

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA MECÂNICA E DE MATERIAIS
CÂMPUS CURITIBA**

PAULO HENRIQUE DE MODESTI

**MÉTODO BASEADO EM INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DO
PRAZO DE ENTREGA DE TAREFAS EM ESTAÇÕES DE MANUFATURA**

DISSERTAÇÃO

CURITIBA

2020

PAULO HENRIQUE DE MODESTI

**MÉTODO BASEADO EM INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DO
PRAZO DE ENTREGA DE TAREFAS EM ESTAÇÕES DE MANUFATURA**

Artificial Intelligence-based Method for Predicting Job Shop Flow Time

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador(a): Prof. Dr. Milton Borsato.

CURITIBA

2020



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite o download e o compartilhamento da obra desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-la ou utilizá-la para fins comerciais.



TERMO DE APROVAÇÃO DE DISSERTAÇÃO Nº 395

A Dissertação de Mestrado intitulada **MÉTODO BASEADO EM INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DO PRAZO DE ENTREGA DE TAREFAS EM ESTAÇÕES DE MANUFATURA**, defendida em sessão pública pelo candidato Paulo Henrique de Modesti, no dia 30 de outubro de 2020, foi julgada para a obtenção do título de Mestre em Engenharia Mecânica e de Materiais, área de concentração Engenharia de Manufatura, linha de pesquisa Desenvolvimento Integrado de Produto, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Mecânica e de Materiais.

BANCA EXAMINADORA:

Prof. Dr. Milton Borsato – Presidente – UTFPR

Prof. Dr. Julio Cesar Nievola – PUCPR

Prof. Dr. Neri Volpato – UTFPR

Este Termo de Aprovação encontra-se na pasta do aluno na Secretaria do Programa, contendo a assinatura da Coordenação, realizada após a entrega da versão final, incluindo correções necessárias, permitindo o encaminhamento para análise e publicação no Repositório Institucional.

RESUMO

Modesti, Paulo Henrique. **MÉTODO BASEADO EM INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DO PRAZO DE ENTREGA DE TAREFAS EM ESTAÇÕES DE MANUFATURA**, 2020, Dissertação de Mestrado em Engenharia de Manufatura – Programa de Pós-Graduação em Engenharia Mecânica e de Materiais, Universidade Tecnológica Federal do Paraná, Curitiba, 104 p.

Um importante diferencial competitivo de uma indústria, é a capacidade de cumprir os prazos de entrega prometidos aos seus clientes. Todavia, com o aumento da demanda por produtos customizados, imposto pelo mercado nas últimas décadas, aumenta-se a complexidade para estimar os tempos de fabricação. Esta dificuldade é ampliada em alguns setores da indústria onde são produzidas grande variedade de peça e cuja demanda de novos trabalhos é aleatória. São exemplos deste setor empresas como ferramentarias, fabricantes de protótipos e peças de reposição, pois operam com baixos volumes de produção por peça, além da variação dos tempos de execução e necessidade de rápida apresentação dos prazos de entrega. Assim, evidencia-se que a previsibilidade do prazo de entrega trata-se de um processo complexo. Dessa maneira, definiu-se como objetivo desta pesquisa o desenvolvimento de um método, capaz de prever o prazo de entrega de tarefas em tempo real, visando auxiliar na tomada de decisão quanto ao planejamento das indústrias. Para o desenvolvimento deste método utilizou-se como *framework* metodológico o *Design Science Research*. Dessa forma, seis etapas foram realizadas: (i) identificação do problema e motivação; (ii) definição dos objetivos da solução; (iii) projeto e desenvolvimento; (iv) demonstração; (v) avaliação e (vi) comunicação dos resultados. Para demonstração do método o mesmo foi aplicado em um caso real, no departamento de protótipos de uma empresa de eletrodomésticos da região de Curitiba, sendo avaliado através de questionários e comparativos. Ao analisar os resultados, comprova-se que o método proposto permite maior assertividade nas previsões de data de entrega de tarefas. Este trabalho teve como foco o estudo de um departamento de protótipos de uma empresa do ramo de linha branca, porém há possibilidade de o modelo ser adaptado para outros segmentos.

Palavras-chaves: Inteligência Artificial, Redes Neurais Artificiais; previsão de prazo de entrega; estação de manufatura.

ABSTRACT

Modesti, Paulo Henrique. **ARTIFICIAL INTELLIGENCE-BASED METHOD FOR PREDICTING JOB SHOP FLOW TIME**, 2020, Master's Degree Dissertation in Manufacturing Engineering – Post-graduate Program in Mechanical and Materials Engineering, Federal University of Technology – Paraná, Curitiba, 104 p.

An important competitive advantage of an industry is the ability to meet the delivery times promised to its customers. However, with the increase in demand for customized products, imposed by the market in the last decades, the complexity to estimate manufacturing times increases. This difficulty is amplified in some sectors of the industry where a great variety of parts are produced and whose demand for new tasks is random. Examples of this sector are companies such as job shops, prototype manufacturers and spare parts, as they operate with low volumes of production per part and have to deal with variable lead times and the need for quick presentation of delivery times. Thus, it is evident that the predictability of the delivery time is a complex process. In this way, the objective of this research was defined as the development of a method, capable of predicting the deadline for the delivery of tasks in real time, aiming to assist in decision making regarding the planning of industries. For the development of this method, Design Science Research was used as the methodological framework. Thus, six steps were taken: (i) problem identification and motivation; (ii) definition of the solution's objectives; (iii) design and development; (iv) demonstration; (v) evaluation and (vi) communication of results. To demonstrate the method, the same was applied in a real case, in the prototypes department of an appliance company in the region of Curitiba, being evaluated through questionnaires and comparisons. When analyzing the results, it is proved that the proposed method allows greater assertiveness in the task delivery date forecasts. This work focused on the study of a prototype department of a company in the white good business, but there is a possibility that the model could be adapted to other segments.

Keywords: Artificial Intelligence, Artificial Neural Networks, flow time prediction, job shop.

LISTA DE FIGURAS

Figura 1 - Esquema de interpretação de programa Python.....	25
Figura 2 - Esquema conceitual de estação de manufatura.....	28
Figura 3 - Estrutura de preparação de dados	36
Figura 4 - Modelo de processo DSR	39
Figura 5 - Fluxograma do Desenvolvimento da Solução	42
Figura 6 - Imagem do questionário de avaliação de facilidade de uso.....	48
Figura 7 - Métodos utilizados para cálculo de prazo de entrega de tarefas em estações de manufatura	51
Figura 8 - Imagem do portal de solicitações de protótipos da empresa parceira	52
Figura 9 - Imagem do cabeçalho da planilha	53
Figura 10 - Fluxo de produção no departamento de protótipos da empresa parceira.....	62
Figura 11 - Imagem da tela de interface com o usuário	64
Figura 12 - Resultado das respostas da primeira pergunta do questionário de avaliação de facilidade de uso do artefato.....	70
Figura 13 - Resultado das respostas da segunda pergunta do questionário de avaliação de facilidade de uso do artefato.....	71
Figura 14 - Resultado das respostas da terceira pergunta do questionário de avaliação de facilidade de uso do artefato.....	72
Figura 15 - Resultado das respostas da primeira quarta do questionário de avaliação de facilidade de uso do artefato.....	72
Figura 16 - Resultado das respostas da quinta pergunta do questionário de avaliação de facilidade de uso do artefato.....	73
Figura 17 - Resultado das respostas da sexta pergunta do questionário de avaliação de facilidade de uso do artefato.....	74
Figura 19 - Resultado das respostas da sétima pergunta do questionário de avaliação de facilidade de uso do artefato.....	75
Figura 20 - Resultado das respostas da primeira pergunta do questionário de avaliação de operacionalidade do artefato.....	76
Figura 21 - Resultado das respostas da segunda pergunta do questionário de avaliação de operacionalidade do artefato.....	77

Figura 22 - Resultado das respostas da terceira pergunta do questionário de avaliação de operacionalidade do artefato.....	78
Figura 23 - Resultado das respostas da quarta pergunta do questionário de avaliação de operacionalidade do artefato.....	78
Figura 24 - Resultado das respostas da primeira pergunta do questionário de avaliação de generalidade do artefato.....	79
Figura 25 - Resultado das respostas da segunda pergunta do questionário de avaliação de generalidade do artefato.....	80
Figura 26 - Resultado das respostas da terceira pergunta do questionário de avaliação de generalidade do artefato.....	81
Figura 27 - Resumo das notas do questionário de avaliação de facilidade de uso do artefato	83
Figura 28 - Resumo das notas do questionário de avaliação de generalidade do artefato	84

LISTA DE TABELAS

Tabela 1 - Classificação da correlação de Pearson.....	34
Tabela 2 – Valores dos indicadores para os métodos tradicionais	55
Tabela 3 - Valores obtidos após aplicação correção Pearson	57
Tabela 4 - Cálculo número de camada versus de quantidade de neurônios	58
Tabela 5 - Cálculo número de camada versus de quantidade de neurônios	59
Tabela 6 - Parâmetros de entrada da rede neural.....	60
Tabela 7 - Comparativo da influência da função de ativação no desempenho da rede neural	61
Tabela 8 - Comparativo dos indicadores de performance entre o método atual e DTWK e DPPW	65
Tabela 9 - Mapa de calor comparativo entre o método atual e diversas configurações de rede neural	66
Tabela 10 - Comparativo entre o método atual, DTWK e a rede neural	67
Tabela 11 - Comparativo dos indicadores com a eliminação de parâmetros de entrada	68
Tabela 12 - Comparativo de indicadores de diferentes funções de ativação	69
Tabela 13 - Comparativo final entre o método atual, DTWK e rede neural	69
Tabela 14 - <i>Report</i> com o número de questionários respondidos.....	83

LISTA DE SIGLAS E ACRÔNIMOS

AI	<i>Artificial Intelligence</i>	Inteligência artificial
AIM-DIP	<i>Artificial Intelligence Method for Deadline Prediction</i>	Método de inteligência artificial para previsão de prazo de fabricação
API	<i>Application Programming Interface</i>	Interface de Programação de Aplicativos
CAD	<i>Computer Aided Design</i>	Desenho Auxiliado por Computador
CPU	<i>Central Process unit</i>	Central de Processamento de Dados
DTWK	<i>Dynamic Total Work Content</i>	Conteúdo Dinâmico de Trabalho Total
DPPW	<i>Dynamic Process Plus Waiting</i>	Processo Dinâmico Mais Espera
DD	<i>Due date</i>	Data de vencimento
DSR	<i>Design Science Research</i>	Pesquisa Científica de Projeto
EDD	<i>Earliest due date</i>	Data de Vencimento Mais Próxima
FIFO	<i>First in First out</i>	Primeiro a chegar primeiro a servir
GP	<i>Genetic Programming</i>	Programação Genética
GUI	<i>Graphical User Interface</i>	Interface Gráfica do Usuário
IAI	<i>Industrial Artificial Intelligence</i>	Inteligência Artificial Industrial

IoT	<i>Internet of Things</i>	Internet das Coisas
JIQ	<i>Jobs In Queue</i>	Trabalhos em Fila
MAL	<i>Mean Absolute Lateness</i>	Atraso Médio Absoluto
MSL	<i>Mean Squared Lateness</i>	Atraso Quadrático Médio
ML	<i>Machine Learning</i>	Aprendizado de Máquina
MT	<i>Mean Tardiness</i>	Atraso Médio
MTO	<i>Make To Order</i>	Produção sob Pedido
MTS	<i>Make To Stock</i>	Produção para Estoque
NN	<i>Neural Network</i>	Rede Neural
PIB	<i>Gross National Product</i>	Produto Interno Bruto
PT	<i>Percentual Tardiness</i>	Atraso Percentual
PPGEM	<i>Postgraduate Program in Mechanical and Materials Engineering</i>	Programa de Pós-Graduação em Engenharia Mecânica e de Materiais
ProKnow-C	<i>Knowledge Development Process Constructivist</i>	Processo de Desenvolvimento de Conhecimento Construtivista
SPT	<i>Shortest Processing Time</i>	Tempo de Processamento Mais Curto

TI	<i>Information Technology</i>	Tecnologia da informação
TWK	<i>Total Work Content</i>	Conteúdo de Trabalho Total
UTFPR	<i>Federal Technological University of</i>	Universidade Tecnológica Federal do
	<i>Paraná</i>	Paraná
ZB	Zettabyte	Zettabyte

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVOS	16
1.1.1	Objetivo Geral.....	16
1.1.2	Objetivos Específicos.....	16
1.2	JUSTIFICATIVA	17
1.3	DELIMITAÇÃO DA PESQUISA.....	17
1.4	ESTRUTURA DO TRABALHO	18
2	FUNDAMENTAÇÃO TEÓRICA.....	19
2.1	INTELIGÊNCIA ARTIFICIAL	19
2.2	APRENDIZADO DE MÁQUINA	20
2.3	REDES NEURAIS ARTIFICIAIS	22
2.4	LINGUAGEM DE PROGRAMAÇÃO PYTHON.....	23
2.5	BIBLIOTECAS DE PROGRAMAÇÃO	24
2.5.1	Tkinter.....	24
2.5.2	Numpy.....	25
2.5.3	Tensorflow	26
2.5.4	Pandas.....	26
2.5.5	Scikit-learn	27
2.6	ESTAÇÃO DE MANUFATURA.....	27
2.7	PRAZO DE ENTREGA	28
2.8	REGRAS DE DESPACHO	31
2.9	CRITÉRIOS DE PERFORMANCE	32
2.10	CORRELAÇÃO DE PEARSON	33
2.11	TRATAMENTO DE DADOS	35
3	ASPECTOS METODOLÓGICOS	38
3.1	CARACTERIZAÇÃO DA PESQUISA	38
3.2	PROCEDIMENTO METODOLÓGICO	38
3.2.1	Identificação do Problema e Motivação.....	41
3.2.2	Definição dos Objetivos da Solução	41
3.2.3	Projeto e Desenvolvimento da Solução.....	41

3.2.4	Demonstração da Solução	44
3.2.5	Avaliação da Solução	44
3.2.6	Comunicação dos Resultados	49
4	RESULTADOS E DISCUSSÃO.....	50
4.1	IDENTIFICAÇÃO DO PROBLEMA E MOTIVAÇÃO	50
4.2	DEFINIÇÃO DOS OBJETIVOS DA SOLUÇÃO	51
4.3	PROJETO E DESENVOLVIMENTO DA SOLUÇÃO.....	51
4.3.1	Passo 1 – Coleta de dados	52
4.3.2	Passo 2 – Tratamento de dados	52
4.3.3	Passo 3 – Cálculo dos indicadores de performance	55
4.3.4	Passo 4 – Construção da rede neural	55
4.3.5	Passo 5 – Treinamento da rede neural.....	57
4.3.6	Passo 6 – Teste e revisão da rede neural	58
4.3.7	Passo 7 – Disponibilização da rede neural	61
4.4	DEMONSTRAÇÃO	61
4.5	AVALIAÇÃO.....	63
4.5.1	Eficiência.....	64
4.5.2	Facilidade de uso	70
4.5.3	Operacionalidade.....	75
4.5.4	Generalidade.....	78
4.6	ANÁLISE DOS RESULTADOS	81
5	CONCLUSÃO.....	85
	REFERÊNCIAS	87
	APÊNDICE A - PRODUCTION PLANNING AND SCHEDULING USING MACHINE LEARNING AND DATA SCIENCE PROCESSES	93

1 INTRODUÇÃO

A indústria de transformação aumentou sua participação no Produto Interno Bruto (PIB) da economia mundial nos últimos 48 anos, conforme recente estudo de Morceiro (2019). Também de acordo com este estudo, ao longo das últimas cinco décadas houve um notável deslocamento da produção industrial dos países desenvolvidos para países em desenvolvimento, sobretudo para a Ásia, que atualmente responde por metade da indústria global.

Segundo Morceiro; Tessarin (2019), na China, o parque industrial multiplicou-se por 44 e na Coreia do Sul por 18, sendo os líderes em crescimento industrial desde 1980. Cabe ressaltar que ambos países realizaram políticas industriais robustas focadas em inovação. Dessa forma, entende-se que o resultado obtido pela indústria destes países é fruto de um planejamento de longo prazo, visando aumentar sua competitividade no mercado mundial, historicamente permeado de grande concorrência.

Com o aumento da busca por maior competitividade, somado à orientação do serviço ao cliente e a maior complexidade do produto, surgem problemas de planejamento de produção a serem enfrentados pelas empresas de manufatura. Além disso, a redução dos ciclos de vida do produto, as instabilidades contínuas do mercado e as incertezas da demanda exigem um alto nível de flexibilidade de produção. Nesta situação de complexidade cada vez maior, é ainda mais importante entender as dependências operacionais e reagir adequadamente às mudanças no mercado ou no comportamento da demanda (GANSTERER, 2015).

Assim, entende-se que uma das principais maneiras de avançar frente à concorrência é buscar aumento da produtividade através do investimento em tecnologias disruptivas (QI; TAO, 2018). Corroborando com este raciocínio a publicação de Gartner (2014), elencando a adoção de tecnologias de inteligência artificial (*Artificial Intelligence* – AI), ramo de pesquisa definida como a capacidade de um computador se passar por uma pessoa sem distinção (ZHANG *et al.*, 2019), como principal estratégia para o desenvolvimento das empresas. Uma das formas de buscar este aumento é através do investimento em ciência, concebido essencialmente em universidades.

O nível crescente de customização, em combinação com o aumento da complexidade do produto, leva as empresas de manufatura a mudar seu modo de produção de produção para estoque (*Make to Stock* - MTS), para produção sob pedido (*Make to Order* - MTO) (GANSTERER, 2015).

Em um ambiente de produção sob encomenda, novos pedidos para uma determinada quantidade de um produto manufaturado chegam dinamicamente, e o prazo de entrega deve ser atribuído no momento em que o pedido chega. Dessa forma, atribuir o prazo de entrega requer essencialmente que o tempo de produção do pedido seja previsto em tempo real (ALENEZI; MOSES; TRAFALIS, 2008).

Na maioria dos sistemas de produção MTO, o desempenho na previsão do prazo de entrega é inferior ao desejado, o que indica a dificuldade dos fabricantes em definir datas de entrega adequadas, embora a atribuição do prazo de entrega seja uma das decisões mais importantes em relação ao atendimento ao cliente (ALENEZI; MOSES; TRAFALIS, 2008).

Considerando este contexto, deu-se início uma pesquisa buscando compreender quais são as alternativas de inteligência artificial (*Artificial Intelligence – AI*), existentes atualmente, para previsão do prazo de entrega de tarefas em sistemas de manufatura MTO, uma vez que técnicas tradicionais tendem a apresentar resultados não replicáveis quando as decisões tornam-se mais complexas (BERGMANN; FELDKAMP; STRASSBURGER, 2017).

Dessa forma, foi realizada uma revisão da literatura utilizando a metodologia *ProKnow-C*. Diversos estudos encontrados focaram em campos específicos da programação da produção como a previsão da data de entrega de ordens de produção, conforme discutido por Nguyen *et al.* (2014). Gansterer (2015) e Wang; Jiang (2019) desenvolveram estudos para determinar o tempo de conclusão de ordens, etapa parcial do levantamento da data de entrega de ordens; e ainda, (CHEN; WANG, 2013; WANG; ZHANG, 2016) analisaram métodos de cálculo do tempo de ciclo para produção seriada de componentes. Já Fang *et al.* (2019) propuseram um método para levantamento do tempo restante para execução dos trabalhos em tempo real, estudo voltado ao planejamento de tarefas de alta complexidade e duração.

Estes estudos ilustram como informações pertinentes à programação da produção são relevantes para tomada de decisão quanto à aceitação de pedidos de uma indústria. As principais saídas desta pesquisa foram: identificação das soluções já propostas por outros autores e também as oportunidades de pesquisa relacionadas ao tema (Apêndice A).

Corroborando com os estudos científicos, verifica-se que empresas de MTO, como ferramentarias e fabricantes de peças protótipo, tem dificuldade para realização de estimativas realistas de prazos de produção pois, segundo (ANTUNES; SEHNEM; LIMA, 2014) são dois os maiores problemas desse tipo de estratégia de produção: determinação de prazos de entrega realistas para os clientes e o desenvolvimento de programas de produção que atendam aos requisitos de entrega.

Na prática, um valor constante (ou seja, prazo de produção fixo) é de longe a abordagem mais comumente usada, embora os tempos de produção de pedidos individuais variem significativamente e um único valor constante seja uma estimativa pobre (ALENEZI; MOSES; TRAFALIS, 2008). Outra alternativa previsão do prazo de entrega de tarefas de empresas de MTO é basear-se na experiência dos operadores.

Considerando o contexto retratado, apresentando um problema nos âmbitos científico e prático, surge a seguinte pergunta: seria possível desenvolver um método baseado em AI, melhor que o atualmente utilizado na prática, para a previsão do prazo de entrega de tarefas?

Aliado com a identificação das oportunidades de pesquisa, o escopo deste trabalho se enquadra no Programa de Manufatura Inteligente do Programa de Pós-Graduação em Engenharia Mecânica e de Materiais (PPGEM) da Universidade Tecnológica Federal do Paraná (UTFPR). Um dos principais objetivos deste programa é promover o desenvolvimento de empresas de manufatura, onde estas deverão ter todas suas funções conectadas, sejam essas internas, parceiros externos ou outras partes envolvidas.

De acordo com o (NGMTI, 2005), a partir da evolução das inovações para entrega e suporte de produto, um conjunto de modelos interligados e que se comunicam em tempo real irá permitir aumento da criatividade humana. Os modelos utilizados para definir produtos e processos devem ser precisos e capazes de controlar a execução do processo. As funções técnicas e de negócios deverão ser integradas com os sistemas baseados em modelos para permitir a otimização do desempenho, em tempo real, e um eficaz controle da empresa.

Os trabalhos propostos pelo Programa de Manufatura Inteligente são divididos em dez demandas, sendo que esta proposta se insere na Demanda 9: Sistemas de Operação Baseados em Modelos, que conduzam e mantenham os processos produtivos, incluindo controle de processos. Esta demanda propõe alguns desafios: 1) Caracterizar completamente processos e equipamentos; 2) Capturar todas as operações críticas através de modelos; 3) Integrar funções de monitoramento, análise e controle; 4) Implementar controle distribuído; 5) Definir claramente “sob controle” através de parâmetros; 6) Implementar a automatização de tomadas de decisão; 7) Implementar a automatização de respostas; 8) Implementar a capacidade de prognóstico; e 9) Construir modelos, conhecimento e respostas com base científica.

Para cumprir os objetivos desta dissertação, seguiu-se as etapas de Pesquisa Científica de Projeto (*Design Science Research* - DSR) proposto por Blessing; Chakrabarti (2009). Esta é uma metodologia que estimula a criação e a avaliação empírica de um modelo ou teoria da situação desejada, o que aumenta a probabilidade de se produzir resultados que possam ser utilizados na prática. Adicionalmente, a DSR enfatiza a natureza iterativa do processo de

pesquisa que possibilita a flexibilidade da aplicação dos métodos que apoiam o planejamento e implementação das pesquisas (BLESSING; CHAKRABARTI, 2009; PIERONI, 2017).

Levando em conta o cenário identificado na indústria e as lacunas de pesquisa encontradas no portfólio bibliográfico em relação à previsibilidade do prazo de entrega de tarefas, considera-se que a presente dissertação um trabalho relevante para o meio acadêmico.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo geral deste estudo consiste em desenvolver uma solução, baseada em AI, capaz de melhorar em torno de cinco pontos percentuais a previsão de prazo de entrega de tarefas em tempo real para indústrias MTO cujo procedimento corrente seja um método prático.

1.1.2 Objetivos Específicos

Para alcançar o objetivo geral proposto foi desenhado o macroplanejamento do trabalho que consiste em cumprir com os seguintes objetivos específicos:

- i. Levantar as principais soluções computacionais propostas para previsões de prazos de fabricação;
- ii. Construir um método de cálculo do prazo de entrega de fabricação baseado em AI, aplicável ao contexto de produção de sistemas de manufatura, através da coleta de dados de produção e fornecendo respostas em tempo real;
- iii. Demonstrar a utilidade do método, por meio de provas de conceito, através do desenvolvimento e aplicação do artefato em uma empresa parceira. Esta etapa busca verificar o funcionamento do artefato;
- iv. Avaliar o método proposto, conforme critérios de: eficiência, facilidade de uso, operacionalidade e generalidade. Etapa em que se procura medir o funcionamento do artefato.

1.2 JUSTIFICATIVA

O controle do processo de produção geralmente se concentra no prazo de fabricação e seu acompanhamento. O desempenho da precisão do prazo de fabricação é cada vez mais importante no ambiente competitivo. As razões estão em dois aspectos: o primeiro é a confiabilidade da entrega, que significa a capacidade de cumprir o prazo prometido; e o segundo é a velocidade de entrega, o que se traduz em concluir os pedidos em pouco tempo (LEE, 2014). O prazo de fabricação informado não deve ser tão longo que o cliente precise esperar muito tempo nem tão cedo que o produto não possa ser cumprido. Nesse sentido, atribuir um prazo de entrega apropriado para uma demanda de fabricação é bastante difícil. A programação de produção de itens únicos ou customizados é mais difícil do que a produção em massa devido à diversidade de produtos pois possuem estruturas, roteiros e tempos de processamento diferentes.

Dessa forma, justifica-se o desenvolvimento do presente trabalho visto que as características da AI como conectividade, capacidade de mineração de dados e sua classificação e principalmente aprendizado, são fatores que a diferenciam das técnicas tradicionais, permitindo assim que a análise de dados melhorem a produtividade e a qualidade das tomadas de decisão (WANG *et al.*, 2018).

1.3 DELIMITAÇÃO DA PESQUISA

Considerando que o presente trabalho tem a finalidade de desenvolver um método, há delimitações dessa pesquisa precisam ser destacadas. Apesar do artefato ser demonstrado e avaliado em um cenário real de uma indústria de manufatura, como será descrito adiante, não há expectativa de implementá-lo, pois há etapas a serem definidas que não estão contempladas pelo estudo como: a responsabilidade pelos resultados, suporte em caso de problemas relacionados ao uso no dia a dia e a construção de uma interface amigável ao usuário.

Também é importante ressaltar que a validação do método à partir de cálculos estatísticos não foi realizada. Para isso seria necessário tratamento estatístico específico complexo que não faz parte do objetivo do trabalho.

Além disso, o presente estudo foi desenvolvido para aplicação específica de previsão em estações de manufatura, conceito a ser explicado no capítulo 2. Dessa forma, não foi estudado sua aplicação a outros segmentos da indústria como produção seriada ou serviços.

Tais limitações justificam-se porque evidencia-se que é necessário proceder com ajustes e aperfeiçoamentos no artefato de acordo com o contexto de sua aplicação, pois as realidades variam enormemente dentro de cada segmento da indústria de manufatura.

