

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

Luiz Fernando Bisan Antunes

**Identificação de massas desbalanceadas
em lavadoras de roupas com técnicas de
redes neurais e visão computacional**

Luiz Fernando Bisan Antunes

**Identificação de massas desbalanceadas
em lavadoras de roupas com técnicas de
redes neurais e visão computacional**

Dissertação apresentada ao do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Processamento Digital de Sinais

Orientador: Prof. Dr. João Vitor de Carvalho Fontes

São Carlos - SP

2023



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Luiz Fernando Bisan Antunes, realizada em 31/10/2023.

Comissão Julgadora:

Prof. Dr. João Vitor de Carvalho Fontes (UFSCar)

Prof. Dr. Andre Carmona Hernandez (UFSCar)

Profa. Dra. Myriam Regattieri de Biase da Silva Delgado (UTFPR)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.

Agradecimentos

Ao Professor João Vitor de Carvalho Fontes pela orientação e amizade. Também agradeço à minha família que sempre me apoiou através da minha formação pessoal, acadêmica e profissional.

Aos meus amigos Samuel Costa Prado, Diego Zozernan, Marcelo Campos Silva, Leonardo Campos, Pedro Oliveira, Leonardo Luis Silva, Andreyson Jambersi e Pedro Henrique Capelotti pelas várias discussões, amizade e paciência durante o desenvolvimento desse trabalho.

Agradeço à Whirlpool Corporation pela compreensão e auxílio na realização deste trabalho, especialmente ao Adriano Tebaldi, Thomas Spicer e ao Adirlei Kraemer, pelo incentivo e apoio.

A Deus, pela vida.

Resumo

A etapa de centrifugação é uma função primária das lavadoras de roupa que tem como objetivo extrair água dos tecidos por meio da rotação do cesto em um eixo vertical suspenso por um conjunto de quatro apoios. Seja por meio do processo de lavagem ou pelo uso inadequado do usuário, quando a distribuição dos tecidos não é uniforme existe o fenômeno de desbalanceamento que pode resultar desde apenas ruídos de batidas até a destruição do produto. Este trabalho tem como objetivo avaliar a aplicação de técnicas de redes neurais para identificação de massas desbalanceadas em lavadoras de roupas utilizando dados obtidos por um sistema de visão computacional. Por meio da observação de variáveis como velocidade angular e movimentos de translação de diferentes componentes, técnicas de inteligência artificial serão aplicadas a fim de identificar e classificar padrões criados por diferentes intensidades de cargas desbalanceadas. Inicialmente será feito um detalhamento do sistema de uma lavadora de roupas e o fenômeno de desbalanceamento de cargas. A revisão bibliográfica sobre processamento de imagens digitais fundamenta o desenvolvimento do sistema e algoritmo de visão computacional. A experimentação prática buscará coletar um grande conjunto de dados abrangendo todo espaço de inferência de possíveis configurações de desbalanceamento, de tal modo que as ferramentas de rede neural tenham dados suficientes para o processo de treinamento, validação e teste. É esperado que o sistema de detecção proposto seja capaz de identificar e classificar diferentes intensidades de cargas desbalanceadas.

Palavras-chave: Lavadoras de Roupa; Detecção de Desbalanceamento; Visão Computacional; Redes Neurais.

Abstract

The spinning phase is a primary function of washing machines which has the objective of extracting residual water from clothes by spinning a vertical axis basket suspended in four points. Either by the washing process or by inappropriate consumer usage, when the clothes are not uniformly distributed there is an unbalancing phenomenon that can result from small hit noises to product destruction. The research has the objective of evaluating the application of neural network techniques to identify unbalanced mass in washer machines using collected data from a computer vision system. By observing variables such as angular speed and translational movement from different parts, artificial intelligence techniques will be applied in order to identify and classify patterns created by different intensities of unbalancing loads. Initially, the systems of a washing machine and the unbalancing phenomenon will be described. The bibliographic review of digital image processing supports the computational vision system and algorithm. The practical experimentation will collect a data set from the entire inference space of possible unbalancing configurations, in such a way that enough data is provided to train, validate and test the neural network tools. It is expected the proposed system be capable of identifying and classifying different intensities of an unbalanced load.

Keywords: Washer Machine; Unbalance Detection; Computacional Vision; Neural Networks.

Lista de ilustrações

Figura 1 – Representação esquemática de uma lavadora de roupas	24
Figura 2 – Sistema de coordenadas de Pixels	32
Figura 3 – Ilustração 3D do Sistema RGB	33
Figura 4 – Ilustração do cone 3D que representa o Sistema HSV	34
Figura 5 – Esquemático do Sistema de Visão de Computacional	39
Figura 6 – Esquemático do Setup de Filmagem	40
Figura 7 – Fluxograma simplificado do processamento de imagem	42
Figura 8 – Exemplo para comparação entre RGB e HSV	42
Figura 9 – Comparação entre os Histogramas RGB e HSV da imagem da Figura 8	43
Figura 10 – Marcadores classificados	44
Figura 11 – Histograma HSV aplicado ao marcador Rosa	44
Figura 12 – Exemplo do processo de rastreamento	45
Figura 13 – Ilustração do cálculo do Posicionamento Angular	46
Figura 14 – Comparação entra diferentes taxas de quadros e rotações	47
Figura 15 – Demonstração do cálculo do Posicionamento Angular	48
Figura 16 – Configuração de teste	49
Figura 17 – Trajetória programada na máquina CNC - Experimento de Velocidade Angular e Configuração de Câmera	50
Figura 18 – Trajetória programada na máquina CNC - Experimento de Posição Linear	51
Figura 19 – Exemplo de uma rede <i>feedforward</i> multicamadas	54
Figura 20 – Função de Ativação ReLu	54
Figura 21 – Representação de cargas de borracha para simular desbalanceamento .	57
Figura 22 – Perfil de Velocidade do Motor para o estudo de velocidade angular . .	60
Figura 23 – Trajetória elíptica medida - Configuração 1	60
Figura 24 – Experimento 1 - Resultados de velocidade da Configuração 3	61
Figura 25 – Experimento 1- Erro Relativo da Configuração 3	62
Figura 26 – Experimento 1 - Configuração 1	63

Figura 27 – Experimento 1 - Configuração 4	64
Figura 28 – Rotor a 100 RPM e 3600 RPM (60 fps)	65
Figura 29 – Experimento 1 - Configuração 5	65
Figura 30 – Experimento 1 - Configuração 7	66
Figura 31 – Experimento 1 - Configuração 8	67
Figura 32 – Experimento 1 - Configuração 6	68
Figura 33 – Deslocamento no Plano XY - Configuração 1	69
Figura 34 – Distribuição do Erro em X	69
Figura 35 – Distribuição do Erro em Y	70
Figura 36 – Erro Médio por Ponto de Referência	70
Figura 37 – Desvio padrão médio do Experimento 2	71
Figura 38 – Erros relativos do Experimento 2.	72
Figura 39 – Erro relativo por rotação.	73
Figura 40 – Velocidades rotacionais por tempo	74
Figura 41 – Velocidades rotacionais por tempo	75
Figura 42 – Desvio padrão relativo médio por RPM.	76
Figura 43 – Velocidades rotacionais de 2400 RPM por tempo.	76
Figura 44 – Cabine de Filmagem	78
Figura 45 – Sistema de Iluminação	78
Figura 46 – Marcadores aplicados na lavadora de roupas	79
Figura 47 – Plano de coleta de dados	80
Figura 48 – 0 kg de Manta Balanceada e 0 kg de Carga Desbalanceada	81
Figura 49 – 0 kg de Manta Balanceada e 1 kg de Carga Desbalanceada na base do cesto	82
Figura 50 – 0 kg de Manta Balanceada e 2 kg de Carga Desbalanceada na base do cesto	83
Figura 51 – Esquemático genérico da RNA MLP	85
Figura 52 – R^2 de Modelos para Y1 (Massas Balanceadas) com conjunto de dados de Treinamento e Validação	86
Figura 53 – R^2 de Modelos para Y2 (Massa Desbalanceada) com conjunto de dados de Treinamento e Validação	87
Figura 54 – R^2 de Modelos para Y3 (Altura da Massas Desbalanceada) com con- junto de dados de Treinamento e Validação	88
Figura 55 – R^2 de Modelos para Y1 (Massas Balanceadas) com conjunto de dados de Teste	89
Figura 56 – Histograma dos valores de R^2 para Y1 (Massas Balanceadas)	90
Figura 57 – Histograma do Desvio Padrão dos Erros dos Modelos para Y1 (Massas Balanceadas)	90

