dez mil itens.

4.1.1 Falha de desgaste da ferramenta (TWF)

A ferramenta será substituída ou falhará em um tempo de desgaste da ferramenta selecionado aleatoriamente entre 200–240 minutos (120 vezes nesse conjunto de dados). Neste momento, a ferramenta é substituída 74 vezes e falha aleatoriamente 46 vezes.

4.1.2 Falha de dissipação de calor (HDF)

A dissipação de calor causa uma falha do processo se a diferença entre a temperatura do ar e do processo for inferior a 8,6 K e a velocidade de rotação da ferramenta for inferior a 1380 rpm. Este é o caso de 115 pontos de dados.

4.1.3 Falha de energia (PWF)

O produto do torque e da velocidade de rotação (em rad/s) é igual à potência necessária para o processo. Se esta potência estiver abaixo de 3500 W ou acima de 9000 W, o processo falha, o que ocorre 95 vezes nos conjuntos de dados.

4.1.4 Falha por sobrecarga (OSF)

Se o produto do desgaste da ferramenta e do torque exceder 11.000 min N.m para a variante de produto L (12.000 para M, 13.000 para H), o processo falha devido à sobrecarga. Ocorre em 98 pontos de dados.

4.1.5 Falhas aleatórias (RNF)

Cada processo tem uma chance de 0,1% de falhar independentemente de seus parâmetros de processo. Este é o caso de 19 pontos de dados, mais frequente do que o esperado para 10.000 pontos de dados levantados.

a) De um total de 348 falhas, 70% estão relacionadas à produção do produto com a variante de qualidade L, 23% para a produção do produto com a variante de qualidade M e 7% para a produção do produto com a variante de qualidade H. Conhecer os perfis de falhas ajuda a adotar medidas para preveni-las, evitando que a falha ocorra, gerando desperdício de tempo e material.

b) A maior quantidade de falhas ocorre no intervalo entre 4.000 e 5.000 unidades produzidas, sendo que 32% do total de falhas está relacionado à falha na dissipação do calor, 27% falha de energia e 22% sobrecarga (Figura 1). Com isso, o monitoramento desses parâmetros através de Big Data Analytics pode contribuir para evitar a ocorrência das falhas.




FIGURA 1 - Quantidade de falhas por tipo.

c) Como indicado acima, 32% das falhas estão relacionadas a problemas na dissipação do calor (HDF). Os dados foram analisados para entender o comportamento da temperatura do ar e temperatura do processo. O gráfico da Figura 2 possui características similares com o anterior e demonstra que tanto a temperatura do ar quanto a temperatura do processo possuem crescimento acentuado a partir de 1.000 unidades produzidas atingindo o pico em 5.000

unidades produzidas. A partir de 5.000 unidades nota-se queda de temperatura tanto do ar quanto do processo.




FIGURA 2 - Temperatura do Ar e do Processo por Unidades produzidas

Segundo as informações do item 3.1.2, não poderia haver uma diferença menor que 8,6 K entre as duas medidas. Percebe-se que entre as unidades produzidas 4500 e 5500 houve um pico de temperatura, com uma diferença menor do que 8,6 K. Esse indício mostra que ocorreu um problema na dissipação de calor, resultando em uma falha. Neste contexto, o monitoramento contínuo da produção e das temperaturas de processo e do ar, através de Big Data Analytics, pode contribuir para a adoção de medidas que se antecipem à ocorrência das falhas, identificando a redução do diferencial de temperatura por exemplo, evitando que estas levem à quebras e interrupções do processo produtivo, combatendo desperdícios dentro dos princípios do *Lean Manufacturing*.

d) O gráfico BoxPlot pode ser reconhecido como um método alternativo ao histograma, sendo muito utilizado na identificação de *outliers*. A análise de boxplot da temperatura do ar demonstra que a temperatura relacionada ao primeiro quartil está próxima de 298 K, com uma mediana de aproximadamente 300 K e o terceiro quartil aproximadamente 301 K. Já o boxplot da temperatura do processo apresenta que a temperatura relacionada ao primeiro quartil está próxima de 308 K, com uma mediana de aproximadamente 310 K e o terceiro quartil está próximo de 311 K, conforme mostra a Figura 3.