1.4 ESTRUTURA DO TRABALHO

Esta pesquisa está estruturada em cinco capítulos. O primeiro apresenta a contextualização do problema investigado, objetivo geral e específicos e justificativa que motivou o desenvolvimento do mesmo. O capítulo 2 expõe a base teórica necessária para a melhor compreensão do trabalho proposto, dado que vários conceitos não são de conhecimento comum. Em seguida, o capítulo 3 descreve os aspectos metodológicos utilizados para o desenvolvimento do trabalho, com destaque nas etapas de projeto e desenvolvimento, demonstração e avaliação da solução, buscando explicar como a pesquisa foi realizada. Já o capítulo 4 destaca as mesmas etapas do capítulo 3, porém com foco nos resultados obtidos durante esta pesquisa. Além disso, este capítulo discorre sobre a análise dos resultados. O último capítulo revela as considerações finais e conclusões a respeito do presente trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos relevantes para o entendimento e desenvolvimento da pesquisa. Esse capítulo foi construído a partir do levantamento bibliográfico e organizado numa sequência progressiva de especialização dos assuntos.

Primeiramente são apresentados com maior clareza os conceitos de AI como aprendizado máquina e redes neurais artificiais. Na sequência são apontados os conceitos de linguagem de programação Python e algumas de suas bibliotecas. Em seguida são expostas as definições de estação de manufatura, prazo de entrega, regras de despacho, critérios de performance e correlação de Pearson. Para concluir apresenta o conceito de preparação de dados para aprendizado de máquina (*Machine Learning* – ML).

2.1 INTELIGÊNCIA ARTIFICIAL

Não há na literatura uma definição clara a respeito de AI. Esta indefinição reside nas diversas dimensões em que este tema pode ser abordado. Segundo Norvig; Russell (2013), AI pode ser definida ao longo de duas dimensões: as que se relacionam ao processo de pensamento e raciocínio e as que se referem ao comportamento. Assim, foi adotada a definição de Nilsson (1998) “AI... está relacionada a um desempenho inteligente de artefatos”, associada à dimensão do comportamento inteligente.

O desenvolvimento da AI tem experimentado vários ciclos de avanço desde seu início em 1943. Atualmente, as principais forças motrizes de avanço da AI são dados, processadores e algoritmos de aprendizado (XUEJIAO; XIAOFENG; YANG, 2013). Desde 2010, a quantidade de dados produzidos no mundo atingiu o nível de zettabyte (ZB). O surgimento de processadores específicos melhorou a eficiência do processamento de dados de AI. Estes processadores aceleram a velocidade de treinamento e iteração dos cálculos e promovem o desenvolvimento da indústria de AI. Conforme Farid (2017) o computador infere características do próprio objeto a partir do banco de dados e, em seguida, identifica o objeto de acordo com a regra da característica. Segundo este mesmo autor, este aspecto permite a eliminação de gargalos de processamento da AI.

Um atributo que está diretamente vinculado ao que a AI visa alcançar é a criação de sistemas que possam perceber seu ambiente e, conseqüentemente, tomar medidas para aumentar as chances de sucesso (DOPICO *et al.*, 2016).

Como as formas de consumo estão mudando, os fabricantes buscam concentrar-se em demandas cada vez mais individualizadas para alcançar o máximo de clientes em potencial. Assim, o ambiente industrial também deve tornar-se variável. Portanto, a indústria precisa fornecer uma linha de produção dinâmica, onde não apenas os produtos são feitos, mas uma combinação de produtos e serviços são oferecidos para obter vantagem contra seus concorrentes, o que leva a produção a mudar constantemente (LEE; WANG; SU, 2015). Para conseguir isso, deve-se buscar um grau de automação flexível, onde a computação sensível e coleta de informações do ambiente, deve poder prever as próximas etapas da produção com quase nenhuma interação com o operador, da mesma maneira que a AI preconiza (ZHANG *et al.*, 2019).

Devido ao avanço das tecnologias de AI e o desenvolvimento contínuo da fabricação industrial inteligente no mundo, as empresas começaram gradualmente a integrar as tecnologias de AI às atividades industriais. Este processo de integração é chamado de Inteligência Artificial Industrial (*Industrial Artificial Intelligence – IAI*) (ZHANG *et al.*, 2019). Da perspectiva industrial, é possível definir a IAI a partir dos requisitos de aplicação industrial, tecnologias e funções da AI.

Funções inteligentes estão ligadas a capacidade dos *softwares* de aprendizado e previsibilidade das próximas etapas, cuja tecnologia é conhecida como aprendizado de máquina, uma das linhas de estudo da AI, conforme apresentado a seguir.

2.2 APRENDIZADO DE MÁQUINA

Se é difícil programar um computador para resolver um certo problema, por que não fornecer instruções indiretamente, transmitindo as habilidades necessárias por meio de exemplos, com os quais o mesmo poderá aprender (KUBAT, 2017).

Aprendizado de Máquina (*Machine Learning - ML*) é utilizado com sucesso em várias aplicações de otimização de processos, monitoramento, controle da produção e manutenção preditiva em diferentes indústrias. As técnicas de ML fornecem um potencial promissor para o controle de sistemas de manufatura, especialmente em ambientes complexos de manufatura em que a detecção das causas dos problemas é difícil. No entanto, muitas vezes as aplicações de ML são limitadas, concentrando-se em processos específicos em vez de todo o programa ou sistema de manufatura (DOLTSINIS; FERREIRA; LOHSE, 2012).

Como um mecanismo computacional para análise de dados, o ML serve como ferramenta para reconhecimento de padrões de dados e previsões. Para efetivamente realizar a

análise de dados, os algoritmos de ML desempenham um papel importante. Existem basicamente quatro tipos diferentes de algoritmos de aprendizado de máquina, sejam aprendizado não supervisionado, aprendizado supervisionado, aprendizado semi-supervisionado e aprendizado por reforço (MITCHELL, 1997). Embora o aprendizado por reforço seja usado nas áreas de robótica, jogos e navegação, os outros três tipos de aprendizado de máquina foram amplamente utilizados para análise de dados na indústria de processos. O ML explora o estudo e a construção de algoritmos que podem aprender e fazer previsões sobre os dados.

Nas últimas décadas, o aprendizado de máquina tem desempenhado um papel importante na construção de modelos baseados em experiência a partir de dados do processo. Com base nesta experiência, informações úteis podem ser extraídas, pois novos padrões de dados podem ser identificados, previsões podem ser feitas mais facilmente para novas amostras de dados e as decisões podem ser tomadas com mais rapidez e eficácia (RAHMAN; ESMAILPOUR; ZHAO, 2016). Toda essa aplicação de aprendizado de máquina vem permitindo mudanças na forma de programação da produção da indústria.

Segundo Wuest *et al.* (2016), as principais aplicações do método de aprendizado de máquina supervisionado incluem monitoramento de processo, classificação e identificação de falhas, localização do modo de operação *on-line*, modelagem de sensores e aplicativos *on-line*, previsão da qualidade e estimativa *on-line*, além de previsão e diagnóstico de índices de desempenho.

Os algoritmos de ML requerem dois tipos de dados: treinamento e teste. Um conjunto de recursos ou atributos é extraído como entrada para um algoritmo de aprendizado, com base nos conjuntos de dados de treinamento e nos dados rotulados. Os conjuntos de dados de treinamento também são usados para treinar um algoritmo de aprendizado. Já os conjuntos de dados de teste são usados para avaliar o algoritmo de aprendizado. Depois que um modelo de ML é avaliado, ele pode ser usado para prever o resultado potencial de um evento (WUEST *et al.*, 2016).

No contexto da fabricação, o aprendizado de máquina pode ser usado para prever o desgaste de uma ferramenta e determinar quando a manutenção deve ser realizada. Como ML em volumes muito grandes de dados de treinamento pode exigir quantidades significativas de núcleos de memória e Central de Processamento de Dados (*Central Process unit* - CPU), a implementação de algoritmos de aprendizado de máquina na nuvem ajuda a acelerar a modelagem preditiva. Segundo Wuest *et al.* (2016), no futuro, imagina-se criar modelos

preditivos usando algoritmos de aprendizado de máquina e integrar esses modelos ao sistema de monitoramento de processos *on-line* para diagnóstico e prognóstico.

Assim, dentre os quatro tipos de algoritmos de aprendizado de máquina, optou-se por desenvolver o presente trabalho utilizando aprendizado supervisionado devido ao tipo de dados disponíveis. Por sua vez, para o aprendizado supervisionado há diversas técnicas possíveis, como regressão linear, máquinas de suporte vetorial, redes neurais artificiais e árvores de decisão. Desta forma, conforme mencionado no capítulo 1, foi selecionada a técnica de redes neurais para a realização do presente estudo, como apresentado na seção subsequente.

2.3 REDES NEURAIAS ARTIFICIAIS

As redes neurais artificiais (*Neural Nets* - NN) são sistemas computacionais inspirados nas funções biológicas do cérebro humano. Redes Neurais Artificiais são técnicas que adquirem conhecimento através da experiência. Uma grande rede neural possui centenas ou milhares de unidades de processamento; já o cérebro de um mamífero pode ter bilhões de neurônios, como afirma Llinas (1989).

Segundo este mesmo autor, a NN consiste em camadas, elementos de processamento (nós) e conexões. A NN pode ser usada para desenhar funções a partir de observações. Essa característica pode ser útil em situações em que a complexidade dos dados impossibilita o projeto dessa função “manualmente”.

A NN tem sido amplamente empregada em várias áreas como manufatura, para previsão de desempenho da produção ou previsão de nível de estoque e finanças e contabilidade, para previsão de falências bancárias (PATIL, 2008).

Conforme indicado nas seções anteriores, a previsão do prazo de fabricação é uma tarefa difícil devido ao número de variáveis não linearmente relacionadas que podem afetá-lo. Dessa forma, como resultado dos avanços nos sistemas computacionais, estudos mais recentes sobre a atribuição de data de entrega de tarefas buscam aplicar sistemas inteligentes, como NN, para resolver a complexidade este tipo de problema (HSU; SHA, 2004).

No problema da atribuição de data de entrega, (PHILIPOOM; REES; WIEGMANN, 1994) são citados como os primeiros pesquisadores para estudar o uso de redes neurais para previsão de tempo de fluxo. Eles estudaram a eficácia das redes neurais quando comparadas à métodos matemáticos como Conteúdo de Trabalho Total (*Total Work Content* – TWK) e Trabalhos em fila (*Jobs In Queue* – JIQ) em uma estação de manufatura (conceitos a serem detalhados nas próximas seções). Esses autores concluíram que as redes neurais superaram

estas regras em termos de desvio padrão de atraso e, na medida de desempenho relacionada ao desvio médio absoluto na maioria dos experimentos.

Hsu; Sha, (2004) estudaram o desempenho de uma rede neural na previsão de data de entrega (*Due Date* – DD) em uma estação de manufatura complexa sob diferentes regras de despacho e políticas de revisão de pedidos comparando a rede neural com as regras TWK e JIQ. Os resultados de sua investigação mostraram que a NN obteve também melhores resultados dentro do prazo e atraso médio do que as regras TWK e JIQ.

Com esses estudos em mente, é possível concluir que as redes neurais podem superar as regras convencionais de atribuição de data de entrega e são dignas de experimentação. A literatura sobre as regras de atribuição de datas de entrega mostra que as regras dinâmicas superam as regras baseadas apenas em informações sobre o trabalho.

Por esse motivo, foi proposto estender a pesquisa desenvolvendo um modelo de NN para previsão de prazo de fabricação utilizando uma linguagem de programação simples e atual como *Python*, apresentada em seguida.

2.4 LINGUAGEM DE PROGRAMAÇÃO PYTHON

Python é conhecida como uma das linguagens de programação mais populares usada pelos cientistas de dados, sendo uma linguagem poderosa para processamento de dados, com uma curva de aprendizagem curta, além de uma grande comunidade de usuários, oferecendo grandes quantidades de bibliotecas e recursos.

Apesar da simplicidade, o Python é muito utilizado nos mais variados projetos de software. Existem diversas bibliotecas para trabalhar com interface gráfica, cálculos matemáticos complexos, banco de dados, desenvolvimento web e outras tecnologias. Por ser uma linguagem puramente interpretada, *Python* pode ser executada em qualquer ambiente que possua seu interpretador instalado. Por ter uma tipagem dinâmica, tipo de linguagem que não requer declaração de tipos de dados, desperta muitas críticas sobre confiabilidade e desempenho. Estes fatores prejudicam muito o desempenho da linguagem, pois o interpretador precisa traduzir o código e fazer checagem de tipos em tempo de execução. A checagem dinâmica também causa perda na confiabilidade da linguagem, uma vez que é difícil testar manualmente todos os tipos de variáveis de um sistema grande (MEDEIROS, 2015).

De qualquer forma, uma das grandes vantagens desta linguagem é a vasta quantidade de foruns de discussão e tutoriais de programação, além da disponibilidade de bibliotecas de programação, pois simplificam a construção de algoritmos, conforme explicado a seguir.

2.5 BIBLIOTECAS DE PROGRAMAÇÃO

Em ciência da computação, uma biblioteca é uma coleção de recursos não-voláteis usados por programas de computador, muitas vezes para o desenvolvimento de software. Incluem dados de configuração, documentação, dados de ajuda, modelos de mensagens, código pré-escrito e sub-rotinas, aulas, valores ou tipo especificações (FINZI *et al.*, 2013).

Segundo este mesmo autor, a biblioteca é também um apanhado de implementações de comportamento, escritas em termos de uma língua, que tem uma interface bem definida pelo qual o comportamento é invocado. Um programa invoca o comportamento fornecidos pela biblioteca através de um mecanismo da língua. Em uma simples linguagem imperativa, como C, o comportamento em uma biblioteca é invocada usando a função-chamada normal de C. O que distingue a chamada como sendo de uma função de biblioteca, versus ser para outra função no mesmo programa, é a maneira que o código é organizado no sistema.

O conceito de biblioteca difere bastante do de uma Interface de Programação de Aplicativos (*Application Programming Interface* – API), conjunto de rotinas de programação para acesso a um aplicativo em nuvem. Uma biblioteca não fornece uma interface para que sejam consumidos recursos de um sistema. Ela é um conjunto de subprogramas ou funções, geralmente organizadas em classes, que podem ser usadas para a construção de um software ou aplicativo mobile. As bibliotecas geralmente tornam a utilização de uma linguagem de programação mais fácil (FINZI *et al.*, 2013).

Conforme comentado, há inúmeras bibliotecas com aplicações específicas, porém algumas são mais utilizadas por permitirem montar interfaces com usuário de maneira rápida e simples como a *tkinter*.

2.5.1 Tkinter

O *tkinter* é uma biblioteca da linguagem *Python* que permite a estruturação de uma Interface Gráfica do Usuário (*Graphical User Interface* – GUI), ela é nativa da linguagem o que facilita o uso de outras ferramentas. A base de organização do *tkinter* é a estrutura que segue analogia de containers, onde todas as informações (janelas, botões, textos) devem estar dentro de um container (COSTA, 2019).

Neste contexto é importante citar como é possível executar os cálculos numéricos e por isso foi relatado sobre a biblioteca *Numpy*.

Acompanha a instalação padrão e permite desenvolver interfaces gráficas. Isso significa que qualquer computador que tenha o interpretador Python instalado é capaz de criar interfaces gráficas usando o *tkinter*.

Para executar um programa *Python*, é preciso ter um interpretador. O interpretador *Python* é um programa que lê o código e, em seguida, executa as instruções encontradas nele, como representado na Figura 1.

Figura 1 - Esquema de interpretação de programa Python



Fonte: Lee (2014).

Além de uma interface, são necessárias bibliotecas como *NumPy* para realização de cálculos matemáticos, como apresentado em seguida.

2.5.2 Numpy

NumPy, é uma biblioteca *Python* que é usada principalmente para realizar cálculos em matrizes multidimensionais. O *NumPy* fornece um grande conjunto de funções e operações de biblioteca que ajudam os programadores a executar facilmente diversos cálculos numéricos (NUMPY, 2019).

O pacote fornece um objeto de matriz multidimensional de alto desempenho e ferramentas para trabalhar com essas matrizes. É o pacote fundamental para computação científica com *Python*. Além de seus usos científicos óbvios, o *NumPy* também pode ser usado como um contêiner multidimensional eficiente de dados genéricos.

Matriz em *NumPy* é uma tabela de elementos (geralmente números), todos do mesmo tipo, indexados por uma lista de inteiros positivos. Em *NumPy*, o número de dimensões da matriz é chamado de classificação da matriz (NUMPY, 2019).

Podem ser criadas matrizes utilizando a biblioteca *NumPy* de várias maneiras, como por exemplo a partir de listas dados. O tipo de matriz resultante é deduzido do tipo dos elementos nas sequências. Porém para apresentar o resultado de funções e operações entre matrizes é preciso seguir regras e neste contexto utiliza-se a ferramenta *Tensorflow*.

2.5.3 Tensorflow

TensorFlow é uma biblioteca de software de código aberto para computação numérica usando grafos computacionais. Foi originalmente desenvolvido pela *Google Brain Team* na organização de pesquisa *Machine Intelligence* do Google para aprendizado de máquina e pesquisa de redes neurais profundas (*Deep Learning*). Mas esta biblioteca é abrangente o suficiente para ser aplicada em uma grande variedade de outros domínios também. Foi disponibilizada como *open-source* em 2015 e alcançou a versão 1.0 em 2017, com um desenvolvimento e adoção incrivelmente rápidos e muitos colaboradores externos. O *TensorFlow* vem se tornando a biblioteca padrão para desenvolvimento em aprendizagem profunda e outras aplicações de AI (TENSORFLOW, 2019).

Com o avanço na área de redes neurais e ML houve também um aprimoramento de *frameworks* (abstração que une códigos comuns entre *softwares*) e interface de programação de aplicação (*Application Programming Interface – API*) que implementam redes cada vez mais complexas de aprendizado em um nível superior de programação, exigindo menos código e menos conhecimento para a implementação de algoritmos preditivos, por exemplo (TENSORFLOW, 2019).

A ferramenta explorada neste trabalho foi o *TensorFlow*, uma API de código aberto em *Python* da *Google* (TENSORFLOW, 2019). A mesma já apresenta as principais ferramentas de redes neurais (LSTM, manipulação de dados) implementadas, sendo chamadas por meio de funções prontas, além de criar códigos portáteis entre diferentes sistemas.

A ferramenta para manipulação de dados a ser utilizada é a *Pandas*, descrita em seguida.

2.5.4 Pandas

Pandas, é uma biblioteca de software escrita para a linguagem de programação *Python* para manipulação e análise de dados. Em particular, oferece estruturas de dados e operações para manipular tabelas numéricas e séries temporais (PANDAS, 2018).

O *Pandas* disponibiliza estruturas de dados e ferramentas para tratar algoritmos que foram idealizados para facilitar o processo de tratamento e análise de informações utilizando a linguagem *Python*. No caso de bibliotecas de análise como *scikit-learn*, o *Pandas* também estará atuante no fornecimento de informações (PANDAS, 2018).

A biblioteca *scikit-learn* que é um pacote com algoritmos conforme segue.

2.5.5 Scikit-learn

Scikit-learn é uma biblioteca de aprendizado de máquina de código aberto para a linguagem de programação *Python*, também conhecida como *sklearn*, sua abreviação e nome no pacote *Python*. Inclui vários algoritmos de classificação, regressão e agrupamento incluindo máquinas de vetores de suporte, *K-means* e algoritmos de *clustering*, entre outros. É projetada para interagir com as bibliotecas *Python* numéricas e científicas como *NumPy* e *SciPy*. (SCIKIT-LEARN, 2020).

O *scikit-learn* possui muitos recursos, como:

- Análise de algoritmos de aprendizado supervisionado: Partindo de modelos lineares generalizados (por exemplo, regressão linear), máquinas de vetores de suporte, árvores de decisão e métodos bayesianos, realiza diversos exames.
- Validação cruzada: Existem vários métodos para verificar a precisão de modelos supervisionados em dados não vistos usando esta biblioteca.
- Algoritmos de aprendizado não supervisionado: há uma grande variedade de algoritmos de aprendizado de máquina, começando com agrupamento, análise de fator, análise de componente principal e redes neurais não supervisionadas.
- Extração de recursos: ferramentas desta biblioteca são capazes de extrair recursos de imagens e texto.

Uma das principais razões do uso de ferramentas de código aberto é a enorme comunidade que as utilizam. O mesmo é válido para *sklearn*; que além dessas comunidades, possuem vários encontros em todo o mundo (JAIN, 2015).

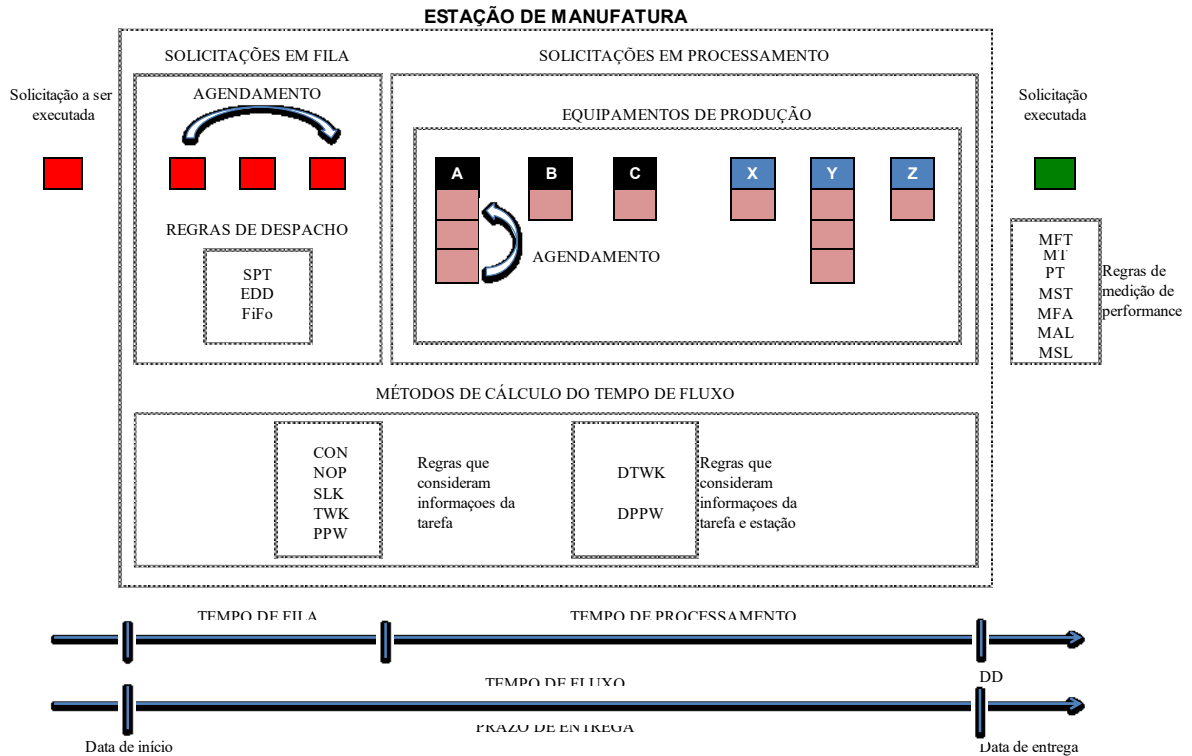
Dessa forma, todas as ferramentas citadas constituem parte de enorme aparato disponível para o desenvolvimento de algoritmos que auxiliem no avanço da tecnologia. Esta tecnologia também é aplicada em diversas áreas da indústria, como em estações de manufatura conforme definido a seguir.

2.6 ESTAÇÃO DE MANUFATURA

Em termos gerais uma estação de manufatura pode ser descrita como o conjunto dos seguintes elementos (PETTIT, 1968): equipamentos de produção, tarefas a serem executadas, cada tarefa pode ter sequência de processamento diferente de outra, as tarefas podem ter tempos de processamento diferentes e cada equipamento pode executar uma ou mais operações. Em resumo, estações de manufatura são entidades que executam grande variedade de tarefas não

repetitivas, isto é, não tratam de fabricação em massa. A Figura 2 ilustra o conceito de uma estação de manufatura.

Figura 2 - Esquema conceitual de estação de manufatura



Fonte: Adaptado de Pettit (1968).

2.7 PRAZO DE ENTREGA

A data de entrega (*Due Date* - DD) pode ser definida como a data em que o pedido deve ser entregue ao cliente (VINOD; SRIDHARAN, 2011). A DD também pode ser estabelecida externamente ou internamente (JOSEPH; SRIDHARAN, 2011). É definida externamente quando a data de entrega é imposta pelo cliente e internamente quando é definida com base nos níveis de congestionamento da estação de manufatura.

Normalmente, o processo de atribuição de DD consiste em fazer uma estimativa do tempo de fluxo de uma tarefa com base em regras para estimativa de tempo de fluxo e, em seguida, definir uma data de conclusão com base nessa estimativa (JOSEPH; SRIDHARAN, 2011). O tempo de fluxo ou prazo de fabricação pode ser definido como o tempo que uma tarefa leva para ser processada em uma estação de manufatura, desde seu início até a finalização (RIBEIRO, 2016).

A literatura fornece uma grande variedade de métodos para estimar o tempo de fluxo, alguns mais simples que outros, mas a principal diferença entre eles, é a quantidade de fatores

que são considerados para fazer a estimativa.

De acordo com Thurer *et al.* (2013) para a estimativa do tempo de fluxo, duas categorias principais de fatores podem ser usadas: informações relacionadas ao trabalho e informações relacionadas à estação de manufatura. A primeira categoria está relacionada às características da tarefa que só podem ser conhecidas no momento em que o trabalho chega à estação. A segunda categoria está relacionada à condição da estação em termos de congestionamento.

As informações relacionadas à tarefa incluem: tempo de processamento, número de operações e o roteiro. As informações relacionadas à estação incluem também fatores que são obtidos antes da tarefa ser liberada para fabricação. Estes fatores (SHA; LIU, 2005; THÜRER *et al.*, 2013) podem compreender: o número de tarefas em fila de cada máquina na rota de execução do trabalho e o número de tarefas no sistema.

Nem todos os fatores têm a mesma influência na estimativa do tempo de fluxo. Alpay; Yuzugullu (2009) realizaram um estudo sobre os fatores que afetam a previsibilidade da DD. Ao comparar cinco regras de atribuição eles concluem que o número de trabalhos nas filas de cada máquina no rota da tarefa, o tempo total de processamento da tarefa e o número de operações são os fatores mais importantes para a estimativa do tempo de fluxo. No entanto, eles também apontam que, para aumentar a qualidade da previsão de DD, mais fatores devem ser considerados.

Exemplos de métodos para a estimativa do tempo de fluxo são: Constante (*Constant - CON*), Número de operações (*Number of Operations - NOP*), Folga (*SLK*), Conteúdo de Trabalho Total (*Total Work Content - TWK*) e Tempo de Processamento Mais Espera (*Processint Time plus Waiting - PPW*). O cálculo da estimativa de tempo de fluxo nesses métodos é obtida da seguinte forma (BAYKASOĞLU; GÖÇKEN; UNUTMAZ, 2008):

- CON: o tempo de fluxo de um trabalho é a soma do seu tempo de chegada com uma constante que dá igual fator de tolerância (índice que estabelece limite de variação do tempo de fluxo) para cada trabalho;
- NOP: define a estimativa do tempo de fluxo de um trabalho em função do número de operações a serem realizadas;
- SLK: a estimativa do tempo de fluxo é baseada em uma folga comum que reflete tempos de espera iguais ou folgas iguais.
- TWK: o fator de tolerância é um múltiplo do tempo de processamento do trabalho;
- PPW: combina CON, SLK e TWK em um modelo, onde as datas de vencimento são funções lineares do tempo de processamento do trabalho.