Figura 58 – Histograma da Média dos Erros dos Modelos para Y1 (Massas Balanceadas)	91
Figura 59 – R^2 de Modelos para Y2 (Massas Desbalanceadas) com conjunto de dados de Teste	92
Figura 60 – Histograma dos valores de R^2 para Y2 (Massas Desbalanceadas)	92
Figura 61 – Histograma do Desvio Padrão dos Erros dos Modelos para Y2 (Massas Desbalanceadas)	93
Figura 62 – Histograma da Média dos Erros dos Modelos para Y2 (Massas Desbalanceadas)	93
Figura 63 – R^2 de Modelos para Y3 (Altura da Massas Desbalanceada) com conjunto de dados de Treinamento e Validação	94
Figura 64 – Histograma dos valores de R^2 para Y3 (Altura das Massas Desbalanceadas)	94
Figura 65 – Histograma do Desvio Padrão dos Erros dos Modelos para Y3 (Altura das Massas Desbalanceadas)	95
Figura 66 – Histograma da Média dos Erros dos Modelos para Y2 (Altura das Massas Desbalanceadas)	95
Figura 67 – Deslocamento Estimado para Configuração 1	107
Figura 68 – Deslocamento Estimado para Configuração 2	108
Figura 69 – Deslocamento Estimado para Configuração 3	108
Figura 70 – Deslocamento Estimado para Configuração 3	109
Figura 71 – Deslocamento Estimado para Configuração 4	109
Figura 72 – Deslocamento Estimado para Configuração 5	110
Figura 73 – Deslocamento Estimado para Configuração 6	110
Figura 74 – Deslocamento Estimado para Configuração 7	111
Figura 75 – Deslocamento Estimado para Configuração 8	111
Figura 76 – Deslocamento Estimado para Configuração 9	112
Figura 77 – Perfil de Velocidade - Configuração 1	114
Figura 78 – Perfil de Velocidade - Configuração 2	115
Figura 79 – Perfil de Velocidade - Configuração 3	116
Figura 80 – Perfil de Velocidade - Configuração 4	117
Figura 81 – Perfil de Velocidade - Configuração 5	118
Figura 82 – Perfil de Velocidade - Configuração 6	119
Figura 83 – Perfil de Velocidade - Configuração 7	120
Figura 84 – Perfil de Velocidade - Configuração 8	121
Figura 85 – Erro Relativo - Configuração 1	122
Figura 86 – Erro Relativo - Configuração 2	123
Figura 87 – Erro Relativo - Configuração 3	124
Figura 88 – Erro Relativo - Configuração 4	125

Figura 89 – Erro Relativo - Configuração 5	126
Figura 90 – Erro Relativo - Configuração 6	127
Figura 91 – Erro Relativo - Configuração 7	128
Figura 92 – Erro Relativo - Configuração 8	129
Figura 93 – Medidas de Velocidade em 200 RPM	131
Figura 94 – Medidas de Velocidade em 400 RPM	132
Figura 95 – Medidas de Velocidade em 600 RPM	132
Figura 96 – Medidas de Velocidade em 800 RPM	133
Figura 97 – Medidas de Velocidade em 1000 RPM	133
Figura 98 – Medidas de Velocidade em 1200 RPM	134
Figura 99 – Medidas de Velocidade em 1400 RPM	134
Figura 100 – Medidas de Velocidade em 1600 RPM	135
Figura 101 – Medidas de Velocidade em 1800 RPM	135
Figura 102 – Medidas de Velocidade em 2000 RPM	136
Figura 103 – Medidas de Velocidade em 2200 RPM	136
Figura 104 – Medidas de Velocidade em 2400 RPM	137
Figura 105 – Medidas de Velocidade em 2600 RPM	137
Figura 106 – Medidas de Velocidade em 2800 RPM	138
Figura 107 – Medidas de Velocidade em 3000 RPM	138
Figura 108 – Medidas de Velocidade em 3200 RPM	139
Figura 109 – Medidas de Velocidade em 3400 RPM	139
Figura 110 – Medidas de Velocidade em 3600 RPM	140

Lista de tabelas

Tabela 1 – Configurações - Experimento de Velocidade Angular e Configuração de Câmera	50
Tabela 2 – Pontos da trajetória - Experimento de Posição Linear	51
Tabela 3 – Configurações - Experimento de Posição Linear	51
Tabela 4 – Cálculo de Correlação de Inércia	57
Tabela 5 – Modelos Selecionados	96
Tabela 6 – Dados Coletados - Configurações	141
Tabela 7 – Dados Coletados - Valores de Entrada Extraídos	147

Lista de siglas

BHT Limiarização de Histograma Balanceado

BGR Blue, Green and Red

CNC Controle Numérico Computadorizado

FPS Frames per second

HSV Hue, Saturation and Value

OpenCV Open source Computer Vision library

RNA Rede Neural Artificial

RPM Rotações Por Minuto

ROI Region of Interest

RGB Red, Green and Blue

ReLU Rectified Linear Unit

Sumário

1	INTRODUÇÃO	23
1.1	Contextualização	23
1.2	Objetivo	28
1.3	Organização do Trabalho	28
2	FUNDAMENTOS DE VISÃO COMPUTACIONAL E REDES NEURAIIS	31
2.1	Visão Computacional	31
2.1.1	Sistema RGB	32
2.1.2	Sistema HSV	33
2.1.3	Limiarização De Imagens	34
2.2	Redes Neurais	35
2.3	Ferramentas Computacionais	36
2.3.1	Python	36
2.3.2	OpenCV	37
2.3.3	Sklearn	37
3	MATERIAIS E MÉTODOS	39
3.1	Sistema de Visão Computacional	39
3.1.1	Aquisição de Imagem	40
3.1.2	Processamento de Imagem	41
3.1.3	Exportação de Dados	46
3.1.4	Experimentos de Verificação e Validação	48
3.2	Modelagem por Redes Neurais	52
3.2.1	Arquitetura da Rede Neural	53
3.2.2	Parâmetros de Entrada	55
3.2.3	Parâmetros de Saída	56

3.2.4	Plano de coleta de dados	56
4	RESULTADOS - SISTEMA DE VISÃO COMPUTACIONAL	59
4.1	Experimento 1: Velocidade Angular e Configuração de Câmera	59
4.2	Experimento 2: Posição Linear	68
4.3	Experimento 3: Estabilidade e Consistência	73
5	RESULTADOS - MODELAGEM DE CARGAS DESBALAN-	
	CEADAS	77
5.1	Plano e Coleta de Dados	77
5.1.1	Cabine de Filmagem	77
5.1.2	Configuração dos Marcadores	79
5.1.3	Aquisição de Dados	79
5.2	Rede Neural Artificial	80
5.2.1	Extração das Variáveis de Entrada	80
5.2.2	Consolidação do Conjunto de Dados	84
5.2.3	Divisão do Conjunto de Dados	84
5.2.4	Seleção dos hiperparâmetros	84
5.2.5	Treinamento e Seleção dos Modelos	85
5.2.6	Validação dos Modelos	88
5.2.7	Modelos Seleccionados	95
6	CONCLUSÃO	97
	REFERÊNCIAS	99

APÊNDICES 105

APÊNDICE A	–	GRÁFICOS - EXPERIMENTO 2: POSIÇÃO LINEAR	107
A.1		Gráficos de Deslocamento no plano XY	107
APÊNDICE B	–	GRÁFICOS - EXPERIMENTO 1: VELOCIDADE ANGULAR E CONFIGURAÇÃO DE CÂMERA	114
B.1		Gráficos de Velocidade	114
B.2		Gráficos de Erro Relativo	122
APÊNDICE C	–	GRÁFICOS - EXPERIMENTO 3: ESTABILIDADE	131

APÊNDICE D – PLANO E COLETA DE DADOS 141

Capítulo 1

Introdução

1.1 Contextualização

A lavadora automática de roupas é um dos eletrodomésticos mais comuns no cotidiano das famílias, proporcionando economia de tempo e esforço ao simplificar as tarefas domésticas diárias (HARDYMENT, 1988). No entanto, questões como ruídos e vibrações têm se tornado cada vez mais importantes para a qualidade de vida dos consumidores, especialmente em apartamentos e outras residências de dimensões reduzidas em áreas urbanas.