FIGURA 3: Boxplots da temperatura do ar e temperatura do processo

e) Tempo de Desgaste da ferramenta (TWF). Conforme apresentado no item 3.1.1, a falha ocorrerá quando o tempo de desgaste estiver acima de 200 minutos. Na Figura 4, foi traçada uma linha indicando que em diversos momentos o tempo da ferramenta ficou acima de 200 minutos. O monitoramento contínuo dos dados pode permitir o controle do tempo de desgaste das ferramentas.




FIGURA 4: Desgaste da ferramenta x tempo

f) A falha de energia pode ser ocasionada em situações quando a relação velocidade de rotação x torque atinge medidas em potência abaixo de 3500 W ou acima de 9000 W. Assim, a Figura 5 demonstra a falha de energia ocorrendo praticamente ao mesmo tempo, o que reforça a posição de que no início e no fim do processo, ocorreram falhas de Energia.




FIGURA 5 - Falhas de energia

Sem a análise de múltiplos dados que é permitida pela adoção do Big Data Analytics, não seria possível identificar a ocorrência de diferentes tipos de falhas para uma variedade de parâmetros operacionais. Por exemplo, falhas de energia podem ocorrer em altos ou baixos valores de torque, mas não em valores intermediários. Falhas de dissipação de calor, por outro lado, não ocorrem em baixos valores de torque. O Big Data Analytics fornece essa compreensão do processo produtivo, permitindo que se evitem as falhas dentro de uma abordagem Lean.

A utilização de Big Data Analytics em conjunto com a linguagem Python contribuiu para formulação da análise descritiva, impactando positivamente o estudo. A apresentação dos gráficos corrobora os apontamentos de Matzka (2020), evoluindo sua abordagem. Sua utilização no contexto do Lean Manufacturing provou-se útil para análises gerenciais e tomadas de decisão assertivas para evitar a ocorrência de falhas e de desperdícios.

4.2 Análise multivariada

a) Correlação de Pearson. O gráfico de Correlação de Pearson demonstra se existem correlações entre as variáveis. Para esta análise, foram utilizados os seguintes cenários possíveis: correlação positiva, que indica que duas variáveis crescem ao mesmo tempo, ou seja, possuem uma relação direta; correlação negativa, quando as duas variáveis possuem relação, porém enquanto uma cresce a outra decresce; não possui correlação, quando não há relações entre o crescimento ou decrescimento das variáveis. O coeficiente de correlação de Pearson, ρ , pode variar entre -1 e +1 (GUIMARÃES, 2021). A Tabela 2 apresenta os valores de interpretação do coeficiente de correlação de Pearson.

TABELA 2 - Coeficiente de correlação de Pearson

Coeficiente de Correlação (ρ)	Tipo de correlação
0,9 a 1 (positivo ou negativo)	muito forte
0,7 a 0,9 (positivo ou negativo)	forte
0,5 a 0,7 (positivo ou negativo)	moderada
0,3 a 0,5 (positivo ou negativo)	fraca
0 a 0,3 (positivo ou negativo)	não possui correlação

Fonte: Guimarães (2021).

TABELA 3 - Correlação de Pearson

HEATMAP	UDI	Air Temperature [K]	Process Temperature [K]	Rotational Speed	Torque [Nm]	Tool Wear [min]	Target
UDI	1	0,12	0,32	-0,0066	0,0032	-0,011	-0,023
Air Temperature [K]	0,12	1	0,88	0,023	-0,014	0,014	0,083
Process Temperature [K]	0,32	0,88	1	0,019	-0,014	0,013	0,036
Rotational Speed [rpm]	0,0066	0,023	0,019	1	-0,88	0,00022	0,044
Torque [Nm]	0,0032	-0,014	-0,014	-0,88	1	-0,0031	0,19
Tool Wear [min]	0,011	0,014	0,013	0,00022	-0,0031	1	0,11
Target	0,023	0,083	0,036	-0,044	0,19	0,11	1

Fonte: Elaborado pelo autor.

A Tabela 3 corrobora algumas correlações apresentadas anteriormente.

- Existe uma correlação forte positiva entre Temperatura Ar e Temperatura Processo;
- Existe uma correlação forte negativa entre Torque e Velocidade de Rotação;
- Existe uma correlação fraca positiva entre Alvo e Tipo da Falha.