Nestes métodos, o mesmo fator de tolerância é atribuído à todas tarefas, por isso são conhecidas como métodos estáticos. A precisão destes métodos depende do fator de tolerância mais adequado para os trabalhos (BAYKASOĞLU; GÖÇKEN; UNUTMAZ, 2008; CHENG; JIANG, 1998).

A principal questão levantada para estes métodos é que, dado o mesmo fator de tolerância para todas as tarefas, a carga de trabalho da estação de manufatura não está sendo levada em consideração. Ainda assim, esta carga influenciará o tempo que a tarefa passará no sistema. Portanto, se houver uma grande carga de trabalho na estação, um fator de tolerância maior deve ser atribuído e, por outro lado, se a carga da estação de manufatura for moderada, um fator de tolerância menor deve ser atribuído (CHENG; JIANG, 1998).

Para superar o problema dos métodos estáticos, outros métodos conhecidos como dinâmicos foram desenvolvidos por Cheng; Jiang (1998), onde o fator de tolerância é atualizado dinamicamente conforme a tarefa chega à estação. Em seu estudo, eles propuseram dois novos métodos baseados em métodos estáticos: Dynamic Total Work Content (DTWK) derivado da regra TWK e Dynamic Processing Plus Waiting (DPPW) derivado da regra PPW. O método DTWK é calculado da seguinte maneira:

$$k_t = \frac{N_{st}}{\lambda \mu_g \mu_p} \quad (1)$$

Onde k_t , N_{st} , λ , μ_g e μ_p correspondem respectivamente ao fator de tolerância, o número de solicitações na estação de trabalho em um momento “t”, a taxa média de chegada de tarefas, o número médio de operações e o tempo de processamento médio.

Para evitar que ocorra um fator de tolerância menor que 1, é usada a função $\max[1, k_t]$.

$$d_i = r_i + \max[1, k_t] \sum_{j=1}^{m_j} p_{ij} \quad (2)$$

Onde d_i , r_i , m_j e p_{ij} correspondem respectivamente à data de previsão de entrega da tarefa “i”, a data de chegada da tarefa na estação, número de operações da tarefa “i” e o tempo de processamento da tarefa “i” para a operação “j”.

O método DPPW é calculado através das fórmulas:

$$k_t = \frac{N_{qt}m_j}{\lambda\mu_g} \quad (3)$$

Onde N_{qt} é o número total de tarefas em fila em cada equipamento.

$$d_i = r_i + k_t + \sum_{j=1}^{m_j} p_{ij} \quad (4)$$

Estas regras são capazes de estimar dinamicamente o tempo de fluxo usando informações de *feedback* sobre o status atual da estação e as características da tarefa que chega para definir um fator de tolerância no momento em que o trabalho chega à estação (CHENG; JIANG, 1998). Neste caso, o fator de tolerância refletirá as condições atuais da estação. Eles também demonstraram que as regras de atribuição dinâmica de DD fornecem melhores resultados do que suas contrapartes estáticas.

Dessa forma, o presente estudo se concentrará nas regras dinâmicas de atribuição de DD propostas por Cheng; Jiang (1998), porém focando no cálculo do prazo de entrega de novas solicitações.

Todavia para determinação do prazo de entrega, há uma importante variável a ser considerada. Esta variável é a regra de despacho a ser estabelecida. O estudo de diversas dessas regras é apresentado na próxima seção.

2.8 REGRAS DE DESPACHO

Uma regra de despacho estabelece a ordem de execução das tarefas a serem processadas a partir de um conjunto de tarefas aguardando processamento na fila de entrada de uma máquina (RHEE; BAE; KIM, 2004). As regras de despacho também são denominadas regras de agendamento ou regras de sequenciamento. As regras de despacho são classificadas em quatro grandes categorias: regras baseadas em tempo de processo, datas de vencimento, combinação e regras que não são baseadas no tempo de processo nem na data de vencimento (HAUPT, 1989; WONG; ZHANG, 2014).

Um exemplo de regra baseada no tempo de processo é o Tempo de Processamento mais Curto (*Shortest Processing Time* – SPT) onde a prioridade mais alta é dada à operação de espera

com o tempo de processamento mais curto. Esta regra reduz significativamente o tempo de fluxo dos trabalhos e o atraso médio (BLACKSTONE; PHILLIPS; HOGG, 1982). No entanto, resulta em maiores atrasos para trabalhos com tempos de processamento mais longos.

A regra Data de Vencimento mais Próxima (*Earliest Due Date* - EDD) é um exemplo de regra com base em datas de vencimento onde a prioridade mais alta vai para o trabalho com a DD mais antiga. De acordo com Holthaus; Rajendran (1997) este tipo de regra de despacho tem um bom desempenho.

Todavia, conforme afirmado por Blackstone; Phillips; Hogg (1982), não há regra de despacho que tenha ótimo desempenho em todas as circunstâncias, uma vez que sua eficiência depende do características da estação de trabalho e do objetivo da produção.

Alguns autores sugeriram associar diferentes regras de despacho, combinando os melhores recursos de regras baseadas em tempo de processo e data de vencimento. Foi descoberto que esse tipo de regra supera as regras baseadas somente em tempo de processo ou data de vencimento (FAN *et al.*, 2015).

Um exemplo de regra de despacho que não é baseada no tempo ou data de vencimento é Primeiro a chegar primeiro a servir (*First in First out* – FiFo). A tarefa que chega primeiro na fila de um equipamento é a primeira a ser processada (WONG; ZHANG, 2014). Uma das mais utilizadas em diversas indústrias devido à sua simplicidade. Para o presente trabalho foi definido utilizar a regra FiFo, pois é a regra adotada no caso de aplicação; isto é, na empresa parceira, como será discutido no capítulo 3.

Dessa forma, a precisão no cumprimento das previsões de datas de entrega de tarefas em uma estação de manufatura depende diretamente do método de cálculo do tempo de fluxo e da regra de despacho adotada. Assim, para medir o desempenho das previsões, é necessário utilizar critérios de performance, conforme detalhado a seguir.

2.9 CRITÉRIOS DE PERFORMANCE

Para avaliar a qualidade das regras de atribuição DD, várias medidas de desempenho têm sido empregadas. No entanto, há uma maior ênfase na seleção entre as medidas de desempenho relacionadas à pontualidade e atraso, como atraso médio (*Mean Tardiness* – MT) e percentual de tarefas atrasadas (*Percentual of Tardy Jobs* - PT) (VINOD; SRIDHARAN, 2011). Segundo estes mesmos autores, isso pode ser explicado pelo fato de que a conclusão tardia das obras pode acarretar na perda de confiança do cliente e em custos adicionais ou mesmo penalizações. Por outro lado, a rapidez, embora não seja tão crítica no relacionamento

com o cliente, também é indesejável devido ao fato de que uma conclusão antecipada dos trabalhos pode elevar custos relacionados ao armazenamento de produtos. Isso significa que a qualidade do DD deve ser avaliada não apenas em termos de atrasos, mas também em termos de pontualidade.

A pontualidade média absoluta (*Mean Absolute Lateness* – MAL) foi definida como uma medida linear da DD perdida. MAL é sempre igual à soma dos valores absolutos de atraso (ALPAY; YÜZÜGÜLLÜ, 2009; VINOD; SRIDHARAN, 2011). De acordo com estes autores, um valor MAL menor sugere uma melhor aptidão de predição de DD e, portanto, uma melhor precisão. No entanto, uma previsão DD pode ser precisa, mas não exata. Por este motivo, a pontualidade quadrática média (*Mean Squared Lateness* – MSL) também é usada na avaliação de previsão de DD. O MSL mede a diferença quadrática média entre as datas reais de conclusão e as datas de vencimento estimadas para os trabalhos. Um valor MSL menor implica em um desvio menor de uma ocorrência de data de vencimento designada.

Desta forma, para avaliação da qualidade dos métodos de predição do presente trabalho em termos de precisão e exatidão, foram utilizados o MAL e MSL. Além disso, também avaliaremos o PT e MT para estudar o impacto dos trabalhos atrasados, visto que em ambientes reais o atraso tende a ser uma questão crítica para as empresas.

Um outro importante aspecto a ser avaliado, relacionado diretamente ao resultado da rede neural, é a coerência dos dados a serem utilizados. Uma maneira de examinar estes dados é através da correlação de Pearson, conforme apresentado a seguir.

2.10 CORRELAÇÃO DE PEARSON

O coeficiente de correlação de Pearson, também chamado de "coeficiente de correlação produto-momento" ou simplesmente de " ρ de Pearson" mede o grau da correlação (e a direção dessa correlação) entre duas variáveis de escala métrica (MOORE; NOTZ; FLIGNER, 2015). Este coeficiente, normalmente representado por " ρ " assume apenas valores entre -1 e 1, onde:

$\rho = 1$: significa uma correlação perfeita positiva entre as duas variáveis;

$\rho = -1$: significa uma correlação negativa perfeita entre as duas variáveis, ou seja, se uma aumenta, a outra sempre diminui;

$\rho = 0$: significa que as duas variáveis não dependem linearmente uma da outra. No entanto, pode existir uma dependência não linear. Assim, este resultado ($\rho = 0$) deve ser investigado por outros meios.

A fórmula do coeficiente de correlação de Pearson, conforme (MOORE; NOTZ; FLIGNER, 2015), é a seguinte:

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} * \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{cov(X, Y)}{\sqrt{var(X) * var(Y)}} \quad (5)$$

A análise correlacional, indica a relação entre duas variáveis lineares e os valores sempre foram entre +1 e -1. O sinal indica a direção se a correlação é positiva ou negativa, o tamanho da variável indica a força da correlação. Santos (2018) propõe a classificação da correlação linear de Pearson de acordo com a Tabela 1. Para o presente trabalho foi utilizado este segundo critério, associado a uma escala de cores.

Tabela 1 - Classificação da correlação de Pearson

Coeficiente de correlação	Correlação
$\rho=1$	Perfeita positiva
$0,8 \leq \rho < 1$	Forte positiva
$0,5 \leq \rho < 0,8$	Moderada positiva
$0,1 \leq \rho < 0,5$	Fraca positiva
$0 < \rho < 0,1$	Ínfima positiva
0	Nula
$-0,1 < \rho < 0$	Ínfima negativa
$-0,5 < \rho \leq -0,1$	Fraca negativa
$-0,8 < \rho \leq -0,5$	Moderada negativa
$-1 < \rho \leq -0,8$	Forte Negativa
$\rho=-1$	Perfeita Negativa

Fonte: Santos (2018).

Coeficientes de correlação são usados para avaliar a força e a direção das relações lineares entre pares de variáveis. Os coeficientes de correlação não comunicam informações sobre se uma variável se move em resposta a outra. Não há tentativa de estabelecer uma variável como dependente e a outra como independente. Assim, as relações identificadas usando coeficientes de correlação devem ser interpretadas como associações, não relações causais (MUKAKA, 2012).

Todavia, para examinar qualquer correlação entre dados, é necessário que estes sejam tratados de maneira que seja possível realizar esta análise. Uma maneira de realizar este tratamento é apresentada na próxima seção.

2.11 TRATAMENTO DE DADOS

Há uma grande variedade de técnicas de preparação de dados que podem ser usadas em um projeto de modelagem preditiva. Em alguns casos, a distribuição dos dados ou os requisitos de um modelo de aprendizado de máquina podem sugerir o tipo de preparação de dados necessária, embora isso raramente seja o caso, dada a complexidade e a alta dimensionalidade dos dados, a necessidade cada vez maior de novos aprendizados a respeito de algoritmos e limitações humanas (BROWNLEE, 2020).

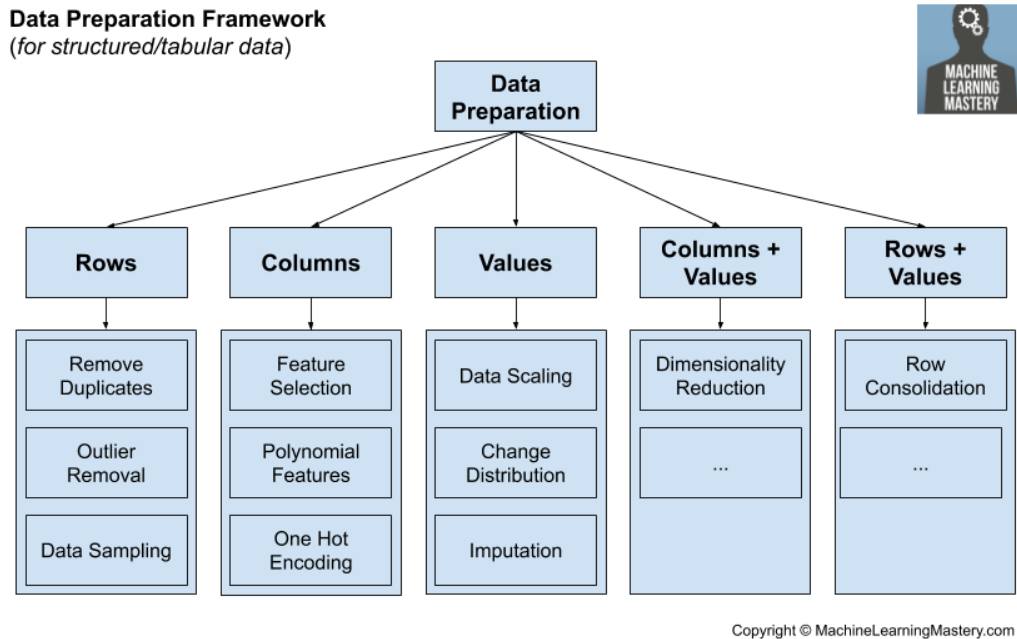
A preparação de dados refere-se à transformação de dados brutos em um formato mais adequado à modelagem preditiva. Isso pode ser necessário porque os próprios dados contêm erros. Também porque os algoritmos escolhidos têm expectativas quanto ao tipo e distribuição dos dados. Para tornar a tarefa de preparação de dados ainda mais desafiadora, é comum que a preparação de dados necessária para obter o melhor desempenho de um modelo preditivo possa não ser óbvia, e pode distorcer ou violar as expectativas do modelo que está sendo usado. Como tal, é comum tratar a escolha e configuração da preparação de dados aplicada aos dados brutos como mais um parâmetro do *pipeline* de modelagem a ser ajustado. Esse enquadramento de preparação de dados é muito eficaz na prática, pois permite que você use técnicas de pesquisa automática como pesquisa em grade e pesquisa aleatória para descobrir etapas de preparação de dados não intuitivas que resultam em modelos preditivos hábeis (BROWNLEE, 2020).

A preparação de dados eficaz requer que as técnicas de preparação de dados disponíveis sejam organizadas e consideradas de forma estruturada e sistemática. Isso permite que você garanta que as técnicas de abordagem sejam exploradas para seu conjunto de dados e que as técnicas potencialmente eficazes não sejam puladas ou ignoradas. Isso pode ser alcançado usando uma estrutura para organizar técnicas de preparação de dados que consideram seu efeito no conjunto de dados brutos (BROWNLEE, 2020). Podemos considerar técnicas de preparação de dados que operam em cada um desses níveis: Preparação de dados para linhas, colunas, valores, colunas e valores ou linhas e valores, conforme ilustrado na Figura 3.

Preparação de dados para linhas é um grupo composto por técnicas de preparação de dados que adicionam ou removem linhas de dados. Essas técnicas costumam ser usadas para aumentar um conjunto de dados de treinamento limitado ou para remover erros ou ambigüidade

do conjunto de dados. Esta classe de técnicas de preparação de dados também inclui algoritmos para identificar e remover outliers dos dados. Essas são linhas de dados que podem estar longe do centro de massa de probabilidade no conjunto de dados e, por sua vez, podem não ser representativas dos dados do domínio.

Figura 3 - Estrutura de preparação de dados



Fonte: Brownlee (2020).

O grupo de preparação de dados para colunas é o conjunto de técnicas de preparação de dados que adicionam ou removem colunas de dados. Essas técnicas são frequentemente necessárias para reduzir a complexidade (dimensionalidade) de um problema de previsão ou para desempacotar variáveis de entrada compostas ou interações complexas entre recursos. Isso inclui técnicas que usam estatísticas para pontuar a relevância das variáveis de entrada para a variável de destino com base no tipo de dados de cada uma. Isso também inclui técnicas de seleção de recursos que testam sistematicamente o impacto de diferentes combinações de variáveis de entrada na habilidade preditiva de um modelo de aprendizado de máquina (BROWNLEE, 2020).

O grupo de preparação de dados para colunas e valores contém técnicas de preparação de dados que alteram o número de colunas e os valores nos dados. A principal classe de técnicas utilizadas são as técnicas de redução de dimensionalidade que reduzem especificamente o número de colunas e a escala e distribuição de variáveis de entrada numéricas. Isso inclui métodos de fatoração de matrizes usados em álgebra linear, bem como algoritmos de

aprendizado múltiplos usados em estatísticas de alta dimensão (BROWNLEE, 2020).

Finalmente, o último grupo, preparação de dados para linhas e valores, é composto por técnicas de preparação de dados que alteram o número de linhas e os valores dos dados. Formado por algoritmos onde todas ou subconjuntos de linhas de dados do conjunto são substituídas por amostras de dados nos centros de agrupamento, referidos como os centróides de agrupamento.

3 ASPECTOS METODOLÓGICOS

Este capítulo caracteriza a pesquisa e os procedimentos empregados para sua realização. Em resumo, descreve como a pesquisa foi executada. O capítulo é dividido em duas seções. A Seção 3.1 traz a caracterização da metodologia de pesquisa, seguida pela Seção 3.2 onde o procedimento metodológico adotado é apresentado.

3.1 CARACTERIZAÇÃO DA PESQUISA

De acordo com as classificações de pesquisa de Goretti; Biaggini (2014), a presente proposta de pesquisa é aplicada, quantitativa, prescritiva e bibliográfica e experimental. Do ponto de vista de sua natureza a pesquisa é aplicada, pois visa gerar conhecimento para aplicação prática com foco em um problema específico. Do ponto de vista da forma de abordagem a pesquisa é quantitativa, pois pretende-se medir o índice de acerto do método gerado, comparando-se com a técnica atual. Sob o ponto de vista dos objetivos da pesquisa, é prescritiva (KLEINA; RODRIGUES, 2014), pois irá propor uma solução que fornece resposta direta ao problema apresentado. Quanto ao ponto de vista dos procedimentos técnicos, a pesquisa é bibliográfica, pois é elaborada a partir do estudo de publicações, conforme levantamento bibliográfico apresentado no Apêndice A, e experimental, pois a solução foi testada de forma controlada a fim de avaliar seus efeitos (KLEINA; RODRIGUES, 2014).

3.2 PROCEDIMENTO METODOLÓGICO

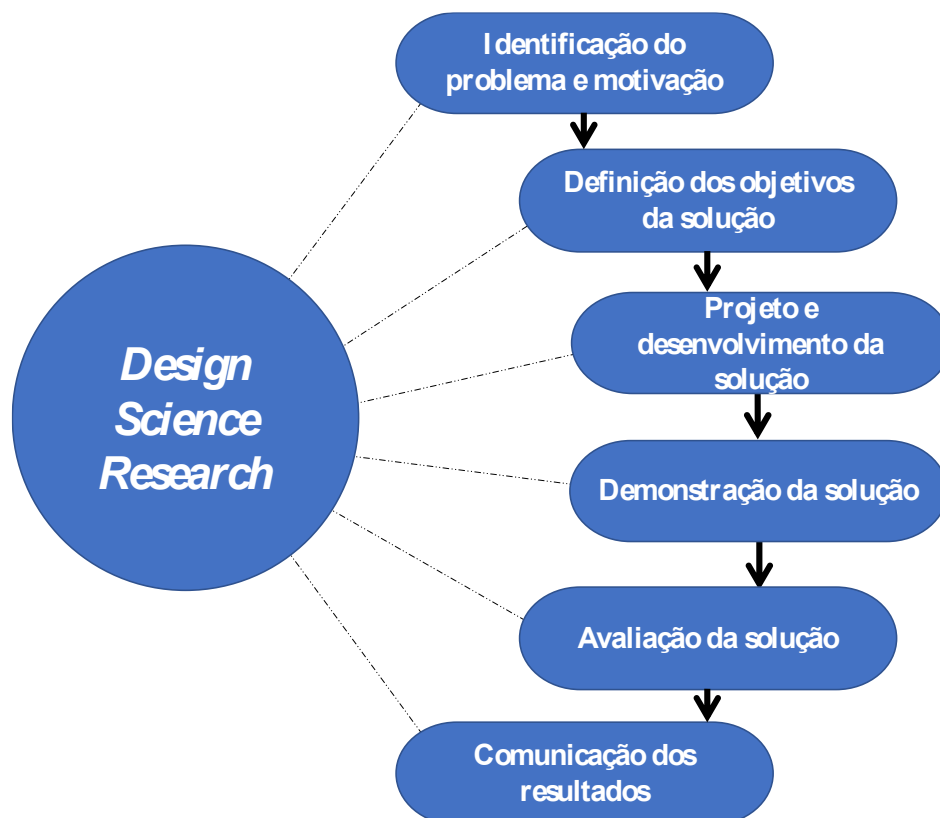
Para a execução do trabalho proposto, optou-se pela a abordagem metodológica Pesquisa Científica de Projeto (*Design Science Research Methodology – DSR*), proposta por Peffers *et al.* (2007). Esta metodologia incorpora princípios, práticas e procedimentos necessários para realizar pesquisas científicas e busca atingir três objetivos; i) fornecer um processo para a realização de pesquisas em ciência; ii) basear-se na literatura científica e disciplinas de referência; e iii) fornecer aos pesquisadores um modelo mental para estrutura e os resultados da pesquisa.

A metodologia DSR inclui seis etapas: identificação e motivação do problema, definição dos objetivos da solução, projeto e desenvolvimento, demonstração, avaliação e

comunicação, conforme ilustrado na Figura 4. Dessa forma, a presente seção busca apresentar o processo de execução da pesquisa sem abranger os resultados encontrados, conteúdo que será exposto no Capítulo 4.

Identificação e motivação de problemas significam respectivamente definir o problema de pesquisa específico e justificar o valor de sua solução. Como a definição do problema é usada para desenvolver um artefato que possa efetivamente fornecer uma solução, pode ser útil dividir o problema para que a solução proposta possa capturar sua complexidade. Justificar o valor da solução realiza duas funções: motiva o pesquisador e o público da pesquisa a entender e aceitar seus resultados, além de ajudar a entender o raciocínio associado à compreensão do pesquisador sobre o problema. Os recursos necessários para esta atividade incluem o conhecimento do estado do problema e a importância de sua solução (PEFFERS *et al.*, 2007).

Figura 4 - Modelo de processo DSR



Fonte: Adaptado de Peffers et al. (2007).

A etapa de definição dos objetivos da solução deve ser feita a partir do problema e conhecimento do que é possível e viável. Os objetivos podem ser quantitativos, como atingir uma solução melhor que as soluções atuais, ou qualitativos, como uma descrição de como se

espera que um novo artefato suporte soluções para problemas até agora não abordados. Os objetivos devem ser inferidos racionalmente a partir da especificação do problema. Conforme mencionado, os recursos necessários para isso incluem o conhecimento do estado do problema e das soluções atuais, se houverem, e sua eficácia.

A etapa de projeto e desenvolvimento trata da criação de um artefato. Artefatos são potencialmente construções, modelos ou métodos ou novas propriedades de recursos técnicos, sociais ou informacionais (JÄRVINEN, 2007). Conceitualmente, um artefato de pesquisa de design pode ser qualquer objeto projetado, no qual uma contribuição de pesquisa seja incorporada ao design. Essa atividade inclui determinar a funcionalidade desejada do artefato e sua arquitetura e, em seguida, criar o artefato real. Os recursos necessários para passar dos objetivos para o design e o desenvolvimento incluem o conhecimento da teoria que pode ser aplicada em uma solução.

Deve ser demonstrado o uso do artefato para resolver uma ou mais instâncias do problema. Isso pode envolver seu uso em experimentação, simulação, estudo de caso, prova ou outra atividade apropriada. Os recursos necessários para a demonstração incluem conhecimento eficaz de como usar o artefato para resolver o problema (PEFFERS *et al.*, 2007).

Avaliação mede o quão bem o artefato suporta a solução para o problema. Essa atividade envolve a comparação dos objetivos de uma solução com os resultados reais observados do uso do artefato na demonstração. Requer conhecimento de métricas e técnicas de análise relevantes. Dependendo da natureza do local do problema e do artefato, a avaliação pode assumir várias formas. Pode incluir itens como uma comparação da funcionalidade do artefato com os objetivos da solução, medidas quantitativas objetivas de desempenho, como orçamentos ou itens produzidos, resultados de pesquisas de satisfação, *feedback* do cliente ou simulações. Pode incluir também medidas quantificáveis do desempenho do sistema, como tempo de resposta ou disponibilidade (PEFFERS *et al.*, 2007).

Conceitualmente, a avaliação pode incluir qualquer evidência empírica apropriada ou prova lógica. No final desta atividade, os pesquisadores podem decidir se devem voltar à atividade de design e desenvolvimento para tentar melhorar a eficácia do artefato ou continuar com a comunicação e deixar melhorias adicionais nos projetos subsequentes (PEFFERS *et al.*, 2007).

Finalmente é importante a comunicação do problema e sua importância, o artefato, sua utilidade e novidade, o rigor de seu design e sua eficácia a pesquisadores e outras audiências relevantes. Nas publicações de pesquisas acadêmicas, os pesquisadores podem usar a estrutura desse processo para estruturar o artigo, assim como a estrutura nominal de um processo de

pesquisa empírica (definição de problemas, revisão de literatura, desenvolvimento de hipóteses, coleta de dados, análise, resultados, discussão e conclusão) (PEFFERS *et al.*, 2007).

O DSR está estruturado em uma ordem nominalmente sequencial; no entanto, não há expectativa de que o pesquisador proceda nesta ordem de atividades. Na realidade, ele pode realmente começar quase que em qualquer etapa. O pesquisador pode em seguida avançar na sequência proposta se a ideia para a pesquisa resultar da observação do problema ou de pesquisas futuras sugeridas em um artigo de um trabalho anterior (PEFFERS *et al.*, 2007). O detalhamento das etapas do DSR é apresentado nas próximas seções.

3.2.1 Identificação do Problema e Motivação

A identificação do problema iniciou partindo-se de uma análise bibliométrica e sistêmica sobre planejamento e programação de produção utilizando processos de aprendizado de máquina e ciência de dados na indústria (Apêndice A). Nesta investigação foi utilizado o processo *Knowledge Development Process – Constructivist* (ProKnow-C), proposto por Ensslin; Ensslin; Pinto (2013). Através desta análise foi possível identificar os principais problemas de pesquisa abordados na literatura, os métodos adotados para solução dos problemas e as oportunidades de pesquisa.