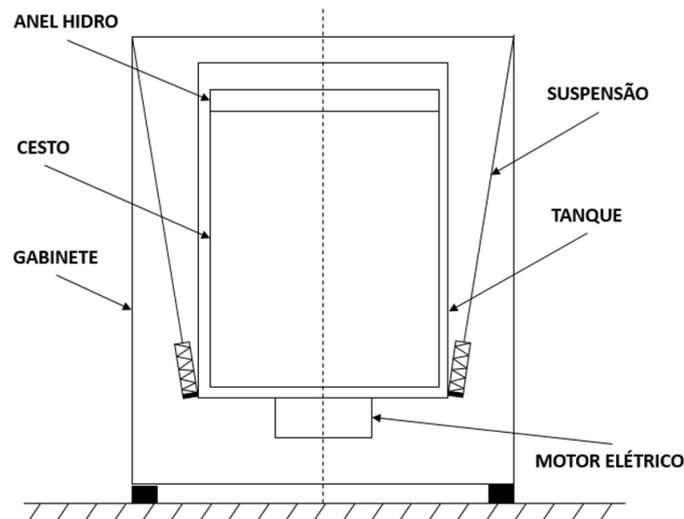
De maneira geral, as lavadoras de roupas podem ser classificadas em duas categorias: eixo vertical (*top loader*) e eixo horizontal (*front loader*). No mercado brasileiro, a lavadora de roupas com eixo vertical é o modelo mais utilizado, enquanto em países europeus, as lavadoras de roupas com eixo horizontal são mais comuns.

As máquinas de lavar roupas possuem duas funções principais, que são lavar e secar as cargas de roupa. No caso das lavadoras de eixo vertical, durante a etapa de lavagem o movimentador de roupas, seja ele um agitador (eixo central com pás) ou um impulsor (peça cônica ou helicoidal localizada na base, mais conhecido como *impeller*), executa uma série de movimentos rotacionais curtos que alternam de direção a cada oscilação. Já na etapa de secagem, conhecida como centrifugação, o cesto da lavadora gira com velocidades entre 500 e 800 Rotações Por Minuto (RPM), visando extrair a água residual da carga de tecidos por meio da força centrípeta.

É durante a etapa de centrifugação em que os maiores níveis de ruído sonoro e vibração mecânica ocorrem. Os fatores de maior influência para estes fenômenos são as excitações nas frequências de ressonância durante a aceleração do cesto, somadas às massas desbalanceadas em relação ao eixo de giro.

Antes de se discutir o comportamento dinâmico de uma lavadora de roupas, a Figura 1 ilustra, de maneira simplificada, a composição de uma lavadora de eixo vertical. Os principais componentes são o tanque, responsável por armazenar a água utilizada no processo de lavagem, o cesto, compartimento onde as roupas são colocadas, o anel hidro, que tem como função compensar massas desbalanceadas utilizando o fluido contido em seu interior, o motor elétrico, responsável por gerar movimento durante as etapas de lavagem e centrifugação, as suspensões, que mantêm todo o conjunto (tanque, cesto, anel hidro e motor) suspenso, absorvendo e amortecendo seus movimentos, e o gabinete, que sustenta todo o conjunto suspenso e isola os componentes do acesso do usuário.

Figura 1 – Representação esquemática de uma lavadora de roupas



Fonte: o Autor

A modelagem matemática do comportamento dinâmico de lavadoras de roupas é um assunto amplamente explorado na comunidade científica. Conrad (1994) desenvolveu modelos simplificados para o sistema de suspensão de lavadoras com eixo horizontal e vertical que apresentaram uma boa correlação com a resposta dinâmica dos testes em sistemas reais. Barcha (2004) realizou um estudo comparativo do comportamento dinâmico de uma lavadora com eixo vertical, utilizando três métodos diferentes: analítico, experimental e simulação multicorpos. Por sua vez, Qu e Jiang (2019) criaram um modelo dinâmico do sistema de suspensão de uma lavadora com eixo vertical baseado na equação Lagrangiana, o qual foi verificado por meio de simulação de elementos finitos e experimentos, a fim de fornecer uma base teórica para a subsequente otimização da redução de vibração.

Como descrito por Ioriatti (2007), o sistema de suspensão deve ser projetado de forma a limitar a mobilidade do conjunto interno, evitando assim choques do tanque com o gabinete que podem levar a lavadora a se deslocar. Durante a etapa de centrifugação, o sistema apresenta uma órbita elíptica e oscilações em relação ao eixo de rotação do

conjunto suspenso, enquanto o gabinete externo se mantém estável. Porém em condições extremas de desbalanceamento, a orbita se expande e o conjunto suspenso se choca com o gabinete, deslocando todo o sistema. Tal comportamento representa um desafio para a aquisição de dados experimentais, uma vez que sensores externos, como tacômetros e encoders, necessitam de alterações invasivas e limitam o teste a condições de laboratório, além de serem sensíveis em condições de vibrações e/ou deslocamentos abruptos.

Atualmente, o encoder óptico é a ferramenta mais amplamente utilizada para medir a rotação de rotores (LIBERALI et al., 2003). Isso se deve às suas características, como alta precisão (graças à natureza dos sinais ópticos e à divisão em resoluções muito pequenas) e durabilidade (devido à ausência de contato físico entre as partes móveis) (JIA et al., 2020). No entanto, a exigência de contato físico entre o eixo do encoder óptico e o rotor apresenta uma série de desvantagens para o sistema (COSIJNS; JANSEN; HAITJEMA, 2018). Isso inclui sensibilidade a ambientes com alta temperatura, vibrações intensas ou campos magnéticos fortes, que podem impactar o funcionamento dos encoders ópticos.

As limitações dos métodos convencionais aliadas à popularização dos sistemas baseados em visão computacional têm despertado um crescente interesse no desenvolvimento de métodos de medição alternativos que possam substituir as restrições dos encoders ópticos convencionais (DąBEK et al., 2022; ZHAO et al., 2022; ZHOU et al., 2021; BONNARDOT et al., 2021). Em particular, há uma busca por soluções de baixo custo que possam fornecer informações precisas sobre o posicionamento rotacional e translacional dos rotores. Esses métodos alternativos permitem medições remotas do posicionamento rotacional e translacional dos rotores sem a necessidade de montagem física próxima ao rotor, possibilitando aplicações mais flexíveis e facilitando o controle de rotores em diferentes contextos, como robótica, automobilística e aeronáutica.

Como evidenciado por Block et al. (2021), a evolução dos sistemas de visão computacional representa uma opção valiosa ao oferecer medições não invasivas, eliminando a necessidade de contato físico. Essas soluções têm impactado significativamente os processos de produção, fornecendo ferramentas essenciais para diversas etapas da fabricação e desenvolvimento (FERNANDES; MOREIRA; MATA, 2011; KONSTANTINIDIS; MOUROUTSOS; GASTERATOS, 2021; YACHIDA; TSUJI, 1977). Em particular sistemas de visão computacional, são amplamente aplicados no controle de qualidade e na medição precisa da geometria dos produtos, assim como em etapas de verificação, avaliação e validação de modelos físicos e suas respectivas posições espaciais (ANDREEV; TRETYAKOV; MIKHAILOV, 2019).

Diferentemente das limitações impostas pelo uso dos sensores de contato, sistemas baseados em visão computacional podem ser empregados para extrair dados como deslocamento e velocidade de um objeto com maior flexibilidade. Um sistema convencional de visão computacional é composto por dois elementos essenciais: uma câmera e um sistema de processamento de imagens, muitas vezes implementado em um computador equipado

com software especializado (SZELISKI, 2010a). A seleção criteriosa desse tipo de sistema requer uma análise profunda dos objetivos específicos da aplicação em questão.