Para os demais fatores, não há correlação significativa entre os pares de variáveis.

5. CONSIDERAÇÕES FINAIS

Em vista da grande quantidade de dados disponibilizados diariamente por unidade de produção ou simplesmente por um único equipamento, o uso de ferramentas com maior capacidade de processamento de dados é necessário em todos os campos relacionados. Quando se trata de gestão da produção, espera-se que todo esforço seja realizado para coletar dados que contribuam com a identificação e eliminação de falhas e desperdícios, melhorando a lucratividade das empresas.

Conforme apresentado neste relatório, a utilização do Big Data Analytics e da ferramenta Python influenciou positivamente o gerenciamento de dados e criação de relatórios gerenciais. No atual cenário mundial, a utilização dessas ferramentas mostra-se essencial no contexto do Lean Manufacturing, imprescindível para a redução de desperdícios. Como demonstrado nesse estudo, a quantidade de falhas geradas pode ser monitorada e prevista com a utilização de sensores instalados nas máquinas e equipamentos utilizados pela empresa. Há um momento claro na produção, por exemplo, entre 4000 e 5000 unidades onde diversas falhas ocorrem, como em um efeito em cadeia. Essa informação demonstra quão assertiva a incorporação de tecnologias de Big Data Analytics pode ser no contexto do Lean Manufacturing.

As contribuições do *Big Data Analytics* na abordagem Lean Manufacturing são:

- Monitoramento das condições que provocam falhas, e consequentemente desperdícios, permitindo a adoção de medidas que antecipem as falhas;
- Identificação das causas que desencadeiam as condições que provocam as falhas, permitindo uma ação corretiva na raiz do problema e evitando interrupções no processo produtivo;
- Permite mapear o processo produtivo em relação aos tipos de falhas e aos parâmetros operacionais que induzem ou evitam essas falhas;
- Identificação dos fatores cruzados que podem desencadear os processos de falhas, implicando em desperdícios de tempo e de material.

O Big Data Analytics contribui de maneira significativa para a abordagem Lean Manufacturing ao fornecer informações detalhadas e em tempo real sobre os processos de produção. Com o advento da Inteligência Artificial, é possível que em breve as estratégias relacionadas ao Big Data Analytics e ao Lean Manufacturing estejam mais integradas e automatizadas, com dados sendo processados em tempo real, durante a manufatura dos produtos, o que levará a menor desperdício e melhor controle de toda a cadeia produtiva. Como sugestão para um relatório futuro, coloca-se a elaboração de novos gráficos de

correlação, e a investigação do impacto econômico da adoção das ferramentas de Big Data Analytics.