3.2.2 Definição dos Objetivos da Solução

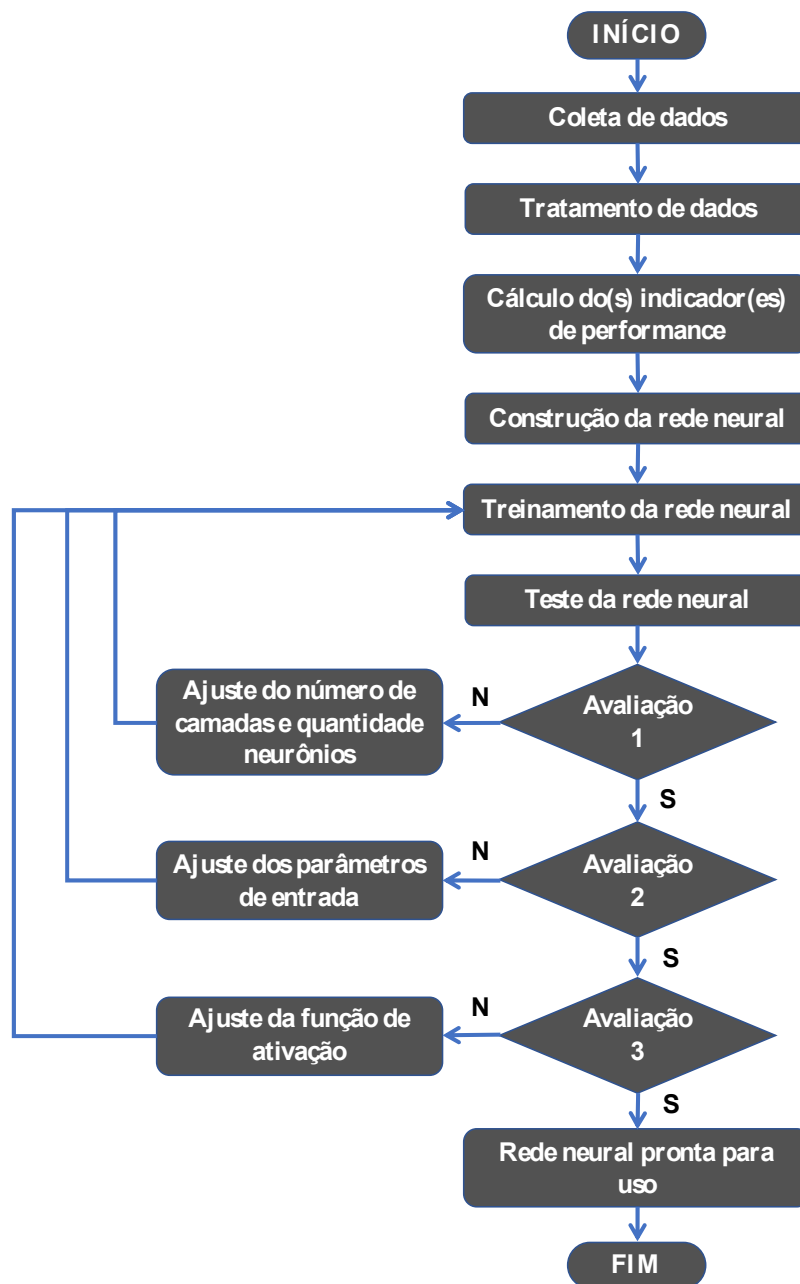
Após identificação do problema e sua motivação, o objetivo principal foi definido buscando preencher uma das lacunas de oportunidade encontradas considerando o que é possível e viável. A definição dos objetivos específicos da solução foi realizada através da correlação das entregas de cada fase da DSR, buscando estabelecer uma sequência lógica de trabalho.

3.2.3 Projeto e Desenvolvimento da Solução

Para a projeto e desenvolvimento da solução havia necessidade da utilização de dados de produção de peças de uma indústria atuante como MTO. Dessa forma, foi firmado acordo de fornecimento de dados de fabricação de peças protótipo entre a universidade e uma indústria de eletrodomésticos na região de Curitiba. Esta empresa parceira, permitiu acesso ao banco de dados do portal de gerenciamento de seu Departamento de Protótipos. Todavia o acordo não permitiu sua divulgação, visto que este banco continha dados sensíveis da empresa, despesas de projetos, custos de componentes, entre outros.

Assim, para a realização da etapa de projeto e desenvolvimento foram executadas as etapas ilustradas na Figura 5, sendo: coleta e tratamento de dados, cálculo dos indicadores de performance, construção, treinamento e teste da rede neural, avaliação do número de neurônios e quantidade de camadas, avaliação dos parâmetros de entrada e função de ativação e finalmente disponibilização da rede neural.

Figura 5 - Fluxograma do Desenvolvimento da Solução



Fonte: O próprio autor (2020).

A coleta de dados foi realizada no portal de solicitações de protótipos da empresa parceira. Verificou-se que era possível obter arquivos de dados em diversos formatos como, Adobe® Acrobat® (.pdf), Microsoft Word® (.docx) e Microsoft Excel® (.xlsx). Devido ao arquivo ser composto essencialmente por números, optou-se pelo formato .xlsx o que permitiu que todos os cálculos necessários fossem realizados com mais facilidade.

O tratamento dos dados foi realizado através da investigação de linhas e colunas da base. Foram encontrados diversos dados desnecessários para a execução da pesquisa, como solicitações de tarefas executadas por terceiros ou que foram canceladas no meio do processo, criando eventos com dados incompletos ou inconsistentes. Dessa forma, diversas colunas e linhas da planilha foram eliminados.

Em seguida foram calculados indicadores para medir a performance do artefato através da comparação entre cada método de cálculo de previsão. Foram selecionados os indicadores MAL, MSL, PT e MT. Inicialmente foram calculados os valores para o método corrente utilizado no departamento de protótipos, pois estes serviram de referência para os demais. Em seguida foram calculados os valores para os dois métodos tradicionais, isto é, DTWK e DPPW.

A construção da rede neural foi realizada com a seleção de bibliotecas de manipulação de dados e upload de arquivos em formato Microsoft Excel®. Em seguida foi aplicada a verificação da correlação de Pearson. A seguir a base foi separada em duas partes; treinamento e outra de teste. A próxima etapa foi a construção da rede neural em si, através da programação da inicialização, especificação da camada de entrada, camada oculta e camada de saída da rede.

Em seguida a etapa de treinamento foi montada, sendo composta por compilação e treinamento da rede neural. No estágio de compilação foram definidas as métricas do algoritmo.

A etapa de teste da rede neural foi executada através de análise da evolução do erro gerado pelo comparativo entre os valores calculados pela rede neural e os valores realizados a cada iteração, com os dados de treinamento.

Três etapas de avaliação foram realizadas, buscando ajustar o número de camadas e neurônios, parâmetros de entrada e função de ativação. Através da variação do número de camadas e neurônios e comparação dos indicadores de performance gerados, foi possível compreender a evolução ou deterioração da rede neural. Em seguida cada um dos parâmetros de entrada foi eliminado buscando analisar sua contribuição ou prejuízo para a performance da rede. Finalmente, diversas funções de ativação, elementos utilizados para conferir capacidade não-linear ao processamento realizado pelas redes neurais (SCIKIT-LEARN, 2020), foram utilizadas buscando investigar também sua contribuição.

3.2.4 Demonstração da Solução

Conforme mencionado na seção anterior, foi feito um caso de aplicação no departamento de protótipos de uma empresa parceira. Este departamento foi selecionado pelo fato de estar alinhado às necessidades de pesquisa propostas, isto é, possui fabricação de peças MTO, conforme uma estação de manufatura. Verificou-se que neste departamento são fabricadas peças únicas, que demandam de planejamento e programação exclusivos, característica identificada com a proposta da dissertação.

Verificou-se que quase a totalidade das peças protótipo utilizadas na empresa é produzida ou tem sua produção controlada por este departamento. Todavia evidenciou-se que não há ferramenta para fornecimento de previsão de prazo de entrega das tarefas. A previsão é realizada através da análise do tamanho da fila, estimando o tempo decorrido nesta etapa, somado à estimativa de tempo de execução da tarefa, baseado na experiência dos operadores. Dessa forma é possível afirmar que não há um método matemático que forneça o prazo de entrega de tarefas, tampouco que este método seja capaz de ajustar-se em tempo real às oscilações da fabricação de peças e antever possíveis atrasos ou antecipações.

Conforme ilustrado na Figura 3, o processo de fabricação das peças é composto pelas etapas de recebimento das solicitações, avaliação, ingresso da solicitação na estação de manufatura, fila 1, programação da operação 1, realização da operação 1, fila 2 e realização da operação 2.

Foram utilizados dados reais do departamento de protótipos e executado o artefato para que fossem gerados dados de saída. Posteriormente foi feita análise dos resultados e avaliação da solução.

3.2.5 Avaliação da Solução

O objetivo desta seção é medir a eficiência do método para resolução do problema identificado. De acordo com March; Smith (1995), os métodos devem ser avaliados considerando a operacionalidade, ou seja, a capacidade de executar a tarefa pretendida; eficiência, isto é, verificar se o método funciona bem; generalidade, investigar se é possível aplica-lo em outros contextos; e finalmente facilidade de uso, avaliando a facilidade com que usuários utilizam o método.

O processo de avaliação foi dividido em duas categorias, uma quantitativa para avaliação da eficiência do método e outra qualitativa para avaliação dos critérios de facilidade de uso, generalidade e operacionalidade.

Conforme mencionado, para avaliação da eficiência do método foi utilizado um exame quantitativo através da comparação direta entre os indicadores de performance MAL, MSL, PT e MT. Para efeito de análise, para todos os quatro indicadores quanto menor, melhor. Dessa forma, dentro do comparativo, os menores valores apontam o melhor método. Os indicadores são determinados da seguinte maneira:

1. Variação média absoluta (MAL): mede a diferença absoluta média entre a data de conclusão real e a data de vencimento dos trabalhos.

$$L_i = c_i - d_i \quad (6)$$

$$MAL = \frac{1}{n} \left[\sum_{i=1}^n |L_i| \right] \quad (7)$$

Onde L_i e c_i representam respectivamente a variação da solicitação e a data real de conclusão da tarefa.

2. Variação quadrática média (MSL): mede a diferença quadrática média entre as datas reais de conclusão e as datas de vencimento prometidas para as tarefas.

$$MSL = \frac{1}{n} \left[\sum_{i=1}^n L_i^2 \right] \quad (8)$$

3. Percentual de tarefas atrasadas (PT): mede o percentual de tarefas que são finalizadas após a data prevista.

$$PT = \frac{n_T}{n} * 100 \quad (5)$$

Onde n_T é o número de tarefas atrasadas e n é o número de tarefas completas.

4. Atraso médio (MT): mede o atraso médio de trabalhos quando um trabalho é concluído após a data de vencimento atribuída. A diferença positiva entre seu tempo de conclusão e a data de vencimento é o atraso (T_i)

$$T_i = \text{Max}\{0, c_i - d_i\} \quad (6)$$

$$MSL = \frac{1}{n} \left[\sum_{i=1}^n T_i \right] \quad (7)$$

Foram comparados os valores obtidos através do método atual, de cada um dos quatro índices mencionados, com os demais métodos. Isto é, o comparativo foi feito entre os quatro

métodos, sejam eles: o método atual, o método DTWK, DPPW e a rede neural. Outro artifício utilizado para avaliação da eficiência foi o mapa de calor, técnica de visualização de dados que mostra a magnitude de um fenômeno com a variação de cores. O mapa construído possuía variação entre a cor vermelho, para o maior valor, até azul, para o menor valor. Escalas intermediárias de cores foram usadas para os valores dentro deste intervalo.

O ponto de partida foi o cálculo destes índices utilizando os dados de previsão com o método atual. Em seguida, os mesmos índices foram calculados com os dados dos métodos matemáticos DTWK e DPPW. Finalmente, foram calculados os índices com os dados da rede neural para enfim, realizar o comparativo entre todos os métodos.

Para a segunda categoria, foram realizados exames qualitativos para avaliação da facilidade de uso, generalidade e operacionalidade do método. Optou-se por este tipo de ferramenta em função das características do artefato a serem avaliadas, buscando-se mensurar os atributos subjetivos do mesmo. Isto foi realizado por meio da aplicação de questionários a especialistas. Os respondentes selecionados foram usuários solicitantes de peças protótipo ou profissionais de área de TI da empresa parceira, dependendo do assunto em análise. Baseando-se nos percentuais de respostas positivas ou negativas foi mensurado o método segundo estes critérios.

Para avaliação da facilidade de uso, foram selecionados engenheiros de produto, analistas e projetistas que trabalham diretamente com o desenvolvimento de produtos. Uma vez que estas pessoas demandavam conhecer as previsões de prazo de entrega de fabricação de peças protótipos em seu dia a dia, eram o público adequado para avaliar a facilidade de uso. Esta avaliação era composta por um questionário contendo sete perguntas, sendo seis alternativas e uma aberta com objetivo de possibilitar receber comentários gerais a respeito do artefato.

Para o tema de operacionalidade do método, foram selecionados profissionais de TI da empresa parceira. Esta seleção foi adotada devido ao fato destes profissionais conhecerem o portal de solicitações de protótipos e o contexto da hipotética aplicação do artefato.

Finalmente, para avaliação da generalidade do método foram escolhidos profissionais de TI de outras empresas. Esta opção deu-se para que pessoas fora do contexto da empresa parceria pudessem contribuir com uma visão mais ampla do uso do dispositivo em realidades de outras indústrias.

Os questionários de pesquisa foram construídos utilizando a ferramenta *Google Forms*, disponível na internet. Na primeira seção dos formulários, havia um texto e um vídeo de 4 minutos que explicavam o contexto, a justificativa e o objetivo da pesquisa, bem como,

apresentavam o método desenvolvido e o artefato. A Figura 6 apresenta imagem de um formulário de pesquisa. Essa ferramenta foi utilizada devido à sua gratuidade de uso e diversas funcionalidades como, compatibilidade com diversos navegadores, capacidade de inserção de vídeos e imagens que auxiliem na explicação do questionário.

Ao final de cada questionário, foi adicionado um campo para resposta livre do respondente, possibilitando uma oportunidade de postar comentários e sugestões relacionados ao tema em questão. Este campo recebeu diversas informações dos respondentes, com sugestões e opiniões a respeito do artefato. Algumas foram efetivamente incorporadas ao artefato, por exemplo a sugestão para inclusão do prazo em dias, pois não estava claro qual a unidade a que o artefato se referia.

Desta forma, procurou-se medir o desempenho geral do artefato, fruto do método proposto, avaliando sua relevância e entender se houve melhora na precisão da previsão da data de fabricação de peças em sistemas de manufatura.

Figura 6 - Imagem do questionário de avaliação de facilidade de uso

Avaliação de facilidade de uso

ESTE QUESTIONÁRIO FAZ PARTE DE UMA PESQUISA DE MESTRADO E BUSCA AVALIAR A FACILIDADE DE USO DO ARTEFATO PROPOSTO.

Para cada solicitação de protótipo recebida pelo Departamento de Protótipos é necessário fornecer ao solicitante uma previsão de prazo de entrega.

Atualmente, a previsão é feita baseando-se somente na experiência dos operadores. Dessa forma, em busca de maior assertividade na previsão informada ao usuário, está sendo proposto um método baseado em inteligência artificial.

Para isso, basta o solicitante informar alguns dados da tarefa durante o preenchimento da solicitação e em seguida receberá uma previsão de prazo de conclusão.


Como já deve ter experimentado o programa, clique em "Next" e preencha o formulário de avaliação. Caso tenha alguma dúvida veja o video explicativo e entre em contato com Paulo Modesti.

*** Required**

Email address *

Your email

Video explicativo para a etapa de avaliação da facilidade de uso da solução



Fonte: O próprio autor (2020).

3.2.6 Comunicação dos Resultados

Finalmente, é importante a comunicação das principais realizações do trabalho, ou seja, da identificação do problema e sua importância, do artefato, sua utilidade e novidade. Neste caso, a comunicação se dará através da elaboração de uma dissertação de mestrado e a publicação de um artigo científico em um periódico internacional relacionado ao tema de estudo. Além disso, será enviado um relatório técnico para a empresa parceira contendo os benefícios atingidos pela pesquisa, buscando estimular novas cooperações entre academia e indústria.

Após a apresentação dos aspectos metodológicos do trabalho como a caracterização da pesquisa e o procedimento metodológico abordado, o próximo capítulo apresenta os resultados obtidos e sua discussão.

4 RESULTADOS E DISCUSSÃO

Nas seções subsequentes são apresentados os resultados, isto é, o que foi encontrado durante o desenvolvimento de cada uma das etapas do framework da DSR para elaboração da pesquisa e construção do modelo proposto. Este capítulo é dividido em seis seções, sendo: identificação do problema e objetivos da solução, projeto e desenvolvimento da solução, demonstração, avaliação e análise dos resultados.

4.1 IDENTIFICAÇÃO DO PROBLEMA E MOTIVAÇÃO

Nesta primeira fase da DSR, conforme apresentado na Seção 3.2.1, foram prospectadas oportunidades e analisadas seu potencial de contribuição através da busca pelo conhecimento dos problemas. Esta investigação foi realizada essencialmente através de pesquisas bibliográficas, utilizando a técnica de estudo *Pro-Know-C*, abrangendo os temas de manufatura, programação de produção e inteligência artificial.

O estudo chegou a um portfolio de 32 artigos que foram analisados em busca de oportunidades de estudo. Entre elas destacaram-se: i) *Big data* e análises associadas como tecnologias-chave para extrair o conhecimento necessário e fornecer inteligência em todos os processos de engenharia; ii) a necessidade de estudos interdisciplinares relacionados à AI; iii) Customização de soluções tecnológicas aplicadas à manufatura e iv) Desenvolvimento de gêmeos digitais permitindo aos fabricantes gerenciar em tempo real as respostas entre um objeto físico e sua representação digital.


Optou-se por estudar a customização de soluções tecnológicas aplicadas à manufatura, utilizando redes neurais, buscando melhorar a previsibilidade de data de fabricação em sistemas de manufatura. Esta aplicação deu-se devido a dois fatores. Primeiro porque um modelo de redes neurais bem treinado pode fornecer um resultado de previsão em tempo real; e segundo, a criação de uma rede neural não requer a compreensão do relacionamento complexo entre as variáveis de entrada.

Conforme apresentado no Capítulo 3, o ambiente de aplicação do método escolhido foi o departamento de protótipos de uma empresa fabricante de eletrodomésticos da região de Curitiba. A aplicação deu-se como prova de conceito de um artefato fictício utilizando dados reais do departamento.

4.2 DEFINIÇÃO DOS OBJETIVOS DA SOLUÇÃO

O objetivo geral é apresentado no Capítulo 1, procurando nortear o desenvolvimento do trabalho. Já o primeiro objetivo específico busca identificar as principais soluções computacionais propostas na literatura científica para fornecer previsões de prazos de fabricação. Durante o levantamento bibliométrico, foi realizada uma análise dos principais métodos utilizados para previsão de prazo de entrega. Conforme ilustrado pela Figura 7, percebe-se que o método mais utilizado foi o de programação genética (*Genetic Programming* - GP), encontrado em 59% dos artigos. Em segundo lugar encontrou-se o método de redes neurais, aplicado a 14% dos artigos. Na terceira colocação encontram-se artigos que utilizam métodos matemáticos tradicionais de cálculo, em 9% do portfolio.

Figura 7 - Métodos utilizados para cálculo de prazo de entrega de tarefas em estações de manufatura



Fonte: O próprio autor (2020).

Os demais objetivos específicos também foram apresentados no Capítulo 1. Dessa forma, a construção do método, demonstração da utilidade e avaliação do método são detalhados nas seções a seguir.

4.3 PROJETO E DESENVOLVIMENTO DA SOLUÇÃO

A etapa de projeto e desenvolvimento da solução detalha o planejamento e construção do artefato. O método é composto pelas seguintes etapas: coleta e tratamento dos dados de

entrada, cálculo dos indicadores de performance, construção, treinamento, teste e avaliação da rede neural. Estas etapas são ilustradas pela Figura 5. Estas etapas são detalhadas a seguir:

4.3.1 Passo 1 – Coleta de dados

A coleta de dados iniciou através de análise do portal da empresa parceira, ilustrado na Figura 8, onde foram encontradas as informações necessárias para a execução das tarefas, como especificações técnicas, descrição das tarefas, etc. Além disso, registrava as datas de avanço das solicitações entre as etapas do processo de manufatura, assim como os responsáveis por este avanço.

Na data de 13/04/2020 foi feito o *download* do arquivo com 470kB, quando se constatou que o histórico de dados era de aproximadamente 2 anos, visto que o primeiro registro datava de 13/06/2018. O arquivo era composto de 2.941 linhas e 30 colunas.

Figura 8 - Imagem do portal de solicitações de protótipos da empresa parceira

Caixa Entrada 1 Total	Orçamento 2 Total	Fila CNC 50 Total	Programação CNC 19 Total	Usinagem CNC 5 Total	Fila Bancada 9 Total	Execução Bancada 13 Total	Concluído 89 Total
297894 Raphael Santos 10/08/2020 Suporte de Painel	298834 Ricardo Quincozas 01/08/2020 ICE STOCK	297471 Gabriel Silva 14/08/2020 MONTAGEM MOCKUP SKU19 09/08/2020	297886 Guilherme Cuman 07/08/2020 Thomas Lower FRE Drawer P60 03/09/2020	297890 Guilherme Cuman 07/08/2020 Antonio Drawer Rail RH 03/09/2020	297885 Guilherme Cuman 07/08/2020 Oswaldo Upper FRE Drawer P60 03/09/2020	297572 Guilherme Cuman 07/08/2020 Robson Anderson Crisper Drawer P60 26/08/2020	297762 Guilherme Cuman 07/08/2020 Oswaldo Anderson Insero frontal gaveta crisper BZ 19/08/2020
	296893 Thiago Silva 09/08/2020 PONTEIRA TRAVESSA	297348 Bruno Mattos 02/08/2020 Molde Esquerdo Externo - Foamed Box 11/08/2020	292191 Guilherme Cuman 20/04/2020 Antonio F&F drawer base BZ 11/05/2020	297891 Guilherme Cuman 07/08/2020 Antonio Drawer Rail LH 03/09/2020	297579 Augusto Silva 31/08/2020 Antonio Retrabalho porta refrigerador MD Glass 26/08/2020	297562 Augusto Silva 31/08/2020 Cleverton Pintura porta VCZ MD Glass 12/08/2020	297573 Guilherme Cuman 07/08/2020 Oswaldo Joseel Rail Shelf P60 26/08/2020
	297350 Bruno Mattos 02/08/2020 Molde Direito Externo - Foamed Box 11/08/2020	296395 Juliyane Grybogi 31/07/2020 Antonia REMOVABLE BOTTOM COVER 480 13/08/2020	297821 Rodrigo Conceicao 14/08/2020 Robson Prototipo - FAST ADAPT EXT 03/09/2020	299106 Dyogo Liebel 11/08/2020 REFORÇO TRAVESSA INFERIOR 04/08/2020	297583 Augusto Silva 31/08/2020 Cleverton Pintura porta FRZ MD Glass 12/08/2020	297586 Dyogo Liebel 05/07/2020 Robson Sergio support handle 31/08/2020	

Fonte: Electrolux do Brasil S.A. (2020).

4.3.2 Passo 2 – Tratamento de dados

A análise inicial dos dados foi feita através da aplicação de filtros na planilha onde cada uma das 30 colunas foram examinadas. As colunas consideradas desnecessárias foram eliminadas. Em seguida as linhas da planilha foram investigadas. Linhas incompletas ou com

dados inconsistentes foram eliminadas. Ao final desta análise, a planilha continha 17 colunas e 1.942 linhas. A imagem do cabeçalho da planilha é apresentada na Figura 9.

Figura 9 - Imagem do cabeçalho da planilha

SP	DATA ABERTURA SOLICITAÇÃO	DATA OBJETIVO	DATA CONCLUSÃO ESTIMADA	PRODUÇÃO	TIPO DE SERVIÇO	STATUS	DESCRIÇÃO	MATERIAL	QUANTIDADE DE PEÇAS	DATA INÍCIO EXECUÇÃO	DATA ENTRADA FILA CNC	DATA INÍCIO PROGRAMAÇÃO	DATA INÍCIO USINAGEM	DATA ENTRADA FILA BANCADA	DATA INÍCIO EXECUÇÃO BANCADA	DATA CONCLUSÃO SOLICITAÇÃO
----	---------------------------	---------------	-------------------------	----------	-----------------	--------	-----------	----------	---------------------	----------------------	-----------------------	-------------------------	----------------------	---------------------------	------------------------------	----------------------------

Fonte: O próprio autor (2020).

Partindo do conjunto de dados obtido até este ponto, iniciou-se o processo de construção de uma nova base, preparando as informações de maneira adequada para utilização da rede neural, visto que esta trabalha essencialmente com números.

Buscou-se, através desta nova base de dados, descrever de maneira mais detalhada possível as tarefas solicitadas e as condições sob as quais seriam executadas. Assim, a nova base foi dividida em dois grupos, o primeiro composto por informações da tarefa e o segundo, da estação de trabalho. A primeira categoria foi constituída pelos seguintes itens: quantidade de peças, tamanho da peça, complexidade da tarefa, material da peça e número de operações a serem executadas.

A quantidade de peças solicitadas em cada tarefa foi extraída diretamente da base original, simplesmente copiando cada célula linha a linha. Devido à grande variação de tamanho entre as peças fabricadas, criou-se uma coluna para o tamanho da peça. Através do nome da peça foi criado uma fórmula visando tornar discreta essa informação. Foram estabelecidas as seguintes classes para seu tamanho: pequeno, para o qual foi atribuído o valor “1”, médio o valor “2” e grande igual a “3”. Com o mesmo pensamento, criou-se uma coluna chamada complexidade da tarefa. Baseando-se nas descrições, outra fórmula a classificou em: baixa, média e alta complexidade, atribuindo respectivamente os valores 1, 2 e 3.

A seguir, realizou-se uma análise dos materiais das quais as peças haviam sido fabricadas. Foram encontrados 20 diferentes materiais que foram agrupados em três categorias. Considerando o contexto do departamento, o grupo 1 foi classificado como de alta usinabilidade, sendo composto por: ABS, Elastômero, EPS, MDF, Outros, PLA, Policarbonato, Resinas de poliuretano com densidade $0,3\text{g/cm}^3$, $0,7\text{g/cm}^3$ e $1,2\text{g/cm}^3$. Para este grupo, foi criada uma fórmula que retornasse o valor “1”. O grupo 2, categorizado como de média usinabilidade, constituído pelos seguintes materiais: Acrílico, Latão e Cobre a fórmula retornou

o valor “2”. Finalmente, para o grupo 3, composto por Aço carbono, Aço inox, Nylon, Poliacetal, Polipropileno, Teflon e Vidro, considerados materiais de baixa usinabilidade, a fórmula retornou o valor “3”.

Constatou-se que cada solicitação possuía duas possíveis operações de fabricação na estação de trabalho. Havia solicitações que eram executadas apenas na subestação de acabamento (chamada de Bancada) e outras que percorriam as subestações de usinagem e acabamento (chamada de CNC+Bancada). Dessa forma, foi construída uma fórmula que retornasse o valor “1” para operações de acabamento e “2” para operações de usinagem seguidas de acabamento.