A literatura acadêmica apresenta diversos trabalhos de medições de máquinas rotativas por visão computacional em ampla gama de aplicações. Em Kim et al. (2016), por exemplo, é apresentado o conceito de “encoder visual” como um método robusto e preciso de medição do ângulo de rotação. Um disco com padrão de cores Red, Green and Blue (RGB), criando com cores um padrão semelhante ao de discos de encoders ópticos, é monitorado por uma câmera de alta velocidade de 1000 Frames per second (FPS). Tal sistema foi capaz de realizar leituras de velocidade até 8000 RPM.

Kang et al. (2021) propõem em seu estudo um algoritmo baseado no espaço de cores Hue, Saturation and Value (HSV) capaz de extrair informações de posição de objetos de forma automática, sem a necessidade de intervenção humana ou conhecimento prévio.

Com o foco em um sistema de custo reduzido, Wang, Wang e Yan (2017) também abordam a medição de velocidade rotacional utilizando processamento de imagem. Efeitos de diferentes marcadores, algoritmos de processamento de imagem e condição de iluminação são explorados e avaliados durante o estudo. Em testes experimentais, o método proposto mediu velocidade de 0 a 700 RPM utilizando uma câmera de apenas 30 FPS (comumente utilizada para videochamadas).

Já em 2018, Wang et al. (2018) investigaram a medição de velocidade rotacional por meio de algoritmos que utilizam a similaridade de imagens e análise espectral, ampliando o escopo das técnicas de medição.

Em um recente estudo, Liao, Wang e Yan (2022) propõem uma técnica de medição instantânea da velocidade rotacional para pás de turbinas eólicas baseada no rastreamento de marcadores, as quais são realizadas comumente por unidade de medidas inerciais (IMUs). Por meio de simulações, é obtido um erro experimental de cerca de 1% na leitura de velocidade entre 5 e 30 RPM.

O método desenvolvido neste trabalho se posiciona de maneira congruente com os trabalhos correlatos presentes na literatura acadêmica, apresentando uma precisão equiparável às técnicas estabelecidas. No entanto, uma de suas distinções fundamentais está em sua abordagem alternativa, a qual permite a realização da estimativa da posição bidimensional do centro do rotor. Esse aspecto vai além da mera medição da velocidade rotacional do objeto em análise. Diferentemente dos métodos convencionais supracitados, o método em análise revela-se apto a efetuar leituras de velocidades rotacionais máximas que se aproximam da frequência de amostragem.

Por meio de informações como velocidade angular e posicionamento, os estudos mencionados anteriormente oferecem ferramentas e métodos para otimizar sistemas dinâmicos, no entanto, para utilizá-los de maneira fidedigna aos fenômenos físicos reais, é necessário inserir a quantidade máxima aceitável de massa desbalanceada como entrada, considerando o contexto em que o sistema de visão será aplicado.

A massa máxima da carga de uma lavadora de roupas pode ser estimada a partir da capacidade declarada pelo fabricante acrescida do percentual de água residual absorvido durante a lavagem (em casos extremos, como no de toalhas de banho, pode chegar a 200%). Portanto, uma lavadora de roupas com capacidade declarada de 15 kg pode conter, no início da etapa de centrifugação, uma massa de tecidos acrescidos de água igual a 45 Kg.

A carga real de lavagem, por sua vez, apresenta uma natureza aleatória. A disposição dos tecidos no cesto é resultado da combinação de vários fatores, tais como massa total de tecidos, tecidos com diferentes materiais e tamanhos (como, por exemplo, calças jeans, lençóis de algodão ou camisas de manga comprida), posicionamento dos itens dentro do cesto antes da lavagem, nível de água utilizado e intensidade dos golpes do movimentador de roupas. Devido ao número infinito de combinações dos fatores mencionados anteriormente, é possível afirmar que em todos os ciclos de lavagem, a massa de tecido apresentará algum grau de desbalanceamento. A quantidade e distribuição da massa de tecidos contidos no cesto apresentam um papel significativo na geração de ruído e vibrações, uma vez que podem alterar substancialmente o momento de inércia do sistema dinâmico.

Akabay, Dowling e Schultz (2014) propõem um modelo matemático para o conjunto de fenômenos físicos envolvidos no processo de lavagem de roupas totalmente submersas, no qual múltiplas peças de roupas são modeladas como placas elásticas finas (sujeitas as forças de tração, cisalhamento, flexão e torção) enquanto o fluido de lavagem é modelado pela equação de Navier-Stokes para fluidos incompressíveis. Porém, devido a alta complexidade de modelagem e poder computacional necessário para modelar o comportamento dos tecidos após a lavagem, estudos de máquinas de lavar roupa têm sido tradicionalmente empíricos.

Uma abordagem experimental para os testes dinâmicos consiste na utilização de cargas de borracha para simular uma carga de roupa, de modo a garantir o controle e reprodutibilidade das condições de teste. As cargas de borracha são classificadas em dois tipos: mantas balanceadas e cargas pontuais.

A mantas balanceadas são compostas por tiras de borracha que preenchem toda a superfície interna do cesto, enquanto as cargas pontuais desbalanceadas são pequenas tiras de borracha que podem ser posicionadas em diferentes alturas desta superfície. Tanto as massas quanto a altura da carga desbalanceada influenciam diretamente na magnitude e comportamento do desbalanceamento.

Essa abordagem experimental fornece um procedimento padronizado que permite comparar o desempenho dinâmico de diferentes modelos e/ou configurações. No entanto, a falta de correlação das cargas pontuais de borracha suscita dúvidas sobre se as condições testadas representam adequadamente o comportamento real dos tecidos. Testes realizados com borracha podem ser mais severos do que testes com tecidos, o que pode resultar em uma super especificação de projeto e em um custo desnecessário. Por outro lado, se as condições reais de operação forem mais severas do que as condições de teste, isso pode

intensificar a geração de ruídos e vibrações.

Dados os fatos apresentados anteriormente, é evidente que a modelagem e avaliação do comportamento dinâmico de lavadoras de roupa de eixo vertical, no âmbito de projetos mecânicos, é bem explorada e discutida na literatura. Entretanto, a especificação das massas desbalanceadas às quais o sistema é submetido segue uma abordagem empírica, com uma série de lacunas em relação a fidelidade ao fenômeno real.

A avaliação não invasiva do comportamento dinâmico das cargas desbalanceadas em tecidos durante o funcionamento real, juntamente com a correlação correspondente às massas de borracha, representa um avanço substancial no aprimoramento de projetos de lavadoras de roupas verticais, resultando em maior conhecimento e precisão.

1.2 Objetivo

O objetivo principal deste projeto de pesquisa é desenvolver um método de identificação de massas desbalanceadas baseado em técnicas de redes neurais. A partir de dados experimentais obtidos por um sistema de visão computacional e massas concentradas, a rede neural treinada deve realizar uma correlação entre massas concentradas e distribuídas. Para atingir tal objetivo, são necessários os seguintes objetivos específicos:

- a) Desenvolvimento do sistema e algoritmo de visão computacional para mensurar o deslocamento translacional e velocidade angular;
- b) Validação experimental do sistema de visão computacional;
- c) Criação da base de dados experimentais para treinamento das redes neurais;
- d) Treinamento e validação experimental do modelo de rede neural;

1.3 Organização do Trabalho

Esta dissertação está organizada na seguinte estrutura:

- O capítulo 2 apresenta os conceitos gerais de Visão Computacional e RNA. Aqui também são descritas as ferramentas computacionais utilizadas no trabalho proposto;
- O capítulo 3 define as etapas do plano de desenvolvimento da pesquisa, descrevendo os detalhes de cada método utilizado e as etapas da metodologia deste trabalho;
- O capítulo 4 mostra os resultados do método de medição baseado em visão computacional. São apresentados experimentos que determinam a acuracidade e confiabilidade do sistema em diferentes situações.

- ❑ O capítulo 5 demonstra a estratégia experimental empregada no planejamento e coleta de dados com a lavadora de roupas. É também apresentada a técnica de RNA empregada, além de otimização e definição dos melhores modelos matemáticos.
- ❑ O capítulo 6 apresenta as conclusões derivadas da pesquisa realizada.