REFERÊNCIAS

- BABBIE, Earl R. **The Practice of Social Research**. Cengage AU, 2020.
- BELHADI, A.; KAMBLE, S.S.; ZKIK, K.; CHERRAFI, A.; TOURIKI, F.E. The integrated effect of Big Data Analytics, Lean Six Sigma and Green Manufacturing on the environmental performance of manufacturing companies: The case of North Africa. **Journal of Cleaner Production**, v. 252, p. 119903, 2020.
- BÉNDEK, Peter. **Beyond Lean**. Springer, 2016.
- BEN-DAYA, M.; HASSINI, E.; BAHROUN, Z. Internet of things and supply chain management: a literature review. **International Journal of Production Research**, v. 57, n. 15–16, p. 4719–4742, 2019.
- COURSERA. **What Is Big Data Analytics?** Definition, Benefits, and More. Disponível em: <https://www.coursera.org/articles/big-data-analytics>.
- COXON, Anthony Peter Macmillan. **Sorting data: Collection and analysis**. Sage, 1999.
- DJERDJOURI, Mohamed. Data and Business Intelligence Systems for Competitive Advantage: prospects, challenges, and real-world applications. **Mercados y Negocios**, n. 41, p. 5–18, 2019.
- DOS SANTOS, D.M.C.; DOS SANTOS, B.K.; DOS SANTOS, C.G. Implementation of a standard work routine using Lean Manufacturing tools: A case Study. **Gestão e Produção**, v. 28, n. 1, 2021.
- DUBOIS, Paul F. et al. **Programming Numerical Python**. v. 262, n. 1996, 2015.
- GUIMARÃES, Amanda Munari. **Estatística: análise de correlação usando Python e R**. Disponível em: <https://medium.com/omixdata/estatística-análise-de-correlação-usando-python-e-r-d68611511b5a>.
- GUPTA, Shivam; MODGIL, Sachin; GUNASEKARAN, Angappa. Big data in lean six sigma: a review and further research directions. **International Journal of Production Research**, v. 58, n. 3, p. 947-969, 2020.
- HAYES, R.H.; PISANO, G.P. Manufacturing Strategy: at the intersection of two paradigm shifts. **Production and Operations Management**. v. 5, n. 1, p. 25–41, 1996.
- JAVOID, M.; HALEEM, A.; SINGH, R.P.; RAB, S.; SUMAN, R. Significance of sensors for industry 4.0: Roles, capabilities, and applications. **Sensors International**, v. 2, 2021. Disponível em: <https://doi.org/10.1016/j.sintl.2021.100110>.
- KUMAR, N.; HASAN, S.S.; SRIVASTAVA, K.; AKHTAR, R.; YADAV, R.K.; CHOUBEY, V.K. Lean manufacturing techniques and its implementation: A review. **Materials Today: Proceedings**, v. 64, p. 1188-1192, 2022.
- LABEDZKA, Joanna. **Integrated Understanding of Business Intelligence**. 2018.
- LAVALLE, S. et al. Big data, analytics and the path from insights to value. **MIT Sloan management review**, 2010.
- LEKSIC, Ia; STEFANIC, Na; VEZA, Ib. The impact of using different lean manufacturing tools on waste reduction. **Advances in production engineering & management**, v. 15, n. 1, 2020.
- LI, C.; CHEN, Y.; SHANG, Y. A review of industrial big data for decision making in intelligent manufacturing. **Engineering Science and Technology, an International Journal**, v. 29, p. 101021, 2022.
- MATZKA, Stephan. Explainable Artificial Intelligence for Predictive Maintenance Applications. **Proceedings - 2020 3rd International Conference on Artificial Intelligence for Industries, AI4I 2020**, p. 69–74, 2020.
- NAQVI, R.; SOOMRO, T.R.; ALZOUBI, H.M.; GHAZAL, T.M.; ALSHURIDEH, M.T. The

nexus between big data and decision-making: A study of big data techniques and technologies. In: **The international conference on artificial intelligence and computer vision**. Cham: Springer International Publishing, 2021. p. 838-853.

PALANGE, Atul; DHATRAK, Pankaj. Lean manufacturing a vital tool to enhance productivity in manufacturing. **Materials Today: Proceedings**, v. 46, p. 729-736, 2021.

SAPSFORD, Roger; JUPP, Victor (Ed.). **Data collection and analysis**. Sage, 1996.

SCHMIDT, Rainer et al. Industry 4.0-potentials for creating smart products: empirical research results. In: **Business Information Systems: 18th International Conference, BIS 2015**, Poznań, Poland, June 24-26, 2015, Proceedings 18. Springer International Publishing, p. 16-27, 2015.

SHAHIN, M.; CHEN, F.F.; HOSSEINZADEH, A.; ZAND, N. Using machine learning and deep learning algorithms for downtime minimization in manufacturing systems: an early failure detection diagnostic service. **The International Journal of Advanced Manufacturing Technology**, v. 128, n. 9-10, p. 3857-3883, 2023.

TABACHNICK, Barbara G.; FIDELL, Linda S. **Using multivariate statistics**. Boston, MA: pearson, 2018.

TAVERA ROMERO, Carlos Andrés et al. Business intelligence: business evolution after industry 4.0. **Sustainability**, v. 13, n. 18, p. 1–12, 2021.

VAIDYA, S.; AMBAD, P.; BHOSLE, S. Industry 4.0 - A Glimpse. **Procedia Manufacturing**, v. 20, p. 233–238, 2018.

WANG, J.; XU, C.; ZHANG, J.; ZHONG, R. Big data analytics for intelligent manufacturing systems: A review. **Journal of Manufacturing Systems**, v. 62, p. 738-752, 2022.