A segunda categoria de dados, conforme mencionado anteriormente, trata das condições sob as quais as solicitações foram executadas, isto é, informações da estação de trabalho no momento de ingresso da solicitação. Este grupo foi composto pelos seguintes itens: número de tarefas na fila 1, fila 2, número total de tarefas em fila, número de tarefas na estação de manufatura, taxa de entrada de solicitações, tempo médio de processamento na subestação 1, subestação 2 e total e número médio de operações.

O número de tarefas nas filas 1 e 2 foi calculado através da diferença de datas entre as etapas das solicitações. O número de tarefas na fila 1 foi calculado pela quantidade de solicitações anteriores, cuja data de entrada em programação fosse inferior à data de entrada na fila 1 da solicitação em questão. Da mesma maneira, o número de tarefas na fila 2 foi levantado calculando o total de solicitações precedentes cuja data de início de execução de acabamento fosse inferior à data de entrada na fila 2 da solicitação em estudo. A quantidade total de tarefas em fila foi calculada com a soma das solicitações na fila 1 e fila 2.

A quantidade total de tarefas na estação de manufatura foi levantada utilizando-se o mesmo raciocínio anteriormente citado, porém considerando outras variáveis. Calculando-se o número de solicitações com data de conclusão anterior à data de início da execução da tarefa em análise, chegou-se ao número desejado.

Para os cálculos apresentados a seguir, decidiu-se estabelecer como intervalo temporal o período de 30 dias. Esta escolha deu-se pelo fato de que a informação que circulava pelo departamento era de que as solicitações em média eram executadas em um prazo de 15 dias, logo optou-se por considerar um período maior de tempo para os cálculos do presente trabalho.

O tempo médio de processamento na subestação 1 foi calculado através da soma dos prazos de execução de todas as solicitações concluídas nos últimos 30 dias em relação à data da conclusão da solicitação em estudo. De maneira análoga foi calculado o tempo médio de

processamento na subestação 2. A seguir, o tempo médio de processamento total foi obtido com a soma simples dos tempos médios de cada subestação.

Por fim, dois últimos parâmetros foram calculados. A taxa de entrada de solicitações foi calculada através do levantamento da quantidade média de solicitações recebidas; e o número médio de operações considerando quais operações eram executadas. Ambas levaram em conta o período dos últimos 30 dias em relação à solicitação em análise.

Uma coluna adicional foi incluída na base final com as informações do prazo real em que a tarefa foi executada, para permitir que a rede neural executasse as operações de treinamento e teste.

4.3.3 Passo 3 – Cálculo dos indicadores de performance

O cálculo dos indicadores de performance foi realizado considerando como referência o método corrente do departamento de protótipos da empresa parceira, chamado método atual. Em seguida foram calculados os valores para os métodos chamados tradicionais. O resultado é apresentado na Tabela 2. Observa-se que o método atual não é o melhor em três de quatro indicadores. O método DTWK aponta como melhor em dois indicadores, porém seu indicador MT é muito mais alto do que o método atual.

Tabela 2 – Valores dos indicadores para os métodos tradicionais

MÉTODO	Atual	DTWK	DPPW
MAL	✘ 9,43	✔ 9,15	✘ 10,72
MSL	✘ 175,72	✔ 145,39	✘ 177,75
PT	✘ 39,8%	✘ 38,0%	✔ 25,2%
MT	✔ 7,84	✘ 11,45	✘ 11,94

Fonte: O próprio autor (2020).

4.3.4 Passo 4 – Construção da rede neural

A construção da rede neural iniciou com a seleção das bibliotecas necessárias para manipulação de dados, chamada *pandas*. Além dessa, *numpy* e *tensorflow* foram outras

bibliotecas essenciais para o funcionamento da rede, conforme foi apresentado na sequência. A seguir, foi executado o upload do arquivo do Microsoft Excel® com os dados de entrada.

A base então foi separada por colunas em duas partes, uma com as colunas de dados e outra com uma única coluna contendo os prazos em que as tarefas foram realizadas. Uma etapa importante que ainda faz parte da preparação dos dados, mas que foi executada dentro da operação de construção da rede neural foi a normalização dos dados. Esta operação foi realizada nas colunas: Taxa de entrada de solicitações, Tempo médio de processamento total, Número médio de operações e Tempo médio de processamento subestação 1 e 2.

A seguir foi aplicado o mapeamento de correlação de Pearson na base de dados de entrada para verificar a interdependência entre as variáveis. O resultado é apresentado na Tabela 3. Depois foi realizada a separação da base em linhas. Oitenta por cento da base foi reservada para aleatoriamente para treinamento do algoritmo e vinte por cento para teste. Esta proporção foi utilizada baseando-se na observação de exemplos de outros algoritmos.

A próxima etapa foi a construção da rede neural em si, através da programação da inicialização, especificação da camada de entrada, camada oculta e camada de saída da rede. Na programação das camadas ocultas definiu-se iniciar com uma camada apenas, sendo composta por 6 neurônios. Ainda nesta etapa foi especificado a função de ativação; sendo selecionada a função “*relu*” para o início dos testes. A camada de saída foi desenhada contendo apenas um neurônio, visto que se trata de um problema de predição de prazos.

Tabela 3 - Valores obtidos após aplicação correção Pearson

Quantidade de peças da tarefa	1.00	0.04	-0.02	0.05	-0.05	-0.03	-0.02	-0.04	-0.03	-0.02	-0.02	-0.01	-0.01	-0.02
Tamanho da peça	0.04	1.00	0.42	-0.15	0.08	0.05	-0.08	-0.02	0.01	-0.01	0.05	0.03	0.03	0.04
Complexidade da peça	-0.02	0.42	1.00	-0.16	0.16	0.09	-0.04	0.04	0.06	0.06	0.08	0.06	0.05	0.06
Material da peça	0.05	-0.15	-0.16	1.00	-0.29	-0.19	0.13	-0.05	-0.03	-0.02	-0.05	-0.07	-0.01	-0.07
Número de operações	-0.05	0.08	0.16	-0.29	1.00	0.49	-0.26	0.19	-0.00	-0.02	0.00	0.08	-0.02	0.03
Número de tarefas fila 1	-0.03	0.05	0.09	-0.19	0.49	1.00	-0.11	0.69	0.34	0.07	0.34	0.24	0.43	0.01
Número de tarefas fila 2	-0.02	-0.08	-0.04	0.13	-0.26	-0.11	1.00	0.65	0.49	0.10	0.17	-0.15	0.02	0.23
Número total de tarefas nas filas	-0.04	-0.02	0.04	-0.05	0.19	0.69	0.65	1.00	0.62	0.12	0.39	0.07	0.35	0.18
Número de tarefas na estação	-0.03	0.01	0.06	-0.03	-0.00	0.34	0.49	0.62	1.00	0.36	0.47	0.23	0.35	0.31
Taxa de entrada de solicitações	-0.02	-0.01	0.06	-0.02	-0.02	0.07	0.10	0.12	0.36	1.00	0.05	-0.06	-0.09	0.18
Tempo médio de processamento total	-0.02	0.05	0.08	-0.05	0.00	0.34	0.17	0.39	0.47	0.05	1.00	0.30	0.76	0.63
Número médio de operações	-0.01	0.03	0.06	-0.07	0.08	0.24	-0.15	0.07	0.23	-0.06	0.30	1.00	0.43	-0.06
Tempo médio de processamento sub estação 1	-0.01	0.03	0.05	-0.01	-0.02	0.43	0.02	0.35	0.35	-0.09	0.76	0.43	1.00	-0.03
Tempo médio de processamento sub estação 2	-0.02	0.04	0.06	-0.07	0.03	0.01	0.23	0.18	0.31	0.18	0.63	-0.06	-0.03	1.00

Fonte: O próprio autor (2020).

4.3.5 Passo 5 – Treinamento da rede neural

Em seguida a etapa de treinamento foi montada, sendo composta por compilação e treinamento da rede neural. Utilizou-se como função otimizadora adam e como perda mean_squared_error. Para a operação de treinamento foi definido o tamanho do lote em 32 linhas, treinadas em 100 épocas.

4.3.6 Passo 6 – Teste e revisão da rede neural

Conforme comentado na seção 4.3.4, a rede foi inicialmente testada com a configuração de uma camada oculta composta por 6 neurônios. Esta configuração foi selecionada buscando a menor configuração possível de rede, buscando minimizar o tempo de processamento. Além disso, é possível que uma configuração mais enxuta permita um melhor resultado quando comparado com uma rede com mais camadas e neurônios. Dessa forma, visando explorar outras configurações que trouxessem melhores resultados, foram construídas diversas alternativas, com até 4 camadas ocultas contendo 192 neurônios cada, conforme Tabela 4. Para comparativo foram utilizados os indicadores de performance anteriormente citados. Foi possível verificar que a cada incremento de camada ou número de neurônios ocorreram oscilações nos resultados da rede, em comparação à configuração inicial. Por vezes ocorreu incremento e outras declínio na capacidade de predição do algoritmo, conforme apresentado na Tabela 5.

Tabela 4 - Cálculo número de camada versus de quantidade de neurônios

QUANTIDADE DE NEURÔNIOS	NÚMERO DE CAMADAS			
	1	2	3	4
6	1x6	2x6	3x6	4x6
12	1x12	2x12	3x12	4x12
24	1x24	2x24	3x24	4x24
48	1x48	2x48	3x48	4x48
96	1x96	2x96	3x96	4x96
192	1x192	2x192	3x192	4x192

Fonte: O próprio autor (2020).

A configuração de 4 camadas ocultas com 192 neurônios foi definida como final devido ao fato de, a partir deste momento, o tempo de processamento ser o dobro do tempo inicial, com 1 camada x 6 neurônios. Dessa forma, a configuração de 4 x 192 foi estabelecida como melhor alternativa.

Tabela 5 - Cálculo número de camada versus de quantidade de neurônios

	1x6	2x6	3x6	4x6
MAL	8,67	8,24	8,59	8,32
MSL	137,01	113,62	123,24	140,02
PT	32,4%	34,4%	33,9%	37,8%
MT	10,95	9,84	10,31	10,92

	1x12	2x12	3x12	4x12
MAL	9,02	8,65	8,04	8,05
MSL	364,11	124,35	114,18	111,54
PT	36,2%	32,4%	36,5%	37,8%
MT	12,50	9,91	9,24	9,36

	1x24	2x24	3x24	4x24
MAL	8,86	8,10	8,38	7,96
MSL	146,84	109,24	119,21	117,10
PT	32,6%	32,1%	33,9%	42,4%
MT	11,50	9,54	9,34	8,81

	1x48	2x48	3x48	4x48
MAL	7,87	9,91	8,33	7,84
MSL	111,00	676,79	143,32	120,34
PT	40,9%	30,3%	36,5%	41,1%
MT	9,47	14,10	9,07	8,64

	1x96	2x96	3x96	4x96
MAL	8,11	8,32	7,33	7,47
MSL	131,14	144,40	110,73	120,25
PT	36,8%	31,4%	51,9%	45,2%
MT	9,77	9,01	8,83	7,82

	1x192	2x192	3x192	4x192
MAL	8,27	8,16	8,16	7,31
MSL	249,87	200,15	121,03	118,51
PT	43,7%	43,2%	31,6%	40,9%
MT	10,70	9,96	8,95	7,89

Fonte: O próprio autor (2020).

Uma segunda exploração foi então realizada, alterando retirando parâmetros (colunas da planilha de dados) de entrada um a um para verificar seu impacto na performance da rede. Verificou-se que alguns parâmetros são vitais para o bom funcionamento da rede, visto que sua eliminação resultou em grande declínio no resultado da rede. Foram eles o número total de

tarefas nas filas e a quantidade de peças da tarefa, conforme apresentado na Tabela 6. Por fim, optou-se por manter todos os parâmetros visto que seu conjunto proporcionou o melhor resultado.

Tabela 6 - Parâmetros de entrada da rede neural

	Quantidade de peças da tarefa	Tamanho da peça	Complexidade da peça	Material da peça	Número de operações
MAL	8,45	7,45	7,20	7,56	7,97
MSL	122,58	117,82	111,96	118,84	132,44
PT	37,5%	43,2%	46,8%	38,3%	43,7%
MT	9,05	7,19	7,99	8,49	7,03

	Número de tarefas fila 1	Número de tarefas fila 2	Número total de tarefas nas filas	Número de tarefas na estação	Taxa de entrada de solicitações
MAL	7,61	7,49	7,89	7,77	7,33
MSL	132,19	125,73	236,13	120,36	123,66
PT	48,3%	47,6%	49,6%	39,1%	45,5%
MT	7,33	7,52	9,26	7,97	7,71

	Tempo médio de processamento total	Número médio de operações	Tempo médio de processamento subestação 1	Tempo médio de processamento subestação 2
MAL	8,41	7,56	7,52	7,34
MSL	143,83	131,24	125,48	110,57
PT	35,5%	43,4%	46,5%	47,0%
MT	7,85	7,49	8,11	7,20

Fonte: O próprio autor (2020).

A seguir foi investigada a influência da função de ativação no desempenho da rede neural. Dentre as dez funções de ativação encontradas, algumas tiveram resultado desastroso no desempenho como a função linear e *softmax* porém a função *swish* apresentou melhora em média de 3,7% superior à função originalmente escolhida, *relu*, de acordo com Tabela 7.

Tabela 7 - Comparativo da influência da função de ativação no desempenho da rede neural

	relu	tanh	swish	Softplus	softmax
MAL	7,31	7,19	7,06	7,78	9,16
MSL	118,51	108,36	115,92	133,04	161,00
PT	40,9%	45,0%	43,7%	37,8%	51,7%
MT	7,89	7,72	6,61	8,07	12,33

	sigmoid	Selu	linear	Hardsigmoid	elu
MAL	8,18	7,25	9,01	10,00	8,10
MSL	117,56	108,79	337,38	151,41	180,30
PT	34,7%	47,8%	40,4%	32,6%	50,6%
MT	8,42	6,99	12,95	12,57	8,47

Fonte: O próprio autor (2020).

4.3.7 Passo 7 – Disponibilização da rede neural

Após as diversas revisões da rede neural, chegou-se a uma configuração considerada mais adequada observando cada critério anteriormente apresentado sendo: número de neurônios, quantidade de camadas ocultas, parâmetros de entrada e função de ativação. Esta versão foi compilada e então montada uma interface para o usuário para que fosse possível realizar as atividades subsequentes do projeto, isto é, as etapas de teste e avaliação do artefato como pode ser visto no apêndice B desta dissertação.

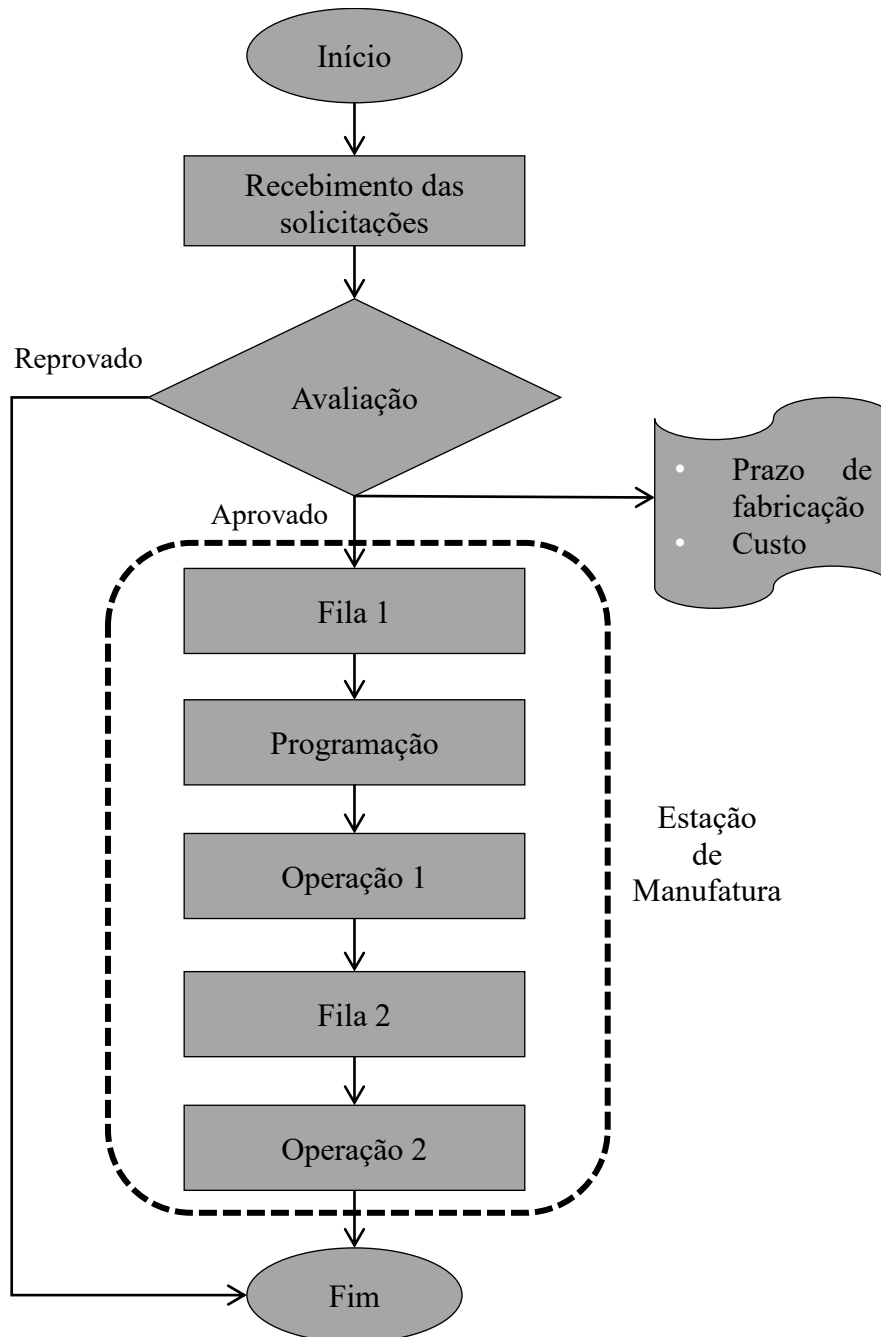
4.4 DEMONSTRAÇÃO

Conforme mencionado anteriormente, foi feito um caso de aplicação no departamento de protótipos de uma empresa parceira, fabricante de eletrodomésticos. Este departamento foi selecionado pelo fato de estar alinhado às necessidades de pesquisa propostas, isto é, possui fabricação de peças conforme uma estação de manufatura. Verificou-se que neste departamento são fabricadas peças únicas, que demandam de planejamento e programação exclusivos, característica identificada com a proposta do projeto. Dessa forma, a demonstração deste estudo foi guiada pelas necessidades desse diagnóstico.

Foi apurado que quase a totalidade das peças protótipos da empresa são produzidas ou controladas por este departamento. Todavia evidenciou-se que não há ferramenta para fornecimento de previsão de prazo de entrega das tarefas. A previsão é realizada através da

análise do tamanho da fila para execução e na experiência do responsável pela informação do prazo.

Figura 10 - Fluxo de produção no departamento de protótipos da empresa parceira



Fonte: Electrolux do Brasil S.A. (2020).

Dessa forma é possível afirmar que não há um método que forneça o prazo de entrega de tarefas, tampouco que seja capaz de ajustar-se em tempo real às oscilações da fabricação de peças e antever possíveis atrasos ou antecipações.

Conforme ilustrado anteriormente, na Figura 10, o processo de fabricação das peças é composto pelas etapas de recebimento das solicitações, avaliação, ingresso da solicitação na estação de manufatura, fila 1, programação da operação 1, realização da operação 1, fila 2 e realização da operação 2.

Assim, para execução demonstração, foram utilizados dados reais do departamento de protótipos e executado o algoritmo para que fossem gerados os dados de saída. Posteriormente foi feita análise dos resultados e avaliação da solução.

4.5 AVALIAÇÃO

Esta seção apresenta quais resultados foram obtidos na etapa de avaliação do artefato conforme metodologia DSR. Esta metodologia estabelece quatro critérios a serem examinados: eficiência, facilidade de uso, generalidade e operacionalidade do método.

Para avaliação da eficiência do artefato foi realizado um exame quantitativo através de um comparativo entre os indicadores de performance adotados para o presente trabalho. Foram comparados os valores obtidos para os indicadores para cada um dos métodos em estudo, sejam o método atual, dois métodos matemáticos, DTWK e DPPW e ainda a rede neural.

Para avaliação da facilidade de uso, operacionalidade e generalidade do método foi utilizada uma abordagem qualitativa, sendo realizada através de questionários enviados a pessoas selecionadas após experimentarem o artefato, conforme o objetivo de cada avaliação, de acordo com a Figura 11.

Figura 11 - Imagem da tela de interface com o usuário

The screenshot shows a window titled "DDPRED" with the following content:

Para conhecer a previsão de entrega da tarefa solicitada informe os dados solicitados.

Quantidade de peças da tarefa:

Tamanho da peça:

Complexidade da tarefa:

Material da peça:

Operações a serem realizadas:

OK

O prazo em dias, para entrega de sua tarefa é: 5

Fonte: O próprio autor (2020).

4.5.1 Eficiência

Para avaliação da eficiência da rede neural foi feita uma análise quantitativa através dos indicadores de performance já descritos, MAL, MSL, PT e MT.

O método DTWK apresentou uma performance ligeiramente melhor que o atual em três dos quatro indicadores, conforme apresentado na tabela 9. O valor de MAL foi 2,9% melhor que o método atual, sendo a menor evolução. Já o MSL teve a maior redução, de 17,3%. O percentual de atrasos (PT) teve uma redução de 4,5% em relação à referência. Por outro lado, o atraso médio (MT) teve um grande aumento, de 46,0% quando comparado ao método atual.

Para o método DPPW houve uma deterioração em três dos quatro indicadores. O PT teve uma grande redução de 36,8%. Todavia o MAL aumentou 13,7%, o MSL 1,2% e finalmente MT aumentou 52,3% sendo o maior acréscimo do método, conforme apresenta a Tabela 8.

Tabela 8 - Comparativo dos indicadores de performance entre o método atual e DTWK e DPPW

	Atual	DTWK	Δ	DPPW	Δ
MAL	9,43	9,15	-2,9%	10,72	13,7%
MSL	175,72	145,39	-17,3%	177,75	1,2%
PT	39,8%	38,0%	-4,5%	25,2%	-36,8%
MT	7,84	11,45	46,0%	11,94	52,3%

Fonte: O próprio autor (2020).

Em seguida foi montado um amplo mapa de calor com todos os resultados obtidos com as diversas configurações onde variou-se o número de camadas ocultas e neurônios por camada, conforme Tabela 9. O mapa de calor estabeleceu um comparativo linha a linha, ou seja, variando as cores de cada indicador de vermelho, para o maior valor a azul, para o menor valor da tabela. Dessa forma, foi facilitada a visualização das variações entre as diversas configurações de rede neural, além de comprovar qual configuração estabeleceu um melhor resultado em relação ao método atual.

Tabela 9 - Mapa de calor comparativo entre o método atual e diversas configurações de rede neural

	Atual	1	2	3	4
		1x6	2x6	3x6	4x6
MAL	9,43	8,67	8,24	8,59	8,32
MSL	175,72	137,01	113,62	123,24	140,02
PT	39,8%	32,4%	34,4%	33,9%	37,8%
MT	7,84	10,95	9,84	10,31	10,92
		1x12	2x12	3x12	4x12
		9,02	8,65	8,04	8,05
		364,11	124,35	114,18	111,54
		36,2%	32,4%	36,5%	37,8%
		12,50	9,91	9,24	9,36
		1x24	2x24	3x24	4x24
		8,86	8,10	8,38	7,96
		146,84	109,24	119,21	117,10
		32,6%	32,1%	33,9%	42,4%
		11,50	9,54	9,34	8,81
		1x48	2x48	3x48	4x48
		7,87	9,91	8,33	7,84
		111,00	676,79	143,32	120,34
		40,9%	30,3%	36,5%	41,1%
		9,47	14,10	9,07	8,64
		1x96	2x96	3x96	4x96
		8,11	8,32	7,33	7,47
		131,14	144,40	110,73	120,25
		36,8%	31,4%	51,9%	45,2%
		9,77	9,01	8,83	7,82
		1x192	2x192	3x192	4x192
		8,27	8,16	8,16	7,31
		249,87	200,15	121,03	118,51
		43,7%	43,2%	31,6%	40,9%
		10,70	9,96	8,95	7,89

Fonte: O próprio autor (2020).

A Tabela 10 apresenta o resultado final desta etapa inicial de avaliação da eficiência do artefato foi uma redução de 22,5% no MAL, redução bastante expressiva considerando que

este indicador leva em conta atrasos ou antecipações das datas de vencimento, isto é, qualquer que seja a variação em relação à data prevista é apontada como erro. O segundo indicador teve uma melhora de 32,6%, a maior redução apresentada. Em seguida, analisou-se o percentual de atrasos (PT), que teve aumento de 2,6% sendo considerado como um sinal negativo, visto que este indicador aponta a quantidade de solicitações que sofrem atrasos. Finalmente, o atraso médio (MT) apresentou-se equivalente ao método atual, com 0,6% de aumento, considerado estável. A Tabela 10 apresenta o resumo final desta etapa de comparativos.

Tabela 10 - Comparativo entre o método atual, DTWK e a rede neural

	Atual	DTWK	Δ	4x192	Δ
MAL	9,43	9,15	-2,9%	7,31	-22,5%
MSL	175,72	145,39	-17,3%	118,51	-32,6%
PT	39,8%	38,0%	-4,5%	40,9%	2,6%
MT	7,84	11,45	46,0%	7,89	0,6%

Fonte: O próprio autor (2020).

Uma segunda etapa de análise da eficiência foi realizada, comparando-se diversos resultados do algoritmo entre si, eliminando um a um os parâmetros de entrada visando otimizar o resultado encontrado pelo artefato. Através da construção de um novo mapa de calor com objetivo de facilitar a análise através da visualização da tabela, conforme apresentado na tabela 10, foi possível verificar que alguns dados de entrada são imprescindíveis para o bom funcionamento da rede neural. Por exemplo, eliminando-se a quantidade de peças da tarefa, há uma piora expressiva no MAL de mais de 15%; ainda, eliminando o número total de tarefas nas filas todos os indicadores aumentam expressivamente, indicando que estes dados são muito importantes para a boa performance do artefato. Dessa forma, optou-se por não eliminar nenhum parâmetro de entrada, mantendo os 14 iniciais. A Tabela 11 apresenta os resultados.

Uma terceira análise foi realizada, variando as funções de ativação da rede neural. Cada uma das 10 funções foi testada e os valores obtidos para os indicadores foram comparados com a função “*relu*”, a mais usada para problemas de regressão não linear. A Tabela 12 apresenta os valores do comparativo. Duas funções de ativação mostraram resultados muito pior que a inicial. Foram: a função “*linear*”, comprovando que não se trata de uma regressão linear, onde praticamente todos os indicadores pioraram em relação à função de referência e, a função “*softmax*” onde todos os indicadores tiveram grande decadência em relação à função

“relu”. Por outro lado, outras funções obtiveram melhora expressiva, como a função “selu”, “tanh” e “swish”.