Capítulo 2

Fundamentos de Visão Computacional e Redes Neurais

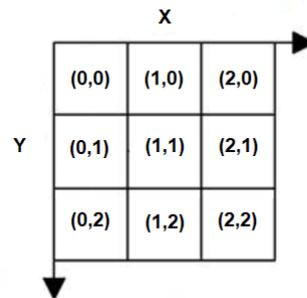
2.1 Visão Computacional

Apesar da superioridade inata da percepção humana, adquirida ao longo da vida por meio da experiência e contexto, a visão computacional visa emular tais capacidades em sistemas mecânicos. Esta abordagem instrui as máquinas no reconhecimento de objetos, cálculo de distâncias, detecção de movimentos e identificação de anomalias, tudo isso em uma velocidade notavelmente excedente à habilidade humana (HUTMACHER, 2019). Essa realização se concretiza por meio da aplicação de câmeras, dados e algoritmos, em contraposição à dependência de componentes biológicos, como a retina, nervos ópticos e o córtex visual. Consequentemente, sistemas de visão computacional podem analisar milhares de produtos ou processos por minuto, inclusive identificando defeitos ou problemas sutis que poderiam passar despercebidos à observação humana, e, em certas tarefas, superando as competências humanas.

As tarefas de visão computacional incluem métodos para adquirir, processar, analisar e compreender imagens digitais, além da extração de dados em alta dimensão do mundo real, com o objetivo de gerar informações numéricas ou simbólicas, por exemplo, na forma de decisões. Entender, neste contexto, significa a transformação de imagens visuais (a entrada na retina no contexto humano) em descrições do mundo que façam sentido para processos de pensamento e possam induzir ações apropriadas. Essa compreensão de imagens pode ser vista como a separação de informações simbólicas dos dados da imagem usando modelos construídos com a ajuda da geometria, física, estatística e teoria de aprendizado (KLETTE, 2014).

Uma imagem digital é uma representação de uma imagem real por meio de um conjunto de elementos discretos e de tamanhos finitos, chamados de pixels, colocados em um arranjo bidimensional. Cada par de coordenadas (x, y) denota um ponto na imagem, como é possível ver na Figura 2 o qual é chamado de pixel.

Figura 2 – Sistema de coordenadas de Pixels



Fonte: o Autor

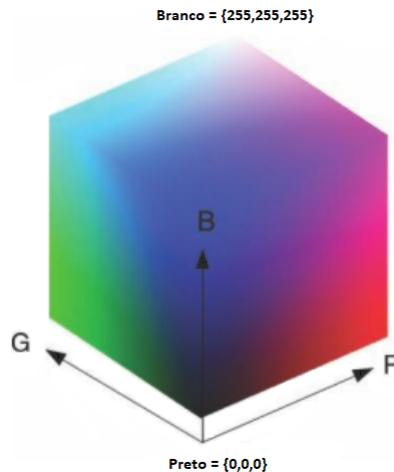
Segundo Shapiro e Stockman (2001), uma imagem digital é uma representação de dados que pode abranger diversos tipos de conteúdo, como desenhos animados, páginas de texto, retratos de pessoas, mapas ou produtos em um catálogo. Essas imagens digitais são compostas por uma grade de dimensões fixas, consistindo em linhas e colunas de elementos conhecidos como *pixels*.

Cada *pixel* é um pequeno bloco que contém um valor quantizado por uma representação numérica, geralmente situado em uma faixa de valores entre 0 e 255, representando a intensidade luminosa em um ponto específico da imagem. O significado exato desse valor depende do sistema de codificação, podendo variar entre representações onde 0 indica a intensidade mais escura e 255 a mais clara, ou vice-versa (SZELISKI, 2010b). O conjunto de convenções e representações que define como as cores são codificadas e exibidas eletronicamente é chamado de sistema de cores, dentre os mais utilizados estão RGB e HSV.

2.1.1 Sistema RGB

O sistema RGB é provavelmente o sistema de cores mais popular na representação de imagens digitais, no qual cada letra corresponde a cada um dos três canais de cores: vermelho (R - red), verde (G - green) e azul (B - blue) (JOSHI, 2015). As três cores primárias são combinadas, com valores que variam entre 0 e 255 em cada canal, totalizando mais de 16 milhões de cores diferentes. A Figura 3 demonstra como o espaço do sistema RGB pode ser representado por um cubo 3D.

Figura 3 – Ilustração 3D do Sistema RGB



Fonte: Solomon e Breckon (2011, p. 11)

2.1.2 Sistema HSV

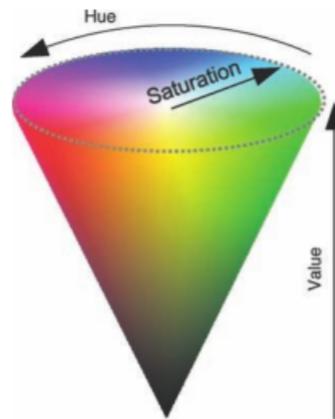
O sistema HSV é composto por três parâmetros: matiz (H - hue), saturação (S - saturation) e luminância (V - value), e é uma representação alternativa do modelo de cores RGB, projetada na década de 1970 por pesquisadores de gráficos por computador. Nestes modelos, as cores de cada matiz são dispostas em uma fatia radial, ao redor de um eixo central de cores neutras que variam de preto na parte inferior a branco na parte superior.

Esta escala pode ser representada por uma geometria cilíndrica, com a matiz, sua dimensão angular, começando no primário vermelho em 0° , passando pelo primário verde em 120° e pelo primário azul em 240° , e depois voltando ao vermelho em 360° . Nesta geometria, o eixo vertical central compreende as cores neutras, acromáticas ou cinza, variando, de cima para baixo, de branco com luminosidade 1 (valor 1) a preto com luminosidade 0 (valor 0).

As cores primárias e secundárias aditivas - vermelho, amarelo, verde, ciano, azul e magenta - e as misturas lineares entre pares adjacentes delas, às vezes chamadas de cores puras, estão dispostas ao redor da borda externa do cilindro com saturação 1; essas cores saturadas têm luminosidade 1 em HSV. Misturar essas cores puras com preto - produzindo assim as chamadas sombras - deixa a saturação inalterada. Neste sistema apenas o tingimento por branco reduz a saturação.

HSV é o sistema de cores mais popular em aplicações de análise de imagens, pois permite a separação entre cores e iluminação com uma melhor acurácia (SOLOMON; BRECKON, 2011). Diferente do sistema RGB, o espaço HSV pode ser representado por um cone 3D, como é visto na figura Figura 4

Figura 4 – Ilustração do cone 3D que representa o Sistema HSV



Fonte: Solomon e Breckon (2011, p. 11)

2.1.3 Limiarização De Imagens

Dentre das técnicas de segmentação de imagens, a Limiarização é um procedimento que seleciona um conjunto de pixels em uma imagem utilizando o valor do pixel (cor ou intensidade) como separador (GONZALEZ; WOODS, 2002). A matriz de pixels é percorrida e cada coordenada é avaliada segundo o limiar estabelecido. Segundo o critério de classificação utilizado, é atribuído o valor de 0 ou 1, segmentando assim o objeto de interesse em relação ao segundo plano da imagem.

O limiares podem ser definidos como pontos únicos ou bandas (limite inferior e superior), e no caso de imagem com múltiplos canais de cores, é possível definir um limiar para cada canal separadamente. O processo de Limiarização é altamente dependente da iluminação, de tal modo que é recomendada a conversão de uma imagem RGB para HSV como forma de atenuar essa dependência.

Embora em alguns casos o limiar possa ser selecionado manualmente pelo usuário, existem muitos casos em que o usuário deseja que o limiar seja definido automaticamente por um algoritmo. Nestes casos, o limiar deve ser o “melhor” limiar no sentido de que a partição dos pixels acima e abaixo do limiar deve corresponder o mais próximo possível à partição real entre as duas classes de objetos representados por esses pixels (por exemplo, os pixels abaixo do limiar devem corresponder ao fundo e os acima a alguns objetos de interesse na imagem) (SEZGIN; SANKUR, 2004).

Dentre os métodos de limiarização automáticos, o escolhido foi o baseado na forma do histograma. No processamento de imagens, o método de Limiarização de Histograma Balanceado (BHT) é um método muito simples usado para a definição automática de limiar em imagens. Assim como o Método de Otsu (OTSU, 1979) e o Método de Limiarização de Seleção Iterativa, este é um método de limiarização baseado em histograma.