Tabela 11 - Comparativo dos indicadores com a eliminação de parâmetros de entrada

	Rede neural com 14 parâmetros de entrada		Eliminado Quantidade de peças da tarefa		Eliminado Tamanho da peça		Eliminado Complexidade da peça		Eliminado Material da peça	
	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ
MA L	7,31	--	8,45	15,6%	7,45	1,9%	7,20	-1,5%	7,56	3,4%
MSL	118,5	--	122,6	3,4%	117,8	-0,6%	112,0	-5,5%	118,8	0,3%
PT	40,9%	--	37,5%	-8,2%	43,2%	5,7%	46,8%	14,5%	38,3%	-6,3%
MT	7,89	--	9,05	14,7%	7,19	-8,8%	7,99	1,3%	8,49	7,6%

	Eliminado Número de operações		Eliminado Número de tarefas fila 1		Eliminado Número de tarefas fila 2		Eliminado Número total de tarefas nas filas		Eliminado Número de tarefas na estação	
	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ
MA L	7,97	-8,3%	7,61	4,2%	7,49	2,5%	7,89	8,0%	7,77	6,3%
MSL	132,4	-10,5%	132,2	11,5%	125,7	6,1%	236,1	99,2%	120,4	1,6%
PT	43,7%	-6,5%	48,3%	18,2%	47,6%	16,4%	49,6%	21,4%	39,1%	-4,4%
MT	7,03	12,2%	7,33	-7,1%	7,52	-4,7%	9,26	17,3%	7,97	1,0%

	Eliminado Taxa de entrada de solicitações		Eliminado Tempo médio de processamento total		Eliminado Número médio de operações		Eliminado Tempo médio de processamento subestação 1		Eliminado Tempo médio de processamento subestação 2	
	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ
MA L	7,33	-0,3%	8,41	15,1%	7,56	3,4%	7,52	3,0%	7,34	0,4%
MSL	123,7	-4,2%	143,8	21,4%	131,2	10,7%	125,5	5,9%	110,6	-6,7%
PT	45,5%	-10,2%	35,5%	-13,2%	43,4%	6,3%	46,5%	13,8%	47,0%	15,1%
MT	7,71	2,3%	7,85	-0,5%	7,49	-5,0%	8,11	2,9%	7,20	-8,7%

Fonte: O próprio autor (2020).

Assim, optou-se por utilizar a função “Swish” devido à sua melhor performance em três dos quatro indicadores, denotando que esta possui uma melhor adaptação aos dados de entrada deste problema em específico.

Tabela 12 - Comparativo de indicadores de diferentes funções de ativação

	Relu		Tanh		swish		softplus		Softmax	
	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ
MAL	7,31	--	7,19	-1,6%	7,06	-3,4%	7,78	6,4%	9,16	25,4%
MSL	118,5	--	108,36	-8,6%	115,92	-2,2%	133,04	12,3%	161,00	35,8%
PT	40,9%	--	45,0%	10,1%	43,7%	6,9%	37,8%	-7,5%	51,7%	26,4%
MT	7,89	--	7,72	-2,1%	6,61	-16,2%	8,07	2,2%	12,33	56,3%

	Sigmoid		Selu		linear		hardsigmoid		Elu	
	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ	Valor	Δ
MAL	8,18	12,0%	7,25	-0,8%	9,01	23,3%	10,00	36,8%	8,10	10,9%
MSL	117,56	-0,8%	108,79	-8,2%	337,38	184,7%	151,41	27,8%	180,30	52,1%
PT	34,7%	-15,1%	47,8%	17,0%	40,4%	-1,3%	32,6%	-20,1%	50,6%	23,9%
MT	8,42	6,7%	6,99	-11,4%	12,95	64,1%	12,57	59,3%	8,47	7,4%

Fonte: O próprio autor (2020).

Finalmente, a Tabela 13 apresenta o comparativo final da avaliação da eficiência do artefato onde a configuração ótima encontrada é composta por uma rede neural com 4 camadas ocultas, 192 neurônios em cada camada, utiliza 14 parâmetros de entrada e função de ativação “Swish”. Esta combinação proporciona uma redução de 25,1% no MAL, 34,0% no MSL, 15,7% no MT, porém aumento de 9,7% no PT.

Tabela 13 - Comparativo final entre o método atual, DTWK e rede neural

	Atual	DTWK	Δ	Rede neural com 4 camadas, 192 neurônios, função de ativação Swish e 14 parâmetros	Δ
MAL	9,43	9,15	-2,9%	7,06	-25,1%
MSL	175,72	145,39	-17,3%	115,92	-34,0%
PT	39,8%	38,0%	-4,5%	43,7%	9,7%
MT	7,84	11,45	46,0%	6,61	-15,7%


Fonte: O próprio autor (2020).

4.5.2 Facilidade de uso

Para avaliação da facilidade de uso do artefato foram selecionados funcionários da empresa parceira que possuíam algum tipo de relação com o desenvolvimento de produtos. Estas pessoas, engenheiros de produtos, especialistas, analistas ou projetistas prestadores de serviço já eram usuários recorrentes do portal de solicitações de produtos. Foram enviados quinze questionários para avaliação da facilidade de uso do artefato. Deste total, onze foram respondidos, equivalente a 73% do total, o que foi considerado um ótimo percentual de respostas.

A primeira pergunta foi “Como avalia os dados solicitados pelo programa?”. A maioria das respostas, 72,7% consideraram de fácil compreensão os dados requeridos em seu maior nível, nota 5 em uma escala de um a 5. Em segundo lugar, os restantes 27,3% também consideraram de fácil compreensão, porém com nota 4, conforme ilustra a Figura 12.


Figura 12 - Resultado das respostas da primeira pergunta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

A segunda pergunta foi “É fácil entender o conceito e a aplicação dos dados solicitados?”. Coincidentemente os percentuais de resposta foram os mesmos da pergunta anterior, isto é, 72,7% nota 5 e 27,3% nota 4, considerando de fácil entendimento o conceito e aplicação dos dados, ilustrado pela Figura 13.

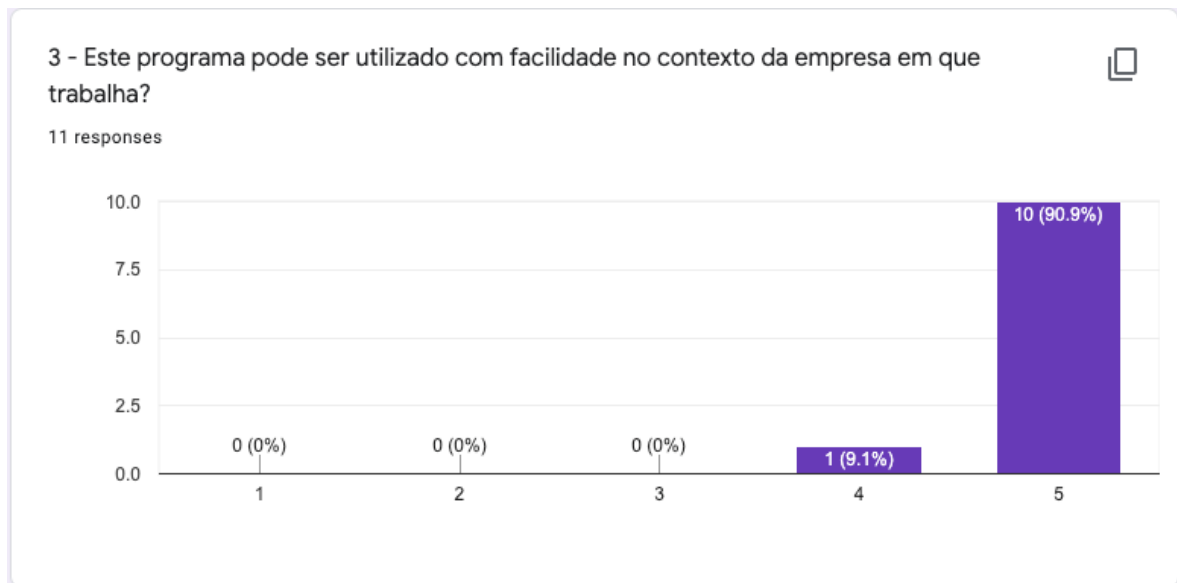
Figura 13 - Resultado das respostas da segunda pergunta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

A terceira pergunta foi “Este programa pode ser utilizado com facilidade no contexto da empresa em que trabalha?”. As notas foram respectivamente 90,9% nota 5 e 9,1% nota 4 que consideraram que o artefato pode ser aplicado com facilidade no contexto da empresa, conforme Figura 14.

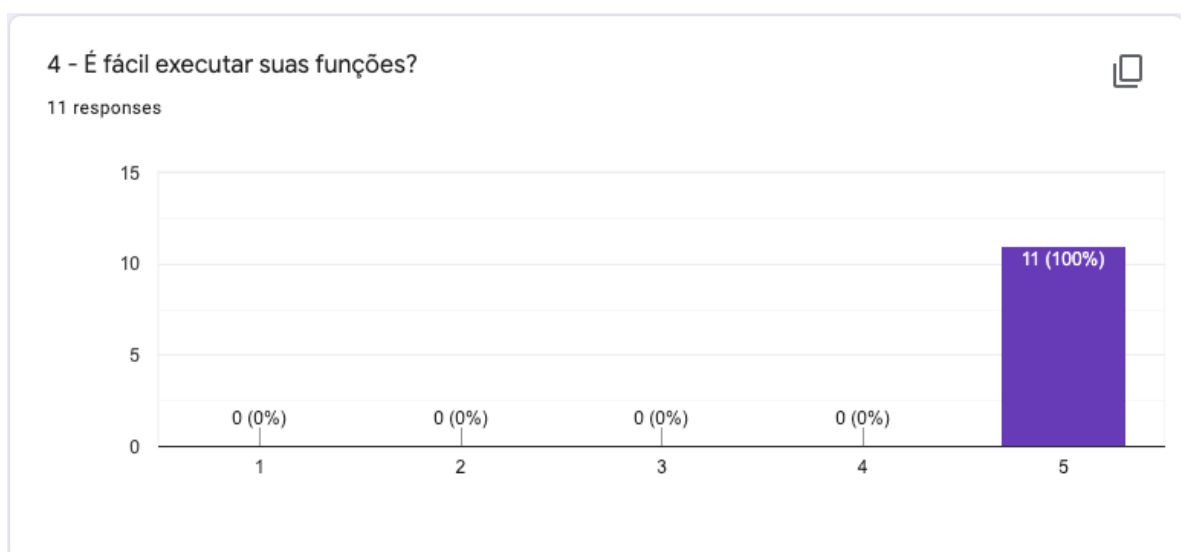
Figura 14 - Resultado das respostas da terceira pergunta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

Em relação à quarta pergunta, “É fácil executar suas funções?”, 100% dos respondentes atribuíram nota 5, isto é, consideraram sendo fácil de executar, apresentado na Figura 15.

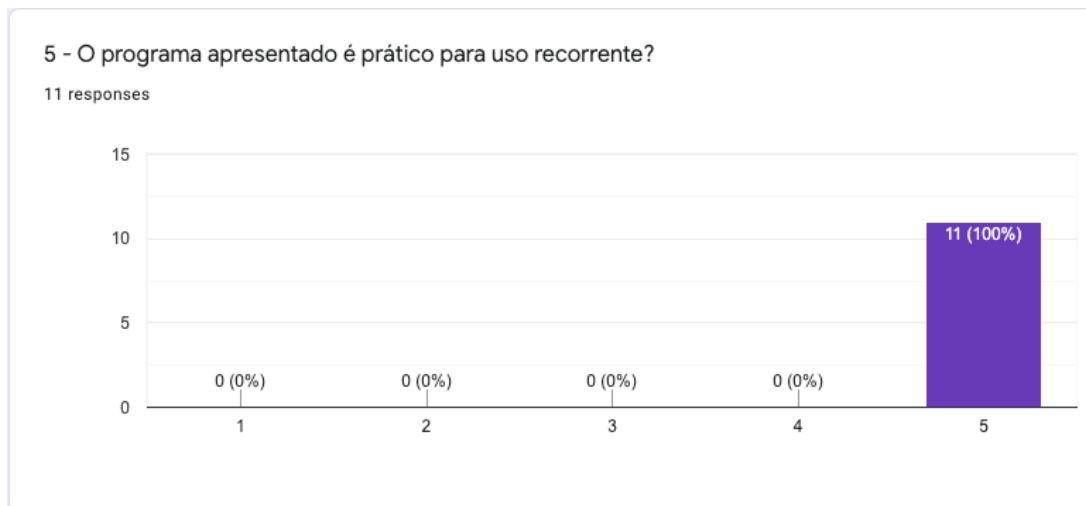
Figura 15 - Resultado das respostas da primeira quarta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

A quinta pergunta, “O programa apresentado é prático para uso recorrente?”, ilustrado na Figura 16 também recebeu nota 5 de 100% dos respondentes, significando que foi considerado muito prático para uso recorrente.

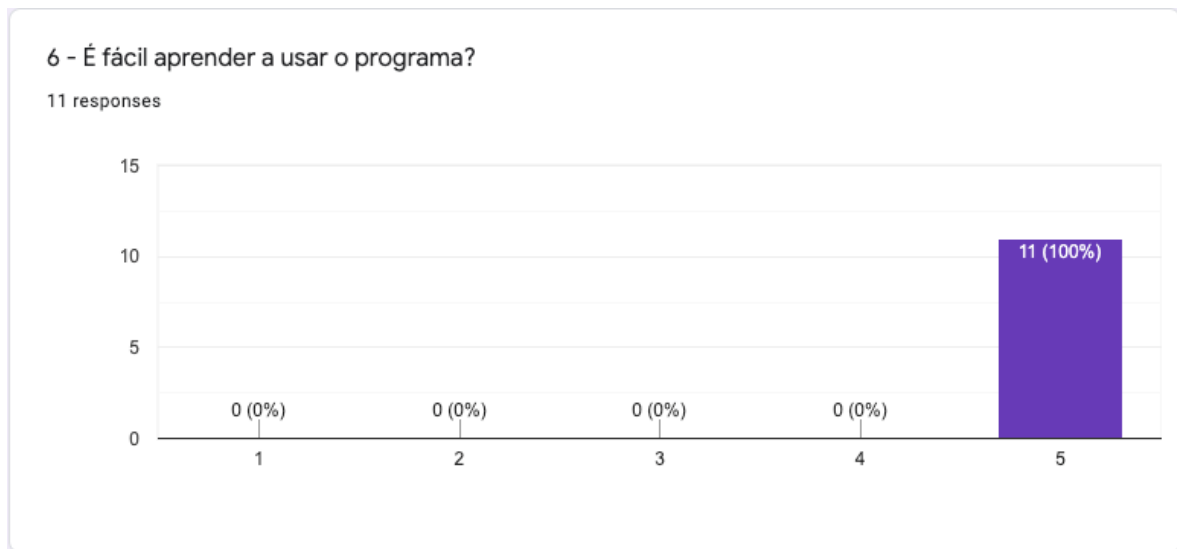
Figura 16 - Resultado das respostas da quinta pergunta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

Para a sexta pergunta, “É fácil aprender a usar o programa?”, 100% dos respondentes atribuíram nota 5, isto é, todos o consideraram de fácil aprendizado, ilustrado na Figura 17.

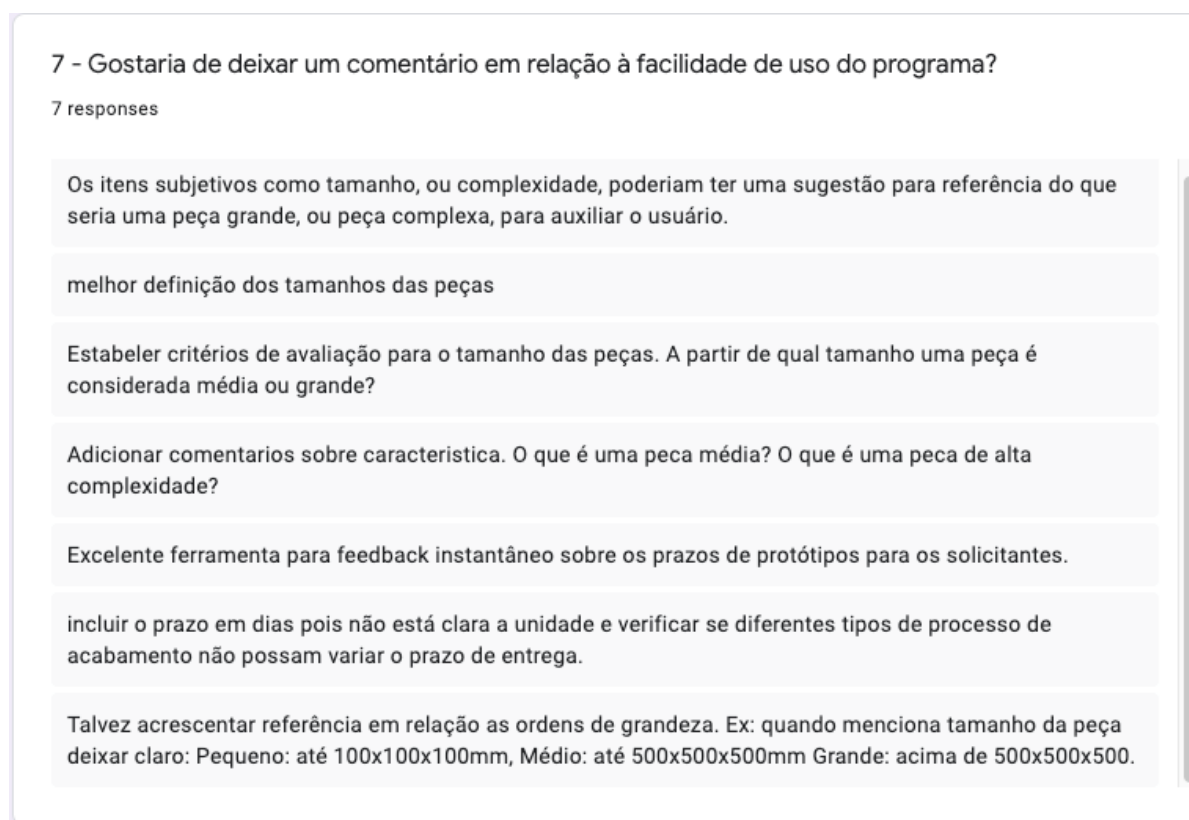
Figura 17 - Resultado das respostas da sexta pergunta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

Para a última questão, número 7 sendo uma pergunta aberta, “Gostaria de deixar um comentário em relação à facilidade de uso do programa?” houve sete observações. A primeira foi uma sugestão em relação às referências para facilitar a interpretação do tamanho da peça e complexidade da tarefa para minimizar a subjetividade das questões. O segundo comentário foi apenas “melhor definição dos tamanhos das peças”, referindo-se ao mesmo assunto, isto é, a subjetividade da questão de tamanho da peça. O terceiro comentário sugeriu “estabelecer critérios de avaliação para o tamanho das peças”, que também traz o tema da subjetividade do tamanho da peça. O quarto comentário, da mesma maneira, sugeriu adicionar informações a respeito do tamanho da peça e complexidade da tarefa. Já o quinto parecer trouxe um elogio à ferramenta, destacando o fato de o prazo ser fornecido instantaneamente aos solicitantes. A sexta observação, sugeriu a inclusão do prazo em dias, pois não estava clara na resposta fornecida pelo artefato. Além disso, trouxe um comentário a respeito de verificar se diferentes tipos de processo de acabamento teriam impacto no prazo de entrega da tarefa. Finalmente, o último parecer trouxe também uma sugestão a respeito de incluir uma referência para o preenchimento do tamanho da peça, ilustrado na Figura 18.

Figura 18 - Resultado das respostas da sétima pergunta do questionário de avaliação de facilidade de uso do artefato



Fonte: O próprio autor (2020).

Após o grupo de respondentes enviarem as respostas sobre a facilidade de uso do artefato, deu-se início o envio dos questionários para avaliação da generalidade do mesmo.

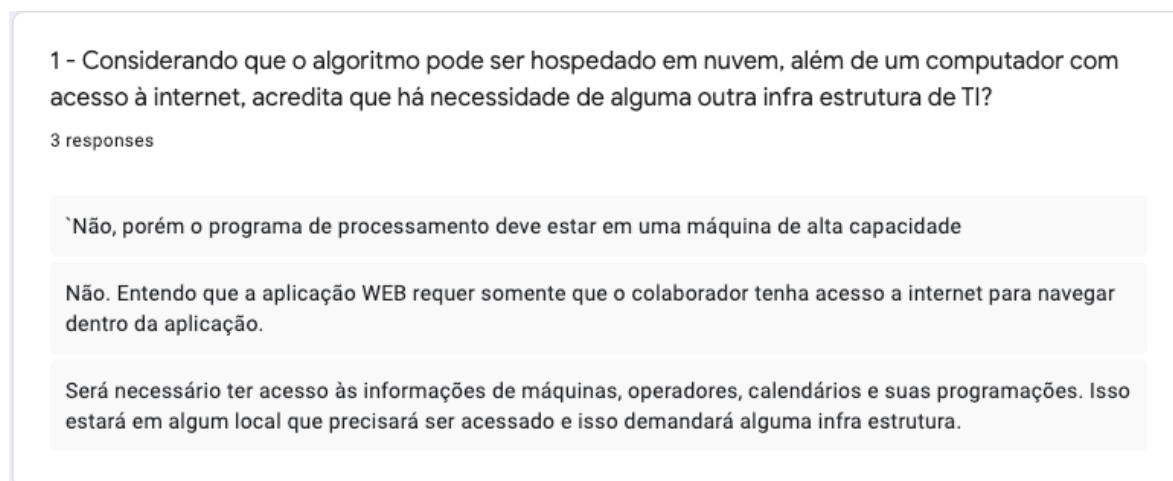
4.5.3 Operacionalidade

A avaliação da operacionalidade do artefato foi realizada através de questionários enviados a profissionais de TI da empresa parceira, visto conhecerem os sistemas implantados no departamento e também seu contexto de aplicação. O questionário continha quatro questões, sendo três questões abertas e uma de múltipla escolha.

Na primeira questão, “Considerando que o algoritmo pode ser hospedado em nuvem, além de um computador com acesso à internet, acredita que há necessidade de alguma outra infraestrutura de TI?” houve três comentários. O primeiro sugeriu que, apesar de não necessitar de outra estrutura de TI o programa de processamento deve estar em uma máquina de alta capacidade. Da mesma maneira o segundo também entendeu que não havia necessidade de

qualquer outra infraestrutura. Já o terceiro respondente sugeriu que, devido à necessidade de hospedagem de todas as informações a respeito de máquinas, operadores e outras informações, demandaria de alguma infraestrutura, apresentado na Figura 19.

Figura 19 - Resultado das respostas da primeira pergunta do questionário de avaliação de operacionalidade do artefato



Fonte: O próprio autor (2020).

A segunda pergunta, “Levando em conta que o algoritmo esteja funcionando na nuvem, em uma plataforma como Microsoft Azure®, acredita que há necessidade de algum procedimento de segurança adicional?”, os comentários foram: sim, depende do nível de confiabilidade da informação. Já o segundo afirmou que a segurança deve estar no repositório dos dados, desde que possuam alguma informação sensível do negócio. O terceiro sugeriu que sim, foi necessário algum procedimento de segurança adicional para as informações que são acessadas durante o uso do artefato, além das informações históricas necessárias ao aprendizado do algoritmo.

Figura 20 - Resultado das respostas da segunda pergunta do questionário de avaliação de operacionalidade do artefato

2 - Levando em conta que algoritmo esteja funcionando na nuvem, em uma plataforma como Microsoft Azure, acredita que há necessidade de algum procedimento de segurança adicional?

3 responses

sim. depende do nível de confiabilidade da informação

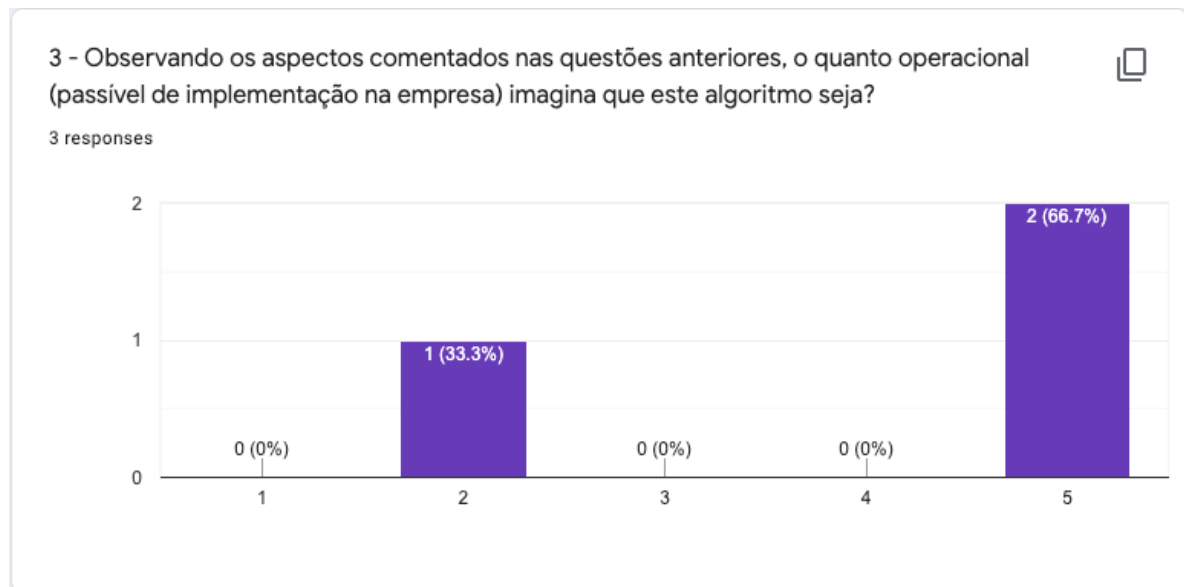
O segurança deve estar no repositório dos dados relacionados ao algoritmo se tiverem algum tipo de informação de negócio.

Sim, para que tenha acesso às informações transacionais e históricas que serão necessárias para alimentar o algoritmo e seu aprendizado.

Fonte: O próprio autor (2020).

Em relação à terceira pergunta, “Observando os aspectos comentados nas questões anteriores, o quanto operacional (passível de implementação na empresa) imagina que este algoritmo seja?”, 66,7% atribuíram nota 5, isto é, o artefato é plenamente passível de implementação. Por outro lado, 33,3% atribuíram nota 2, o que significa que, em sua opinião o artefato era pouco passível de implementação, apresentado na Figura 21.

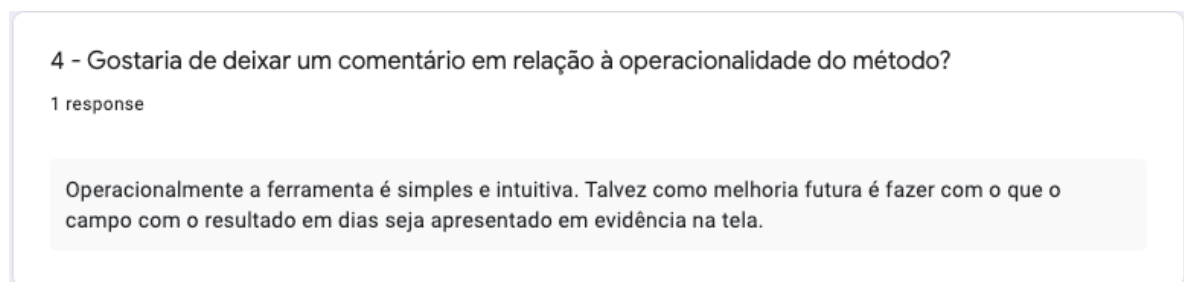
Figura 21 - Resultado das respostas da terceira pergunta do questionário de avaliação de operacionalidade do artefato



Fonte: O próprio autor (2020).

Para a última pergunta, ilustrada na Figura 22 “Gostaria de deixar um comentário em relação à operacionalidade do método?”, houve apenas um comentário. Foi sugerido destacar o resultado em dias na tela de interface, para que o mesmo ficasse mais claro ao usuário.

Figura 22 - Resultado das respostas da quarta pergunta do questionário de avaliação de operacionalidade do artefato



Fonte: O próprio autor (2020).


4.5.4 Generalidade

A avaliação da generalidade do artefato foi executada através de questionários enviados a especialistas em TI de outras empresas que não a empresa parceira, buscando uma

ponderação sob diferente ótica. Foi aplicado questionário com duas questões alternativas e uma questão aberta.

A primeira pergunta a respeito da generalidade foi: Qual é a generalidade do método, isto é, a possibilidade de aplica-lo em outros contexto ou indústrias? O resultado obtido foi de 66,7% consideram que o mesmo é “Muito genérico”, isto é, o método é abrangente o suficiente para aplicação em outras indústrias. Ainda, 33,3% julgam que o mesmo é “Bastante genérico”, perfazendo assim a totalidade dos respondentes, ilustrado Figura 23.


Figura 23 - Resultado das respostas da primeira pergunta do questionário de avaliação de generalidade do artefato



Fonte: O próprio autor (2020).

A pergunta número dois, ilustrado na Figura 24 busca medir o grau de restrição de implementação do método em outros contextos. O resultado foi de 66,7% considerando médio o nível de restrição de aplicação. O restante, 33,3%, considerou que há pouca restrição para implementação.

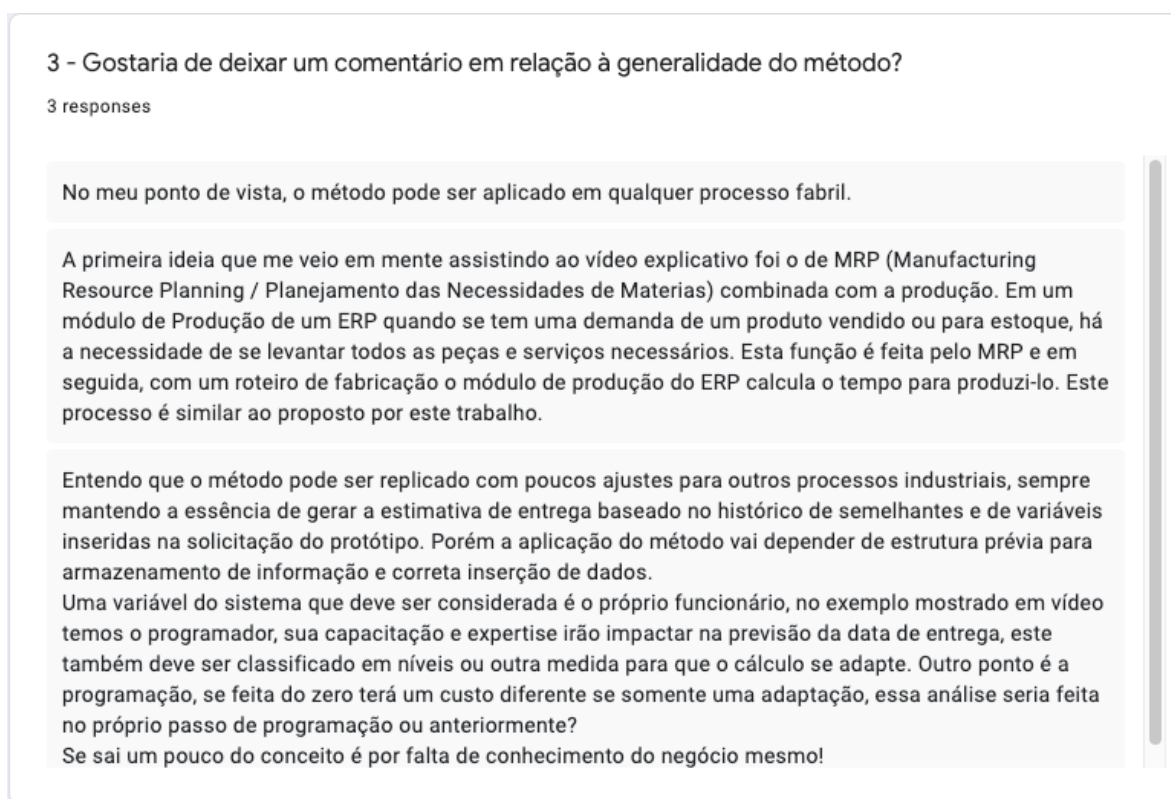
Figura 24 - Resultado das respostas da segunda pergunta do questionário de avaliação de generalidade do artefato



Fonte: O próprio autor (2020).

A terceira pergunta foi uma questão aberta, buscando coletar comentários em geral a respeito do método. Houve três comentários. O primeiro comentário apontou a opinião do respondente que acredita que o método pode ser aplicado em qualquer processo fabril. O segundo comentário trouxe uma ótica de um sistema MRP combinado com ERP para o levantamento do prazo de produção, demandando assim de uma estimativa de material somada a uma estimativa de prazo de fabricação para alimentar o sistema. No comentário do terceiro respondente, este apresenta-se de acordo com a generalidade do método, porém fazendo ressalvas a respeito da necessidade dos devidos ajustes na estrutura de dados conforme cada aplicação. Uma segunda análise do respondente é feita a respeito das variáveis que a capacitação e expertise dos operadores trazem para a estação de manufatura, visto que podem interferir diretamente no prazo de execução das tarefas, ilustrado na Figura 25.

Figura 25 - Resultado das respostas da terceira pergunta do questionário de avaliação de generalidade do artefato



Fonte: O próprio autor (2020).

4.6 ANÁLISE DOS RESULTADOS

Durante o exame do comparativo da eficiência do artefato, partindo da referência dos indicadores do método atual, verificou-se que o método matemático DTWK apresentou uma melhor performance em três indicadores, podendo então ser considerado como um possível avanço em relação ao método atual, conforme apresentado na Tabela 8. Já o método DPPW apresentou performance significativamente menor em relação ao método atual. Dessa forma, o método DTWK passou a ser adotado como uma segunda referência, como meta a ser superada pela rede neural.

Ao comparar as diversas configurações de rede neural, variando a quantidade de camadas ocultas e número de neurônios em cada uma delas, e montado o mapa de calor, foi possível encontrar uma melhora expressiva dos indicadores desta configuração inicial da rede em relação ao método atual, conforme apresentado na Tabela 9. Esta configuração de rede

neural com 4 camadas e 192 neurônios superou amplamente os resultados do método atual com exceção do percentual de atrasos, cujo resultado praticamente permaneceu inalterado.

O resultado desse comparativo inicial, apresentado na Tabela 10, mostra que a rede neural teve um desempenho amplamente vantajoso não somente em relação ao método atual, mas também em relação ao DTWK com exceção do PT que ficou ligeiramente acima. Dessa forma, foi possível considerar que a rede neural na configuração inicial se apresenta como melhor método.

Na segunda análise da rede, em relação aos parâmetros de entrada, apesar de os valores da correlação de Pearson apresentarem altos índices para as variáveis número de tarefas nas filas 1 e 2 e o total de tarefas nas filas e também os tempos médios de processamento nas subestações 1 e 2 e o tempo médio de processamento total, não houve incremento no desempenho da rede quando foi realizada a eliminação de qualquer parâmetro. Em função disso, optou-se por manter todos os parâmetros de entrada.

Na terceira análise da rede, onde explorou-se diversas funções de ativação, quando comparados os valores dos indicadores da rede em relação à função *relu*, a função *swish* apresentou uma melhora expressiva em três dos quatro indicadores, sendo que neste, PT houve piora no resultado em 6,9%. De qualquer maneira, dado que as reduções nos dois principais indicadores, MAL e MSL foram expressivas, optou-se por adotar esta função como componente da configuração final da rede neural.

Finalmente, para avaliação da eficiência do artefato, chegou-se na Tabela 13 que mostra o comparativo final entre os métodos atual, DTWK e a rede neural em sua configuração otimizada. Percebe-se que houve grande avanço nos principais indicadores, chegando à 34% para o MSL e 25,1% para o MAL. Todavia o valor do percentual de atrasos teve aumento de 9,7% o que não é ideal, mas que foi considerado aceitável tendo em vista a grande redução no atraso médio de 15,7%.

Destaca-se que durante a etapa de avaliação da eficácia, em testes manuais realizados com o artefato, este apresentou baixa precisão com dados de entrada extremos, isto é, altas quantidades de peça com elevados índices de complexidade e matérias de difícil usinabilidade. Estima-se que este comportamento seja devido a baixa quantidade desse tipo de combinação na base de dados utilizada para treinamento.

Durante o mês de julho de 2020 foram enviados 21 questionários, dos quais 17 foram respondidos. Isto equivale a uma taxa de resposta de mais de 80%, apresentado na Tabela 14. O principal motivo deste resultado positivo deve-se provavelmente ao tipo de abordagem da pesquisa, sendo realizado pessoalmente através da apresentação do tema, seguido de um vídeo

explicativo, a experimentação do artefato e por fim o envio do *link* do questionário por e-mail para que fosse preenchido posteriormente pelo respondente visando ter pareceres o mais imparciais possível.


Tabela 14 - Report com o número de questionários respondidos

	Número de questionários enviados	Número de questionários respondidos	Percentual de questionários respondidos em relação aos enviados
Profissionais de engenharia de produto	15	11	73%
Profissionais de TI	6	6	100%
TOTAL	21	17	81%

Fonte: O próprio autor (2020).

Para o estudo da performance da operacionalidade do método, realizado através de um questionário aplicado a funcionários da empresa parceira, obteve excelentes resultados. Em 100% das seis perguntas alternativas do questionário tiveram nota entre 4 ou 5, isto é, em análise mais ampla, ótimo ou excelente, conforme apresentado na Figura 26.

Figura 26 - Resumo das notas do questionário de avaliação de facilidade de uso do artefato




Fonte: O próprio autor (2020).

A avaliação da operacionalidade do artefato também foi realizada através de questionário, porém com questões abertas. A primeira buscou explorar a necessidade ou não de infraestrutura para funcionamento do artefato. O resultado foi de que não haverá necessidade de alguma infraestrutura adicional para funcionamento do artefato, visto que o mesmo estaria funcionando a partir de hospedagem em nuvem. A segunda pergunta do quesito operacionalidade, investigando a necessidade de procedimentos de segurança, teve a maior parte dos respondentes afirmando que sim é necessário ter algum procedimento, dado que o trânsito de informações na internet pode oferecer algum risco de vazamento de dados. Em relação à terceira pergunta, a maioria, 66,7% considerou o artefato passível de implementação, o que aponta que o mesmo é uma solução viável sob aspecto prático de implantação. Apesar da pequena quantidade de respondentes, três no total, devido ao fato de conhecerem o ambiente da empresa, considera-se que o artefato foi bem avaliado.

Da mesma maneira que os dois últimos aspectos em avaliação, a generalidade do artefato também foi medida através de questionário. Os resultados apontaram que, da maneira como foi desenvolvido, o artefato teria que necessariamente passar por ajustes para que fosse aplicado em outros contextos. Este parecer corrobora com trabalho no sentido em que cada aplicação de AI necessariamente precisa ter uma sólida base de dados proveniente da aplicação em questão para que seja possível obter um resultado coerente. Por outro lado, percebeu-se que o artefato é genérico o suficiente para adaptar e aplica-lo em outros contextos, conforme ilustrado na Figura 27.

Figura 27 - Resumo das notas do questionário de avaliação de generalidade do artefato



Fonte: O próprio autor (2020).

5 CONCLUSÃO

Ao analisar os resultados da pesquisa conduzida ao longo deste estudo percebe-se que o modelo proposto permite maior precisão nas previsões de data de entrega de tarefas em estações de manufatura em tempo real.

O artefato proposto é um método capaz de contribuir para o desenvolvimento da indústria de fabricação no sentido de melhorar a previsão de datas de fabricação, auxiliando na tomada de decisões relacionadas ao planejamento da produção. Este método utilizou técnicas de AI para construção de um artefato que permite maior agilidade para profissionais de programação de entregas e controle de empresas de manufatura.

A participação de uma empresa parceira, que forneceu dados reais de produção, deu subsídio para a criação, demonstração e avaliação do artefato. Isto foi muito importante para o desenvolvimento do método pois permitiu torna-lo mais confiável. O método tradicional utilizado pela empresa era extremamente subjetivo e lento, pois dependia de análise de cada tarefa solicitada para que fosse fornecido uma previsão de prazo de entrega.

Na etapa de demonstração da solução proposta o método se mostrou capaz de atender às necessidades apresentadas de maneira eficaz. A criação de uma interface amigável aos potenciais usuários facilitou a interpretação das questões demandadas pelo artefato. A partir das avaliações realizadas pode-se afirmar que o método proposto é relevante na medida em que atinge os resultados esperados, estando apto para auxiliar na previsibilidade de tarefas.

Este trabalho teve como foco o estudo de um departamento de produção de protótipos de uma empresa do ramo de eletrodomésticos, contudo há possibilidade de o método proposto ser ajustado, no sentido de incluir outros departamentos da empresa, ou até para outros segmentos da indústria, conforme avaliação de operacionalidade e generalidade.

A utilização do DSR neste projeto possibilitou a delimitação das etapas a serem seguidas para o desenvolvimento do artefato, além de facilitar que a solução proposta fosse aplicada em um ambiente real de manufatura.

Dentre as atividades realizadas para o desenvolvimento do artefato, a programação do algoritmo e construção da interface foram as atividades mais desafiadoras. Houve dificuldade para seleção do ambiente, linguagem de programação, bibliotecas e sintaxe da linguagem *Python* necessários para a construção do programa, visto que não eram do conhecimento do pesquisador.

Como limitações deste estudo, pode-se citar a subjetividade de algumas questões relacionadas à tarefa que foram solicitadas aos usuários, pois poderiam levar a problemas na performance do artefato uma vez que o dado de entrada pode não ser corretamente informado devido a incompreensão da questão por parte do usuário.

O método proposto forneceu apenas prazo de entrega para novas solicitações, não realizando um recálculo durante sua execução na estação de manufatura. O que limita a utilização de todo seu potencial.

Verificou-se também que o artefato não apresentava resultados satisfatórios para extremos, isto é, configurações de dados de entrada como: grandes quantidades de peças ou alto grau de complexidade, apresentavam previsões bastante divergentes em relação aos valores realizados. Acredita-se que isto ocorreu possivelmente devido à base de dados não possuir quantidade suficiente de dados para treina-lo adequadamente nestas configurações.

Por fim, apesar do método proposto exigir conhecimentos de uma linguagem de programação que permita sua adequada implantação, o mesmo apresenta potencial para aumentar o desempenho das atividades de analistas, projetistas e engenheiros de produtos e assim melhorar a eficiência, reduzir custos e aumentar a produtividade na indústria.

Diante disso, como recomendações futuras, sugere-se o desenvolvimento de uma ferramenta que possa atribuir a complexidade e tamanho da peça automaticamente através da coleta de informações do modelo 3D da mesma através de sua árvore de construção.

Outras sugestões são: o desenvolvimento de um método com previsão dinâmica; isto é, à medida em que uma solicitação avança de etapa, é recalculado e informado seu novo prazo de conclusão; também, pode-se estudar alternativas para melhorar a previsibilidade de extremos, como a inclusão de mais dados com estas características e remoção de *outliers*, haja visto que durante os testes de avaliação percebeu-se esta limitação.

Finalmente, sugere-se a realização de um estudo comparativo entre redes neurais com outros algoritmos de IA como algoritmos de aprendizagem baseados em árvore, algoritmos genéticos ou máquinas de vetores de suporte pois dessa forma seria possível entender qual técnica seria mais adequada para este contexto.

REFERÊNCIAS

- ALENEZI, Abdulrahman; MOSES, Scott A.; TRAFALIS, Theodore B. Real-time prediction of order flowtimes using support vector regression. **Computers and Operations Research**, [S. l.], v. 35, n. 11, p. 3489–3503, 2008. Disponível em: <https://doi.org/10.1016/j.cor.2007.01.026>
- ALPAY, Serafettin; YÜZÜGÜLLÜ, Nihat. Dynamic job shop scheduling for missed due date performance. **International Journal of Production Research**, [S. l.], v. 47, n. 15, p. 4047–4062, 2009. Disponível em: <https://doi.org/10.1080/00207540802043980>
- ANTUNES, Luciana Soares; SEHNEM, Simone; LIMA, Mauricio Andrade de. Análise do planejamento e controle de produção no setor de usinagem, corte e conformação em indústria Metal-mecânica. **Navus - Revista de Gestão e Tecnologia**, [S. l.], p. 22–34, 2014. Disponível em: <https://doi.org/10.22279/navus.2014.v4n1.p22-34.99>
- BAYKASOĞLU, Adil; GÖÇKEN, Mustafa; UNUTMAZ, Zeynep D. New approaches to due date assignment in job shops. **European Journal of Operational Research**, [S. l.], v. 187, n. 1, p. 31–45, 2008. Disponível em: <https://doi.org/10.1016/j.ejor.2007.02.020>
- BERGMANN, S.; FELDKAMP, N.; STRASSBURGER, S. Emulation of control strategies through machine learning in manufacturing simulations. **Journal of Simulation**, [S. l.], v. 11, n. 1, p. 38–50, 2017. Disponível em: <https://doi.org/10.1057/s41273-016-0006-0>. Acesso em: 10 ago. 2019.
- BLACKSTONE, John H.; PHILLIPS, Don T.; HOGG, Gary L. A state-of-the-art survey of dispatching rules for manufacturing job shop operations. **International Journal of Production Research**, [S. l.], v. 20, n. 1, p. 27–45, 1982. Disponível em: <https://doi.org/10.1080/00207548208947745>
- BLESSING, Lucienne; CHAKRABARTI, Amaresh. **DRM, a Design Research Methodology**. London: Springer, 2009. *E-book*. Disponível em: <https://doi.org/10.1007/978-1-84882-587-1>
- BROWNLEE, Jason. **Data Preparation for Machine Learning: Data Cleaning, Feature Selection, and Data Transforms in Python**. [S. l.]: Machine Learning Mastery, 2020. *E-book*.
- CHEN, Toly; WANG, Yi Chi. An iterative procedure for optimizing the performance of the fuzzy-neural job cycle time estimation approach in a wafer fabrication factory. **Mathematical Problems in Engineering**, [S. l.], 2013. Disponível em: <https://doi.org/10.1155/2013/740478>
- CHENG, T. C. E.; JIANG, J. Job shop scheduling for missed due-date performance. **Computers and Industrial Engineering**, [S. l.], v. 34, n. 2–4, p. 297–307, 1998. Disponível em: [https://doi.org/10.1016/s0360-8352\(97\)00317-3](https://doi.org/10.1016/s0360-8352(97)00317-3)
- COSTA, Jean Alves. **Controlador de Acesso para Ambientes com Gerenciamento Remoto**. 2019. - UFPR, [s. l.], 2019.

DOLTSINIS, Stefanos; FERREIRA, Pedro; LOHSE, Niels. Reinforcement learning for production ramp-up: A Q-batch learning approach. *In: 2012, Proceedings - 2012 11th International Conference on Machine Learning and Applications, ICMLA 2012.* [S. l.: s. n.] p. 610–615. Disponível em: <https://doi.org/10.1109/ICMLA.2012.113>

DOPICO, M. *et al.* A vision of industry 4.0 from an artificial intelligence point of view. **Proceedings of the 2016 International Conference on Artificial Intelligence, ICAI 2016 - WORLDCOMP 2016**, [S. l.], p. 407–413, 2016.

ENSSLIN, L.; ENSSLIN, S. R.; PINTO, H. M. Processo de investigação e análise bibliométrica: avaliação da qualidade dos serviços bancários. **Revista de Administração Contemporânea**, [S. l.], p. 325–349, 2013.

FAN, Hua Li *et al.* Survey of the selection and evaluation for dispatching rules in dynamic job shop scheduling problem. **Proceedings - 2015 Chinese Automation Congress, CAC 2015**, [S. l.], p. 1926–1931, 2015. Disponível em: <https://doi.org/10.1109/CAC.2015.7382819>

FANG, Weiguang *et al.* Big data driven jobs remaining time prediction in discrete manufacturing system: a deep learning-based approach. **International Journal of Production Research**, [S. l.], 2019. Disponível em: <https://doi.org/10.1080/00207543.2019.1602744>

FARID, Amro M. Measures of reconfigurability and its key characteristics in intelligent manufacturing systems. **Journal of Intelligent Manufacturing**, [S. l.], v. 28, n. 2, p. 353–369, 2017. Disponível em: <https://doi.org/10.1007/s10845-014-0983-7>

FINZI, Yaron *et al.* Shear Band Formation in Numerical Simulations Applying a Continuum Damage Rheology Model. **Pure and Applied Geophysics**, [S. l.], v. 170, n. 1–2, p. 13–25, 2013. Disponível em: <https://doi.org/10.1007/s00024-012-0463-y>

GANSTERER, Margaretha. Aggregate planning and forecasting in make-to-order production systems. **International Journal of Production Economics**, [S. l.], v. 170, p. 521–528, 2015. Disponível em: <https://doi.org/10.1016/j.ijpe.2015.06.001>

GARTNER. **Gartner Identifies the Top 10 Strategic Technology Trends for 2015.** [s. l.], 2014.

GORETTI, Cleide; BIAGGINI, Silva. **Metodologia de pesquisa e construção do conhecimento**. 4. ed. Florianópolis: UFSC, 2014. *E-book*.

HAUPT, R. A survey of priority rule-based scheduling. **OR Spektrum**, [S. l.], v. 11, n. 1, p. 3–16, 1989. Disponível em: <https://doi.org/10.1007/BF01721162>

HOLTHAUS, Oliver; RAJENDRAN, Chandrasekharan. Efficient dispatching rules for scheduling in a job shop. **International Journal of Production Economics**, [S. l.], v. 48, n. 1, p. 87–105, 1997. Disponível em: [https://doi.org/10.1016/S0925-5273\(96\)00068-0](https://doi.org/10.1016/S0925-5273(96)00068-0)

HSU, S. Y.; SHA, D. Y. Due date assignment using artificial neural networks under different shop floor control strategies. **International Journal of Production Research**, [S. l.], v. 42, n. 9, p. 1727–1745, 2004. Disponível em: <https://doi.org/10.1080/00207540310001624375>

IEDI. **Desenvolvimento Industrial em Perspectiva Internacional Comparada**. [S. l.: s. n.].

JAIN, KUNAL. **Scikit-learn(sklearn) in Python – the most important Machine Learning tool I learnt last year!**. [S. l.], 2015. Disponível em: <https://www.analyticsvidhya.com/blog/2015/01/scikit-learn-python-machine-learning-tool/>. Acesso em: 5 ago. 2020.

JÄRVINEN, Pertti. Action research is similar to design science. **Quality and Quantity**, [S. l.], v. 41, n. 1, p. 37–54, 2007. Disponível em: <https://doi.org/10.1007/s11135-005-5427-1>

JOSEPH, O. A.; SRIDHARAN, R. Analysis of dynamic due-date assignment models in a flexible manufacturing system. **Journal of Manufacturing Systems**, [S. l.], v. 30, n. 1, p. 28–40, 2011. Disponível em: <https://doi.org/10.1016/j.jmsy.2011.02.005>

KLEINA, Claudio; RODRIGUES, Karime S. B. **Metodologia Da Pesquisa E Do Trabalho**. 1. ed. Curitiba: IESDE BRASIL S/A, 2014. *E-book*.

KUBAT, Miroslav. **An Introduction to Machine Learning**. 2. ed. Coral Gables: Springer, 2017. *E-book*. Disponível em: <https://doi.org/10.1007/978-3-319-63913-0>

LEE, Kent D. **Python programming fundamentals**. 2. ed. Decorah: Springer, 2014. v. 48 *E-book*. Disponível em: <https://doi.org/10.5860/choice.48-5136>

LEE, Wen Chiung; WANG, Jen Ya; SU, Hsin Wei. Algorithms for single-machine scheduling to minimize the total tardiness with learning effects and two competing agents. **Concurrent Engineering Research and Applications**, [S. l.], v. 23, n. 1, p. 13–26, 2015. Disponível em: <https://doi.org/10.1177/1063293X14559750>

LLINAS, Rodolfo. **Biology of the Brain: From Neurons to Networks (Readings from Scientific American Magazine)**. Londres: W H Freeman & Co, 1989. *E-book*.

MARCH, Salvatore T.; SMITH, Gerald F. Design and natural science research on information technology. **Decision Support Systems**, [S. l.], p. 251–266, 1995.

MEDEIROS, Ciro Morais. **Comparação entre as Linguagens de Programação Suportadas pelo Google App Engine**. 2015. - UFRN, [S. l.], 2015.

MITCHELL, Tom M. **Machine Learning**. Portland: McGraw-Hill, 1997. *E-book*. Disponível em: https://doi.org/10.1007/978-3-642-21004-4_10

MOORE, David S.; NOTZ, William I.; FLIGNER, Michael A. **The Basic Practice of Statistics**. 7. ed. [S. l.]: W. H. Freeman, 2015. *E-book*. Disponível em: <https://doi.org/10.1198/tech.2001.s639>

MORCEIRO, Paulo Cesar; TESSARIN, Milene. **Desenvolvimento Industrial em Perspectiva Comparada**. [S. l.]: IEDI, 2019. Disponível em: https://www.iedi.org.br/artigos/top/estudos_industria/20190802_desind_intern_comp.html

MUKAKA, M. M. Statistics corner: A guide to appropriate use of correlation coefficient in medical research. **Malawi Medical Journal**, [S. l.], v. 24, n. 3, p. 69–71, 2012.

NGMTI. Strategic Investment Plan for the Model-Based Enterprise. **Next Generation Manufacturing Technologies Initiative**, [S. l.], v. 2.1, n. mai, 2005.

NGUYEN, Su *et al.* Genetic Programming for Evolving Due-Date Assignment Models in Job Shop Environments. **Evolutionary Computation**, [S. l.], v. 22, n. 1, p. 105–138, 2014. Disponível em: https://doi.org/10.1162/EVCO_a_00105

NILSSON, Nils J. **Artificial Intelligence: A New Synthesis**. 1. ed. Stanford: Morgan Kaufmann Publishers, Inc., 1998. *E-book*.

NORVIG, Peter; RUSSELL, Stuart. **Inteligência Artificial**. 3. ed. [S. l.]: Campus, 2013. *E-book*.