Essa abordagem pressupõe que a imagem é dividida em duas classes principais: o fundo e o primeiro plano. O método BHT tenta encontrar o nível de limiar ótimo que divide o histograma em duas classes.

Este método pondera o histograma, verifica qual dos dois lados é mais pesado e remove peso do lado mais pesado até que ele se torne o mais leve. Ele repete a mesma operação até que as bordas da balança de pesagem se encontrem (ANJOS; SHAHBAZKIA, 2008).

2.2 Redes Neurais

Uma ampla gama de algoritmos de inteligência artificial tem sido desenvolvida e aplicada para problemas de classificação de padrões. Sendo as redes neurais artificiais a técnica prevalente devido à sua capacidade de mapeamento de entrada-saída não linear (RUNXUAN, 2005). Seu nome e estrutura são inspirados pelo cérebro humano, imitando a maneira como os neurônios biológicos se comunicam entre si. Eles permitem classificar e agrupar dados, após dependerem do treinamento com dados para melhorar ao longo do tempo.

O cérebro humano é composto por cerca de 100 bilhões de neurônios que se comunicam entre si por meio de sinais elétricos e químicos. Uma Rede Neural Artificial (RNA) é um algoritmo que simula os neurônios por meio de uma representação matemática, com capacidade de comunicação e aprendizagem através de experiências (AHMED et al., 2015).

A arquitetura de uma RNA é definida pelo modo que os neurônios artificiais estão conectados entre si. É possível representar a estrutura de redes neurais utilizando três tipos de camadas: Entrada, Escondidas e Saída. A camada de entrada (input layer) é representada pelas informações externas fornecidas a rede neural. Enquanto nas camadas escondidas (hidden layers) é realizado o processamento dos dados, realizando a conexão entre a entrada e saída. Já a camada de saída (output layers) representa o valor final, ou seja, o resultado.

Segundo Silva, Spatti e Flauzino (2010, p. 47), as RNA também podem ser divididas em redes FeedForward (alimentação à frente) de camada simples, redes FeedForward de camadas múltiplas, redes recorrentes e redes de grafos. O processo de treinamento de RNA busca desenvolver a capacidade de aprender a partir de padrões e conseqüentemente definir a relação entre entradas e saídas a fim de poder generalizar soluções. Esse processo é feito por meio do algoritmo de aprendizado, no qual os pesos dos neurônios (parâmetros internos da RNA) são otimizados. Cada nó, ou neurônio artificial, está conectado a outro e possui um peso e um limite associados. Se a saída de qualquer nó individual estiver acima do valor de limite especificado, aquele nó é ativado, enviando dados para a próxima camada da rede (GOEL; GOEL; KUMAR, 2023).

Para um treinamento supervisionado, cada entrada é fornecida juntamente com sua respectiva saída esperada. Neste caso, a RNA é considerada treinada quando a diferença

entre os valores estimados e os valores reais ficam dentro de um intervalo aceitável, atinge o número máximo de iterações ou tempo máximo de treinamento. Enquanto no treinamento não-supervisionado as saídas são inexistentes, e a RNA deve se auto-organizar em relação aos padrões entre as amostras disponibilizadas e dividi-los de acordo com essas similaridades (ALLOGHANI et al., 2020).

O conjunto de dados utilizado no processo de treinamento é normalmente dividido em dois sub-conjuntos, sendo estes os dados de treinamento e os dados de teste. Os dados de treinamento são utilizados no algoritmo de aprendizado, enquanto os dados de testes são usados para verificar a capacidade de generalização da solução proposta.

As proporções dos dados contidos nos conjuntos dados de treinado e teste variam de 60 a 90% e 10 a 40% respectivamente. Porém, o fator decisivo sobre a distribuição entre os conjuntos é a caracterização de dados, como por exemplo o balanceamento de tratamentos.

Uma vez treinada, a qualidade de uma regressão de uma RNA pode ser avaliada por uma variedade de métricas. Entre as mais comuns temos o Erro Quadrático Médio (Mean Square Error - MSE) e o Coeficiente de Determinação (R Squared - R^2).

O MSE é normalmente utilizado para verificar a acurácia de modelos, o qual atribui um peso maior aos maiores erros, uma vez que são elevados ao quadrado como é visto na Equação 1. Fato que também torna a métrica bastante sensível a valores outliers.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

Já o R^2 é uma medida de quão bem o modelo se ajusta aos dados (STEEL; TORRIE, 1960; GLANTZ; SLINKER; NEILANDS, 1996). Ele é calculado pela Equação 2, a qual utiliza a razão entre a soma dos quadrados dos resíduos (Sum of Squared Errors - SSE) e soma total dos quadrados (Total Sum of Squares - SST). Valores perto de 1 indicam uma alta capacidade do modelo para explicar o dados, enquanto valores próximos de 0 indicam que o modelo não consegue explicar a variação dos dados.

$$R^2 = 1 - \frac{SSE}{SST} \quad (2)$$

2.3 Ferramentas Computacionais

O presente projeto tem como objetivo o uso de ferramentas gratuitas e de código aberto. A escolha foi baseada na praticidade de implementação e comunidade de desenvolvedores, a qual fornece um grande ecossistema de troca de informações.

2.3.1 Python

Python é uma linguagem orientada ao objetivo de alto nível gratuita e disponível para as principais plataformas. (PYTHON, 2022) Dentre as principais vantagens da sua

utilização, se destacam a grande variedade de bibliotecas e exemplos disponíveis online. Todo o desenvolvimento do presente trabalho é realizado utilizando a linguagem Python na versão 3.9.12 por meio do ambiente de desenvolvimento (IDE) Spyder (SPYDER IDE, 2022).

2.3.2 OpenCV

Open source Computer Vision library (OpenCV) é uma biblioteca desenvolvida pela Intel, lançada em 1999, usada para visão computacional, aprendizado de máquina e processamento de imagem (OPENCV, 2022). Diversos tipos de rotinas no âmbito de análise de vídeos e imagens (mais de 2500 algoritmos otimizados) são disponibilizadas de forma a viabilizar sistemas complexos de forma rápida e confiável.

É parte da iniciativa Open Source e está disponível em diversas plataformas, sendo as principais: Windows, Linux, Mac OS, iOS e Android. A biblioteca tem uma grande comunidade online e é extensamente utilizada por grandes corporações, grupos de pesquisas e departamentos governamentais ao redor do mundo.

No presente trabalho, o desenvolvimento é feito com a versão 4.6 da biblioteca.

2.3.3 Sklearn

A biblioteca *Scikit-Learn* (PEDREGOSA et al., 2011) é uma biblioteca de aprendizado de máquina de código aberto para a linguagem Python. Ela oferece várias ferramentas para tarefas de aprendizado de máquina, como classificação, regressão, agrupamento e pré-processamento de dados.

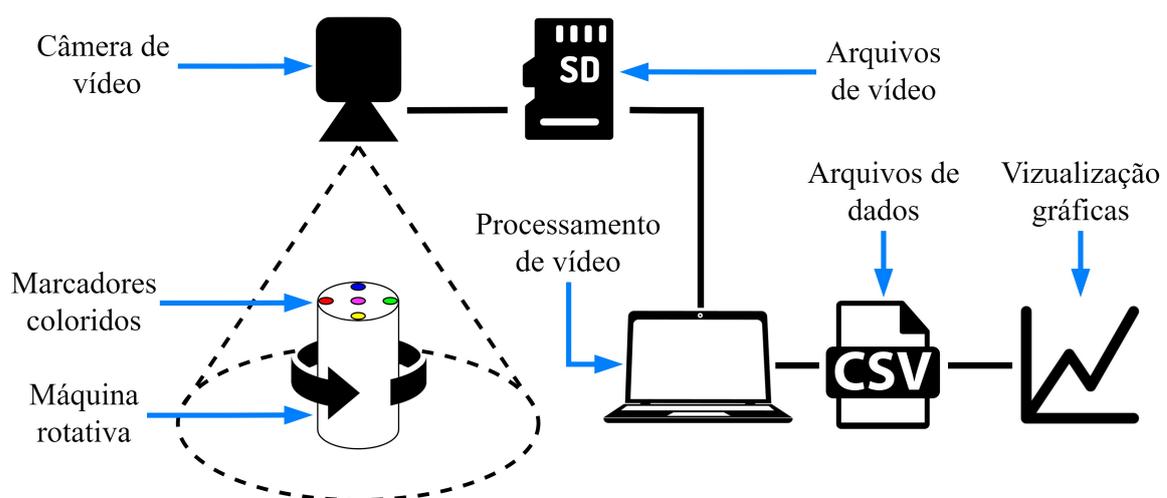
Capítulo 3

Materiais e Métodos

3.1 Sistema de Visão Computacional

A fim de obter dados de posição e velocidade sem contato, é proposto um sistema de visão computacional organizado em três etapas: Aquisição de Imagem, Processamento de Imagem e Exportação de Dados. A Figura 5 ilustra os componentes e etapas de funcionamento do sistema.