NUMPY. **Fundamental package for scientific computing with Python**. [s. l.], 2019. Disponível em: <https://numpy.org/>. Acesso em: 5 ago. 2020.

PANDAS. **Python Data Analysis Library**. [s. l.], 2018. Disponível em: <https://pandas.pydata.org/index.html>. Acesso em: 5 ago. 2020.

PATIL, Rahul J. Using ensemble and metaheuristics learning principles with artificial neural networks to improve due date prediction performance. **International Journal of Production Research**, [S. l.], v. 46, n. 21, p. 6009–6027, 2008. Disponível em: <https://doi.org/10.1080/00207540701197036>

PEFFERS, Ken *et al.* A design science research methodology for information systems research. **Journal of Management Information Systems**, [S. l.], v. 24, n. 3, p. 45–77, 2007. Disponível em: <https://doi.org/10.2753/MIS0742-1222240302>

PETTIT, Ronald G. Job Shop Type Production Scheduling by Simulation. **Yorktown Heights**, N.Y., p. 254–259, 1968.

PHILIPOOM, Patrick R.; REES, Loren Paul; WIEGMANN, Lars. Using Neural Networks to Determine Internally-Set Due-Date Assignments for Shop Scheduling. **Decision Sciences**, [S. l.], v. 25, n. 5–6, p. 825–851, 1994. Disponível em: <https://doi.org/10.1111/j.1540-5915.1994.tb01871.x>

PIERONI, Marina de P. **Proposta de um método para o Desenvolvimento de uma Arquitetura de Processos de Negócios para apoiar a transição de empresas de manufatura para provedoras de Sistema Produto-Serviço**. 2017. - USP, São Carlos, 2017.

QI, Qinglin; TAO, Fei. Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 Degree Comparison. **IEEE Access**, [S. l.], v. 6, p. 3585–3593, 2018. Disponível em: <https://doi.org/10.1109/ACCESS.2018.2793265>

RAHMAN, Mohammad Naimur; ESMAILPOUR, Amir; ZHAO, Junhui. Machine Learning with Big Data An Efficient Electricity Generation Forecasting System. **BIG DATA RESEARCH**, [S. l.], v. 5, p. 9–15, 2016. Disponível em: <https://doi.org/10.1016/j.bdr.2016.02.002>

RHEE, Seung Hyun; BAE, Hyerim; KIM, Yeongho. A dispatching rule for efficient workflow. **Concurrent Engineering Research and Applications**, [S. l.], v. 12, n. 4, p. 305–318, 2004. Disponível em: <https://doi.org/10.1177/1063293X04042471>

RIBEIRO, Vera M. V. C. **Job Shop Flow Time Prediction using Neural Networks**. 2016. [S. l.], 2016. Disponível em: <https://doi.org/10.1016/j.promfg.2017.07.309>

SANTOS, Carla M. L. S. **Estatística Descritiva**. 3. ed. Lisboa: Edições Sílabo Ltda., 2018. *E-book*. Disponível em: <https://doi.org/10.5935/978-85-93729-90-4.2018b001>

SCIKIT-LEARN. **Machine Learning in Python**. [S. l.], 2020. Disponível em: <https://scikit-learn.org/stable/>. Acesso em: 5 ago. 2020.

SHA, D. Y.; LIU, C. H. Using data mining for due date assignment in a dynamic job shop environment. **International Journal of Advanced Manufacturing Technology**, [S. l.], v. 25, n. 11–12, p. 1164–1174, 2005. Disponível em: <https://doi.org/10.1007/s00170-003-1937-y>

TENSORFLOW. . [S. l.], 2019. Disponível em: <https://www.tensorflow.org>. Acesso em: 5 ago. 2020.

THÜRER, Matthias *et al.* Towards an integrated workload control (WLC) concept: The performance of due date setting rules in job shops with contingent orders. **International Journal of Production Research**, [S. l.], v. 51, n. 15, p. 4502–4516, 2013. Disponível em: <https://doi.org/10.1080/00207543.2013.774485>

VINOD, V.; SRIDHARAN, R. Simulation modeling and analysis of due-date assignment methods and scheduling decision rules in a dynamic job shop production system. **International Journal of Production Economics**, [S. l.], v. 129, n. 1, p. 127–146, 2011. Disponível em: <https://doi.org/10.1016/j.ijpe.2010.08.017>

WANG, Chuang; JIANG, Pingyu. Deep neural networks based order completion time prediction by using real-time job shop RFID data. **Journal of Intelligent Manufacturing**, [S. l.], v. 30, n. 3, p. 1303–1318, 2019. Disponível em: <https://doi.org/10.1007/s10845-017-1325-3>

WANG, Jinjiang *et al.* Deep learning for smart manufacturing: Methods and applications. **Journal of Manufacturing Systems**, [S. l.], v. 48, p. 144–156, 2018. Disponível em: <https://doi.org/10.1016/j.jmsy.2018.01.003>. Acesso em: 10 ago. 2019.

WANG, Junliang; ZHANG, Jie. Big data analytics for forecasting cycle time in semiconductor wafer fabrication system. **International Journal of Production Research**, [S. l.], v. 54, n. 23, p. 7231–7244, 2016. Disponível em: <https://doi.org/10.1080/00207543.2016.1174789>

WONG, Shih Fang; ZHANG, Yu Yong. A model of flow-shop production system planning using multiple criteria and multiple constraint levels (MC2). **Concurrent Engineering Research and Applications**, [S. l.], v. 22, n. 2, p. 172–180, 2014. Disponível em: <https://doi.org/10.1177/1063293X14521225>

WUEST, Thorsten *et al.* Machine learning in manufacturing: Advantages, challenges, and applications. **Production and Manufacturing Research**, [S. l.], v. 4, n. 1, p. 23–45, 2016. Disponível em: <https://doi.org/10.1080/21693277.2016.1192517>

XUEJIAO, T.; XIAOFENG, H.; YANG, L. Overview of big data re- search. Journal of System Simulation. **Journal of System Simulation**, [S. l.], 2013.

ZHANG, Xianyu *et al.* A reference framework and overall planning of industrial artificial intelligence (I-AI) for new application scenarios. **International Journal of Advanced Manufacturing Technology**, [S. l.], v. 101, n. 9–12, p. 2367–2389, 2019. Disponível em: <https://doi.org/10.1007/s00170-018-3106-3>

APÊNDICE A - PRODUCTION PLANNING AND SCHEDULING USING MACHINE LEARNING AND DATA SCIENCE PROCESSES

Production Planning and Scheduling Using Machine Learning and Data Science Processes

PAULO HENRIQUE DE MODESTI^{a,1}, EDERSON CARVALHAR FERNANDES^a
and MILTON BORSATO^a

^a*Universidade Tecnológica Federal do Paraná, Curitiba, Parana, Brazil*

Abstract. Increasing manufacturing efficiency has been a constant challenge since the First Industrial Revolution. What started as mechanization and turned into electricity-driven operations has experienced the power of digitalization. Currently, the manufacturing industry is experiencing an exponential increase in data availability, but it is essential to deal with the complexity and dynamics involved to improve manufacturing indicators. The aim of this study is to identify and allow an understanding of the unfilled gaps and the opportunities regarding production scheduling using machine learning and data science processes. In order to accomplish these goals, the current study was based on the Knowledge Development Process – Constructivist (ProKnow-C) methodology. Firstly, selecting 30 articles from 3608 published articles across five databases between 2015 and 2019 created a bibliographic portfolio. Secondly, a bibliometric analysis, which generated comparative charts of the journals' relevance regarding its impact factor, scientific recognition of the articles, publishing year, highlighted authors and keywords was carried out. Thirdly, the selected articles were read thoroughly through a systemic analysis in order to identify research problems, proposed solutions, and unfilled gaps. Then, research opportunities identified were: (i) Big data and associated analytics; (ii) Collaboration between different disciplines; (iii) Solution Customization; and (iv) Digital twin development.

Keywords. Machine Learning, Production Planning, Data Science, Predictive Analytics, Scheduling.

1. Introduction

Technological development in recent decades has provided a huge amount of data. This dataset is known as Big Data [1]. The manufacturing industry is experiencing several advantages from this data availability [2]. Some of these benefits turned out in higher quality and productivity [3]. On the other hand, it is essential to deal with the dynamics involved in it. Despite the benefits and opportunities, there are many risks to improve manufacturing indicators that cover qualified professionals and complexity [4].

¹ Corresponding Author, Paulo Henrique de Modesti, Book Department, IOS Press, Nieuwe Hemweg 6B, 1013 BG Amsterdam, The Netherlands; E-mail: paulomodesti@alunos.utfpr.edu.br.

The development of computer science tools offers high potential to change the manufacturing domain. Some of these developments are applied to machine learning (ML), which is the ability of computers to solve problems without being programmed to do so [5]. Although computer engineering has been such a challenge for many manufacturing companies, the absence of its full potential application can increasingly affect their competitiveness level.

Strong candidates to surpass most of the major challenges of complex manufacturing systems are ML algorithms. This data-driven approach is capable of solving highly complex, non-linear patterns in data of several types and sources and transforming raw data into models, which are then applied to prediction, and in this case, production scheduling [5].

The application of ML techniques has increased over the last years due to several factors, such as the availability of complex data with poor transparency [6] and the increased convenience and power of ML tools. Many ML algorithms are developed to analyze large amounts of data and are capable of handling high dimensionality [7].

This paper presents a literature review for ML methods and data science processes applied to the production scheduling in manufacturing. The main contribution of this research is to identify which trends and proposed solutions have been developed from the last five years as well as to find unfilled gaps and opportunities of research in this field.

This research is organized into five sections. The first section is the introduction; the second section presents the methodological aspects; the third section describes the research development; the fourth section discusses the main conclusions and, finally, the fifth one exhibits the final considerations.

2. Methodological aspects

According to [8], a methodological framework consists of an examination and description of the approaches used in the research, in order to define the set of methods, procedures, and assumptions relevant to the subject. The lack of a standard that allows the adoption a single procedure to establish the research methodology allows the choice of the methodological framework to vary according to the researcher's knowledge [9].

In addition, [10] stated that a research can be classified according to both its purpose and design. Goal-based research is divided into three groups: exploratory, descriptive and explanatory. The design-based study contains two main groups: paper-source or people-source research. Paper-source research has two categories: bibliographic and documentary. People-source has several categories as experimental, ex-pos-facto, gathering, case study, action research, and participant. Considering the goal of this research, it can be labeled as exploratory, as it aims to provide greater familiarity with the topic, in order to make it more explicit or make hypotheses. It can be said that exploratory research has as main objective the improvement of ideas or the discovery of intuitions. In addition, as the source of information is based on material already prepared, composed of scientific articles, the research was classified as bibliographic. Then, the approach adopted proposed by [10] is summarized in Figure 1.

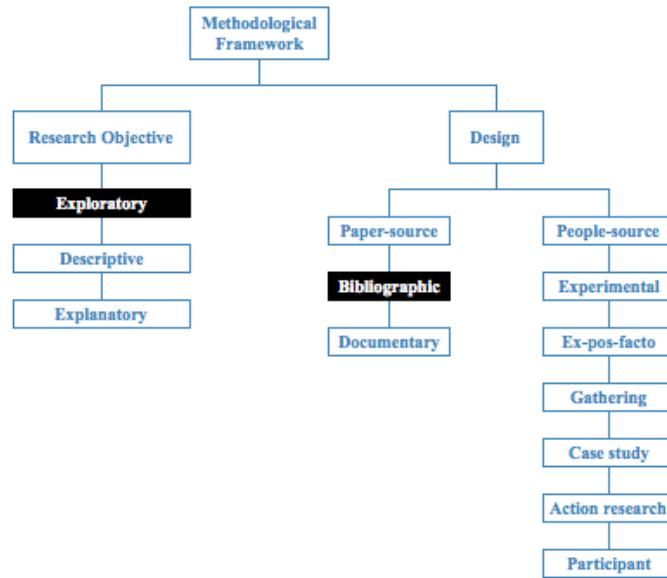


Figure 1. Methodological structure.

The development of the study was based on the Knowledge Development Process – Constructivist (ProKnow-C) methodology, proposed by [8]. This methodology is divided into four steps: (i) bibliographic portfolio selection; (ii) bibliometric analysis; (iii) systemic analysis and; (iv) definition of the research question and objective. The purpose of using this methodology is to facilitate the selection of relevant articles as it aims to identify references with high academic relevance in databases accessed through the Internet, using the bibliometric analysis to filter the selected articles.

The ProKnow-C methodology is adopted up to the systemic analysis step as the goal of this research is to identify trends and opportunities related to the topics under analysis. Access to research in databases was carried out through the CAPES journal portal. The software that supported the study was Mendeley Desktop © version 1.19.4 and Microsoft Excel for Mac 2011 version 14.3.9.

3. Research development

The research process begins with a problem that will motivate the search for data to be examined. The bibliographic portfolio along with bibliometric and systemic analysis, are the main steps towards achieving the research goals [10]. The portfolio includes all relevant published content for the main topic and analysis is vital to discover new

opportunities and gain a deep understanding of production scheduling using machine learning and data science processes.

3.1. Bibliographic portfolio

The bibliographic portfolio contains scientifically recognized publications from 2015 to 2019 and encompasses the most developed stage of knowledge on the subject so far.

In this study, three axes were chosen to be analyzed: Data Science, Production Planning and Machine Learning. In order to have a precise search, 18 keywords were defined to better match the axes analyzed.

The Boolean operators “AND” and “OR” were used to find articles associated with the keywords. The combination used was: ("data analytics" OR "data mining" OR "complex event processing" OR CEP OR "predictive analytics" OR "data acquisition") AND ("Production planning" OR scheduling OR "mixed-integer program*" OR MILP OR "monitoring system*" OR prediction OR "smart manufacturing" OR "intelligent manufacturing") AND ("regression learning" OR "supervised learning" OR "pattern classification" OR "supervised classification" OR "artificial intelligence" OR "machine learning").

There are several scientific databases for searching publications, but only five were selected due to a preliminary analysis of both their relevance in manufacturing research and the availability of full access. They were: Web of Science, Wiley, ProQuest, Scopus and IEEE (Figure 2).

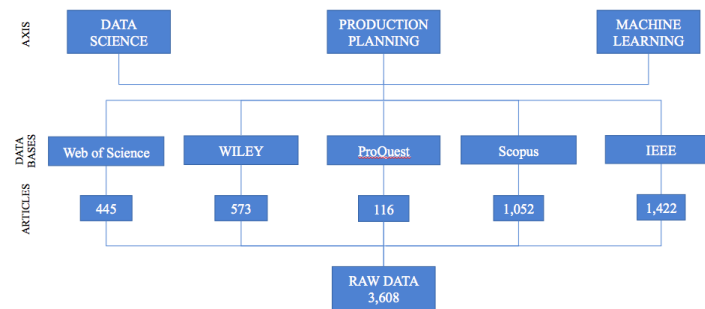


Figure 2. Research scheme.

The result obtained by primary research in the databases had a total of 3608 publications. For getting the best relevant articles from the bibliographic portfolio, four consecutive filters were performed for the current raw data: Published in related Vehicles, Duplicate Elimination, Title Reading and Abstract Reading.

Then, a search was filtered for publication in related vehicles (i.e. in each database to select articles exclusively and in specific areas according to the research goal), such as Production Operations Management, Operations Research, Computer Science, Engineering and Decision Sciences. Therefore, the outcome was 1241 raw articles.

Thus, Mendeley was used to help find the most relevant articles across the following three filters as Duplicate Elimination, Title Reading and Abstract Reading.

Mendeley is a free reference manager, which is used to facilitate access and analysis of each article. The main information of the portfolio such as authors, title, year of publication and journal were downloaded directly from the databases to Mendeley, in order to obtain a single set of data.

Firstly, a duplication check was performed in Mendeley, resulting in a reduction of 37 articles. Secondly, after reading 1204 article titles, the portfolio was reduced to 86 papers related to the topic. Thirdly, abstract readings of each remaining article were performed, resulting in 32 articles considered related to the research subject. The result of each filter is illustrated in Figure 3.




Figure 3. Filter actions and results.

3.2. Bibliometric analysis

Bibliometric analysis is related to the understanding and evaluation of articles in the bibliographic portfolio. This analysis was performed through charts containing portfolio information, such as impact factor, number of citations, publications by year, type of research and most of the published journals.

The portfolio impact factor, as shown in Figure 4, has a regular distribution, ranging from 1 to 6. Two journals can be highlighted with a higher impact factor.




Figure 4. Impact factor of vehicle.

In Figure 5 is possible to see several articles with a large number of citations. Through this number of citations, it is possible to conclude that the portfolio has good relevance.

It is usually possible to regularly check the publication of an article by journal, but its differentiation has been identified in some journals. Figure 8 presents this statement. IEEE Access is the journal with the largest number of publications. In addition, most of the articles in this journal were printed in the current year.




Figure 8. Number of publications by journal and year.

Conform to the results, 63% of the 30 published articles were classified as descriptive, and the others are opportunities for predictive and prescriptive developments (Figure 9).




Figure 9. Classification of the research according to the result.

And last but not least, a comparative chart was created on published articles classified by the manufacturing area to analyze how manufacturing topics were divided between these studies. It was identified in four categories: Virtual Manufacturing, Process and Planning, Control, and Scheduling and Quality Management. Their results are visible in Figure 10.




Figure 10. Published articles classified per manufacturing area and year.

3.3. Systemic analysis

The purpose of systemic analysis is to deeply study each article in the portfolio in order to find gaps in the literature. The criterion for finding gaps is based on the author's decision about what is relevant to the research [11]. The articles were read and analyzed in full in the following aspects: objective, context problem, methodology, results, trends, and opportunities.

And last but not least, after reading full-text filter, 12 articles were eliminated because they were not related to the research subject. The remaining articles resulted in 20 articles. Then, an extra review of the article references was carried out and another 17 articles were analyzed. From this review, 7 were eliminated and 10 added to the final portfolio. The final result of the number of articles in the portfolio is 30 articles.

3.3.1. Identified research problems

The main problems found by the authors were highlighted as follows.

Large datasets: several studies in the portfolio reveal that there are many algorithms capable of solving production planning problems [12]. On the other hand, most of these algorithms take a long time to solve problems or fail when they work with large datasets.

External factors: combining the use of different algorithms, it is possible to solve many complex artificial intelligence problems, such as maintenance prediction or digital twin. On the contrary, it is important to note that external factors are not considered, such as economic recession, weather or an accident [13].

Find the best algorithm: artificial intelligence is a broad concept, where there are many different strategies to be adopt. One such strategy is ML, which has several algorithms. Therefore, an important problem published by some portfolio authors is the difficulty in deciding which algorithm is more appropriate to use.

3.3.2. Proposed solutions

Although the models proposed in the portfolio can identify relationships between variables, they may not indicate a causal relationship. However, causality is essential in

identifying true root causes. Therefore, due to the complexity of the topic, researchers are challenged to investigate [5].

As stated by [14], process and planning are the most researched area of Big data in manufacturing. Therefore, manufacturers must be able to understand the exponential increase in demands for data production, even adopting the analytical techniques necessary to extract the meaning of this data.

[15] stated both the digital twin and big data play important roles in promoting smart manufacturing. The digital twin allows manufacturers to access real-time information and validate data between physical and virtual equipment. Combined with accurate analysis and predictive resources, this technique can provide the manufacturer with a huge improvement in his productivity.

It is proposed by [16] that ML can act with Big Data analytics. The role of Big Data is to retrieve the desired data from the database, and ML is to predict information. By integrating the two techniques, it is possible to work with large datasets in different formats and provide a suitable solution for manufacturing.

Finally [17], intelligent manufacturing means using advanced data analytics to complement physical science and improve productivity and decision making. Deep learning serves advanced analytics tools to process and analyze manufacturing data. The development of deep learning technologies, a subset of artificial neural networks with various layers, and their advantages over traditional ML is clear. Therefore, computational methods based on deep learning improve system performance in manufacturing.

[18] presented a paper to provide a computational methodology based on industrial alarm analysis and an event-log database. Based on the results of frequent sequence mining. A novel methodology and associated network-based visualization technique have been published to learn how the alarm messages that occur represent the states of technology and can be applied to predict future events. In the end, a neural network was explicitly designed to capture long-term dependency on sequences, and a sequence-to-sequence deep learning model was proposed.

3.3.3. *Unfiled gaps identification*

For the raised problems and their solutions previously presented, some unfilled gaps can be identified.

- *Big data and associated analytics*: these will be the key technologies to extract the required knowledge and provide intelligence in all engineering processes. As proposed by [14], it is logical that future work should focus on the development of systematic reviews and literature related to the manufacturing areas identified in this study, such as creating a systematic big data review in the manufacturing diagnosis.
- Collaboration between different disciplines: the need for interdisciplinary studies related to artificial intelligence presents a great opportunity, but also a significant risk, as collaboration between different disciplines, such as Computer Science, Industrial Engineering, Mathematics, and Electrical Engineering, is necessary to boost progress, according to [5] and [15].
- Solution Customization: [19] states that manufacturing is undergoing a technological revolution that, in turn, should revolutionize the industry. On the

other hand, users will require more personalization and electronics features for all products. This will close the cycle between design, manufacturing, marketing, sales, and aftermarket fields of the manufacturing industry.

- Digital twin development: the Digital twin enables manufacturers to manage two-way real-time mapping between a physical object and its digital representation, which opens the way for deep cyber-physical integration. [20] In combination with a digital twin, intelligent data-driven manufacturing will become more responsive, adaptable, and predictive.

4. Discussion chapter

Figure 11 shows the trends identified in the studies based on the selected portfolio. Process and planning show an increasing trend of study over the next years. Scheduling and control can be considered a stable field since the number of published studies is constant. It is interesting to note that Virtual Manufacturing shows a decline, but it is possible to infer that some related articles have not yet been published, justifying the decline. There is only one article related to Quality Management, so it is not possible to perform any analysis.

There are several machine learning technologies available to researchers. Based on the portfolio, it is possible to assume that Artificial Neural Networks are the most used algorithm in the research field, with k-means in second place.




Figure 11. Published articles in manufacturing across the years.




Figure 12. Types of machine learning more used in manufacturing.

5. Conclusions

The study does not attempt to exhaust the proposed subject, as there may be other sources to be investigated. Anyway, this work used a structured methodology designated ProKnow-C in a bibliographic and systemic analysis of production scheduling using machine learning and data science processes.

Firstly, the bibliographic portfolio was created, composed of 3608 published articles, found in five databases between 2015 and 2019. Then, 30 articles relating to the topic were selected.

Secondly, through a bibliometric analysis, the bibliographic portfolio was interpreted and evaluated. In addition, a comparison of the relevance of the journals in relation to the impact factor, scientific recognition of the articles, publishing year, highlighted authors and keywords was done.

Thirdly, in the systemic analysis the entire portfolio was thoroughly read, in order to identify the research problems, the proposed solutions, and the unfilled gaps. The research opportunities identified were: (i) Big data and associated analytics; (ii) Collaboration between different disciplines; (iii) Solution Customization; and (iv) Development of digital twins.

The use of the ProKnow-C methodology allows the researcher to have a deep understanding of the problems, goals, gaps, and opportunities under analysis. However, it depends on the researcher's previous experience in selecting appropriate research axes and keywords in order to provide the best result.

In future studies, the intention is to perform the Big data analysis associated with ML, and focusing on scheduling of the production process, since the use of these tools tends to be widely used in the industry.

References

- [1] J. Lee, E. Lapira, B. Bagheri, and H. Kao, "Recent advances and trends in predictive manufacturing systems in big data environment," *Manuf. Lett.*, vol. 1, pp. 38–41, 2013.
- [2] S. Chand and J. F. Davis, "What is smart manufacturing?," *Time Magazine*, 2010.
- [3] M. Elangovan, N. R. Sakthivel, S. Saravanamurugan, B. B. Nair, and V. Sugumaran, "Machine learning approach to the prediction of surface roughness using statistical features of vibration

- signal acquired in turning," *Procedia Comput. Sci.*, vol. 50, pp. 282–288, 2015.
- [4] T. Wuest, *Identifying product and process state drivers in manufacturing systems using supervised machine learning*. New York, NY: Springer Verlag, 2015.
- [5] T. Wuest, D. Weimer, C. Irgens, and K. D. Thoben, "Machine learning in manufacturing: Advantages, challenges, and applications," *Prod. Manuf. Res.*, vol. 4, no. 1, pp. 23–45, 2016.
- [6] A. Smola and S. V. N. Vishwanathan, *Introduction to machine learning*. Cambridge: Cambridge University Press, 2008.
- [7] K. Yang and J. Trew, *Multivariate statistical methods in quality management*. New York, NY: McGraw-Hill, 2004.
- [8] J. E. Tasca, L. Ensslin, S. R. Ensslin, and M. B. M. Alves, "An approach for selecting a theoretical framework for the evaluation of training programs," *J. Eur. Ind. Train.*, vol. 34, no. 7, pp. 631–655, 2010.
- [9] S.M. Petri, "Modelo para apoiar a avaliação das abordagens de gestão de desempenho e sugerir aperfeiçoamentos: sob a ótica construtivista" Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 2005.
- [10] A. C. Gil, *Como Elaborar Projetos de Pesquisa*, 3rd ed. Belo Horizonte: Atlas, 1996.
- [11] L. ENSSLIN, S. R. ENSSLIN, and H. M. PINTO, "Processo de investigação e análise bibliométrica: avaliação da qualidade dos serviços bancários," *Revista de Administração Contemporânea*, pp. 325–349, 2013.
- [12] M. Usman and S. Asghar, "An Architecture for Integrated Online Analytical Mining," *J. Emerg. Technol. WEB Intell.*, vol. 3, no. 2, 2011.
- [13] R. Bragança, F. Portela, and M. Santos, "A regression data mining approach in Lean Production," *Concurr. Comput. Pract. Exp.*, p. e4449, Mar. 2018.
- [14] P. O'Donovan, K. Leahy, K. Bruton, and D. T. J. O'Sullivan, "Big data in manufacturing: a systematic mapping study," *J. Big Data*, vol. 2, no. 1, 2015.
- [15] Q. Qi and F. Tao, "Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 Degree Comparison," *IEEE Access*, vol. 6, pp. 3585–3593, 2018.
- [16] M. N. Rahman, A. Esmailpour, and J. Zhao, "Machine Learning with Big Data An Efficient Electricity Generation Forecasting System," *BIG DATA Res.*, vol. 5, pp. 9–15, 2016.
- [17] J. Wang, Y. Ma, L. Zhang, R. X. Gao, and D. Wu, "Deep learning for smart manufacturing: Methods and applications," *J. Manuf. Syst.*, vol. 48, pp. 144–156, Jul. 2018.
- [18] G. Dorgo and J. Abonyi, "Learning and predicting operation strategies by sequence mining and deep learning," *Comput. Chem. Eng.*, vol. 128, pp. 174–187, Sep. 2019.
- [19] P. Lade, R. Ghosh, and S. Srinivasan, "Manufacturing analytics and industrial Internet of Things," *IEEE Intell. Syst.*, vol. 32, no. 3, pp. 74–79, 2017.
- [20] F. Tao, Q. Qi, A. Liu, and A. Kusiak, "Data-driven smart manufacturing," *J. Manuf. Syst.*, vol. 48, pp. 157–169, 2018.