Figura 5 – Esquemático do Sistema de Visão de Computacional



Fonte: o Autor

Os adesivos de marcadores circulares são utilizados para sinalizar regiões as quais se deseja rastrear por meio do sistema de visão computacional. A utilização de cores que se

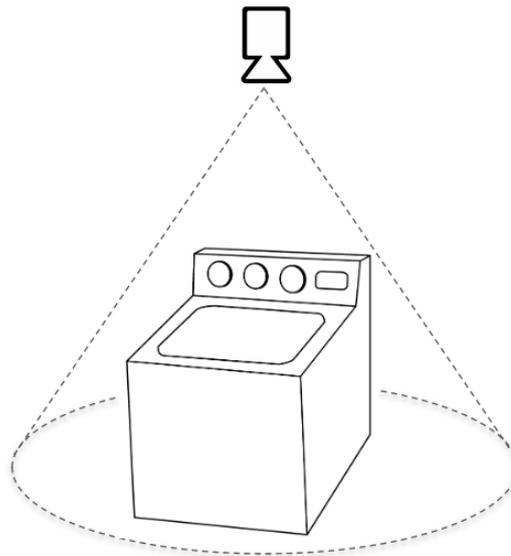
diferenciam do restante da imagem é crucial para a efetividade do algoritmo implementado, fato esse demonstrado nas próximas seções.

Para o experimento desenvolvido na presente dissertação, são utilizados 5 marcadores de cores distintas (adesivos com 19mm de diâmetro), sendo 4 deles para cálculo de rotação e 1 para referência de translação - posicionado no centro do plano. Múltiplos marcadores para rotação são utilizados por razões de redundância a fim de avaliar a parametrização e performance das diferentes cores.

3.1.1 Aquisição de Imagem

O sistema de aquisição de imagens proposto consiste no posicionamento de uma câmera horizontalmente paralela ao eixo rotor e perpendicular ao campo de visão do mesmo, de modo que seja capturada a vista superior da superfície cilíndrica, exemplificado na Figura 6.

Figura 6 – Esquemático do Setup de Filmagem



Fonte: o Autor

A câmera *GoPro Black 10* foi escolhida para o projeto de visão computacional devido à sua capacidade de gravar vídeos em alta taxa de quadros por segundo (de 30 a 240 FPS) e resoluções elevadas (de 720p a 4K). Essas características são essenciais para capturar com precisão ações rápidas e detalhes, fundamentais para as aplicações de visão computacional no projeto.

No contexto da aplicação em questão, a máquina de lavar utilizada no estudo pode atingir uma velocidade máxima de 750 RPM (equivalente a 12.5 Hz). Conforme estabelecido pelo Teorema de Nyquist (SHANNON, 1949), é essencial que a frequência de

amostragem seja pelo menos o dobro da frequência do sinal, o que nesse caso requer uma taxa mínima de 25 Hz para capturar os dados adequadamente. A câmera selecionada opera com uma taxa mínima de 30 FPS (30 Hz), mas optamos por explorar taxas mais elevadas, como 60 e 120 FPS, para assegurar que o arquivo de vídeo possa registrar o fenômeno físico com uma ampla margem de segurança, garantindo assim a qualidade e a confiabilidade dos dados capturados.

Além da taxa de amostragem, outro parâmetro igualmente importante é a velocidade do obturador (tempo de exposição), em inglês *shutter*, pois determina a quantidade de luz a qual o sensor da câmera é exposto. Em situações envolvendo cenas dinâmicas (caso do fenômeno estudado), a escolha da velocidade do obturador desempenha um papel crucial na determinação do grau de desfoque de movimento presente na imagem final. Tipicamente, uma velocidade do obturador mais elevada resulta em um menor desfoque de movimento, permitindo uma melhor nitidez dos pixels. Porém, o menor tempo de exposição também resulta em imagens mais escuras. (SZELISKI, 2010b).

3.1.2 Processamento de Imagem

Terminada a aquisição de vídeo, os arquivos são transferidos para um computador por meio de um cartão de memória a fim de executar o processamento das imagens. Um código em Python é utilizado para pós-processar os arquivos de vídeo, extrair as informações e, em seguida, exportá-las para um arquivo CSV. A Figura 7 mostra um fluxograma do sequenciamento das ações empregadas.

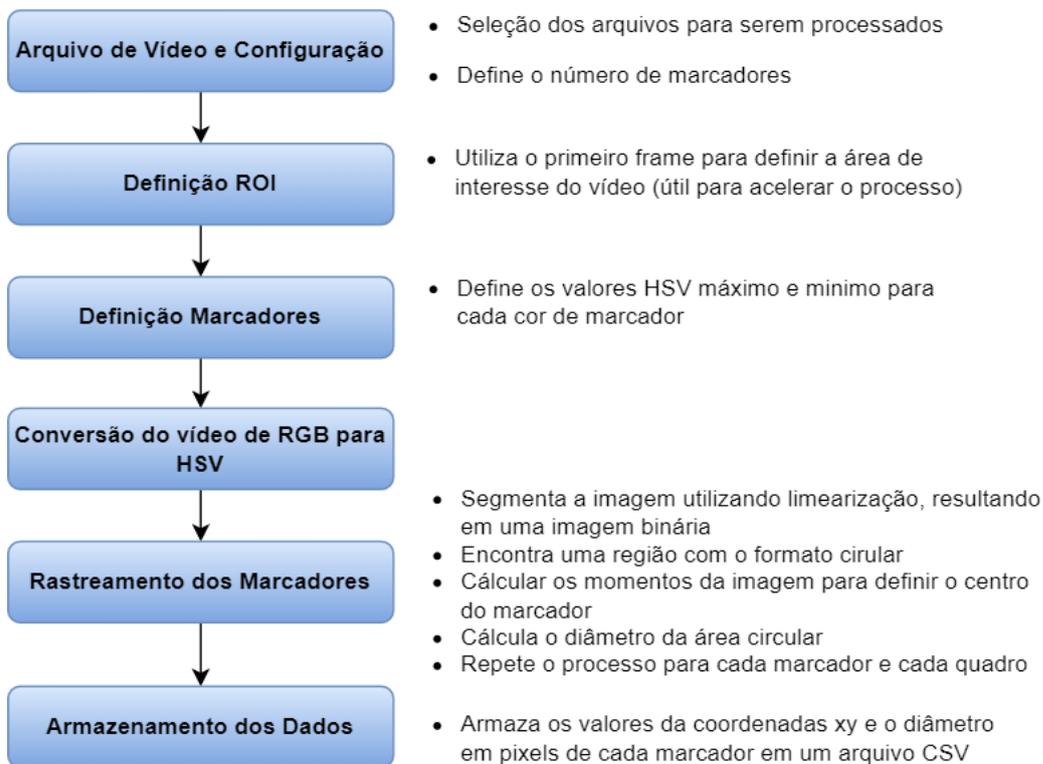
A primeira etapa consiste na seleção da área de interesse do vídeo, *Region of Interest (ROI)* em inglês, a qual restringe a matriz de pixels de cada quadro a ser processado. Tal técnica é aplicada com o objetivo de reduzir o número de pixels a serem processados, acelerando a análise.

Após isso, a biblioteca *OPENCV* captura as imagens no formato *Blue, Green and Red (BGR)* por padrão (formato *RGB* ordenado inversamente) na forma de números inteiros de 0 a 255. Como discutido anteriormente, os componentes *R, G* e *B* são altamente correlatos com a quantidade de luminosidade presente nos objetos que se deseja detectar, em outras palavras, não é possível diferenciar a informação de cor da luminância, dificultando a segmentação da imagem.

Deste forma, seu formato é transladado para o formato *HSV*, o qual oferece vantagens na separação de luminosidade e cor, o componente de matriz *H* por exemplo, representa diretamente a cor facilitando o isolamento da mesma e conseqüentemente permitindo um rastreamento do marcador. Para ilustrar a vantagens do formato *HSV* sobre o formato *RGB*, considere a Figura 8 composta por 4 quadrados com áreas iguais e cores distintas (Azul, Amarelo, Verde e Vermelho).

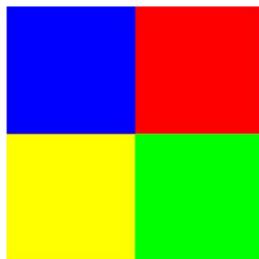
Um histograma da Figura 8 é calculado considerando ambos sistemas de cores. Na Figura 9a observa-se que os canais *R, G* e *B* se misturam de modo a não ser possível

Figura 7 – Fluxograma simplificado do processamento de imagem



Fonte: o Autor

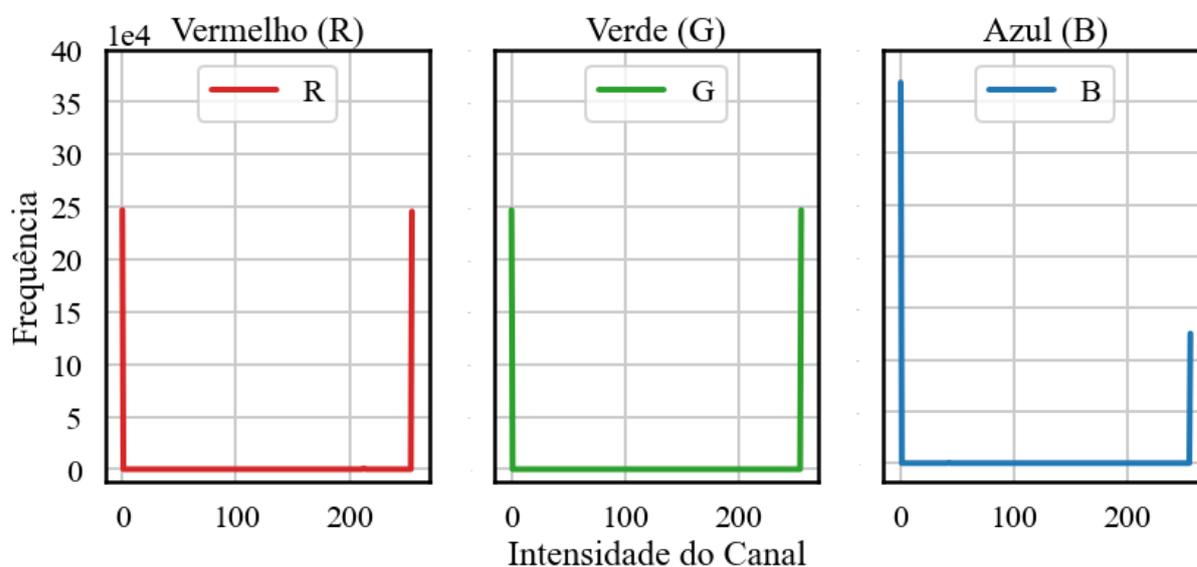
Figura 8 – Exemplo para comparação entre RGB e HSV



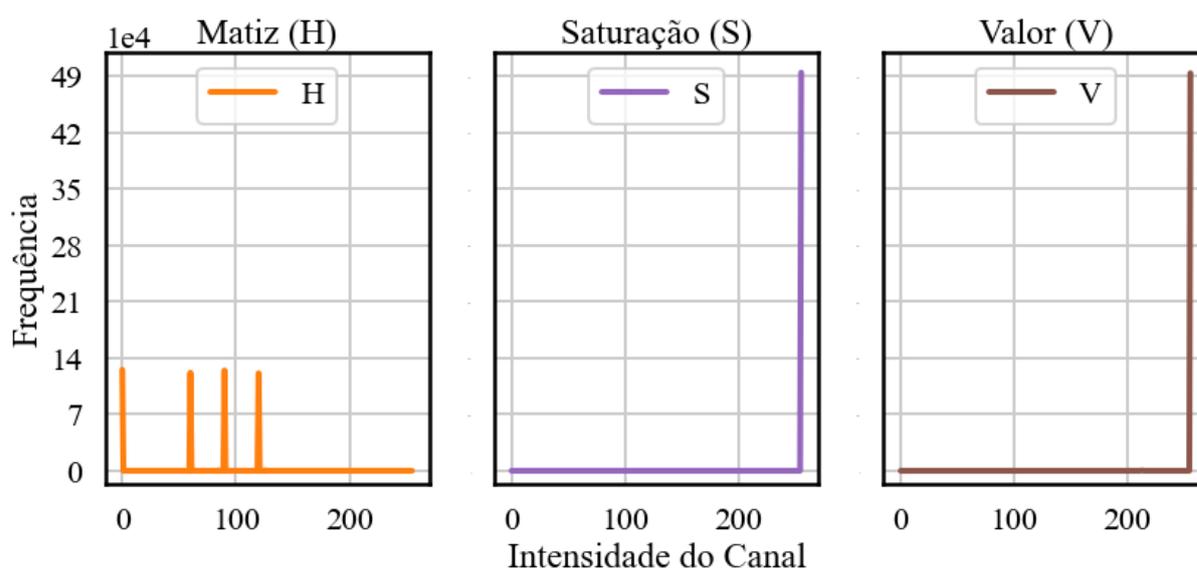
Fonte: o Autor

identificar padrões de valores referente às 4 cores distintas. Enquanto em Figura 9b, com o Formato HSV, o canal H indica a presença de 4 picos de amplitude semelhante que correspondem as 4 cores distintas. Logo, para cada marcador que se deseja detectar é necessário definir um limite inferior e superior correspondente a cor desejada no formato HSV.

Figura 9 – Comparação entre os Histogramas RGB e HSV da imagem da Figura 8



(a) Histograma RGB

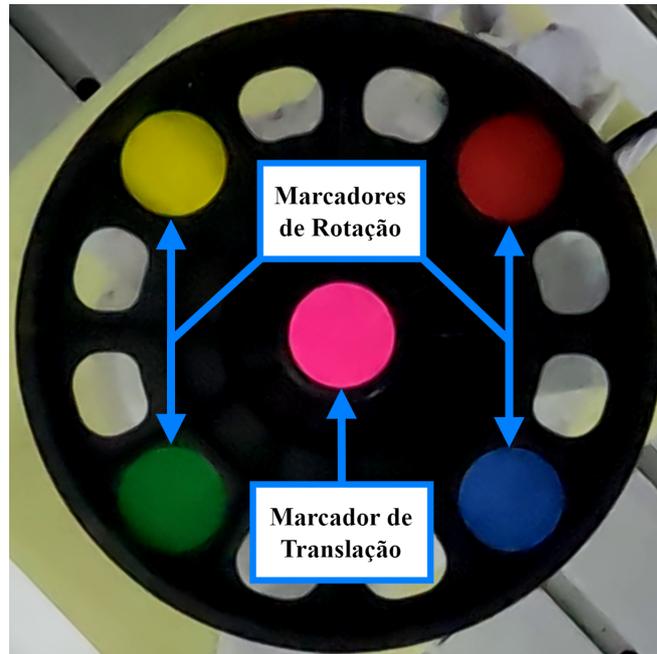


(b) Histograma HSV

Fonte: o Autor

As cores selecionadas para os marcadores devem contrastar com o restante da imagem a fim de viabilizar a técnica de segmentação de imagem por limiarização. As regiões de interesse, ou seja, pontos com movimentos de translação e/ou rotação que se deseja rastrear são caracterizados pelos adesivos. Esta etapa consiste no posicionamento e classificação dos marcadores quanto ao tipo de movimento que será executado. A Figura 10 demonstra os cinco marcadores coloridos classificados.

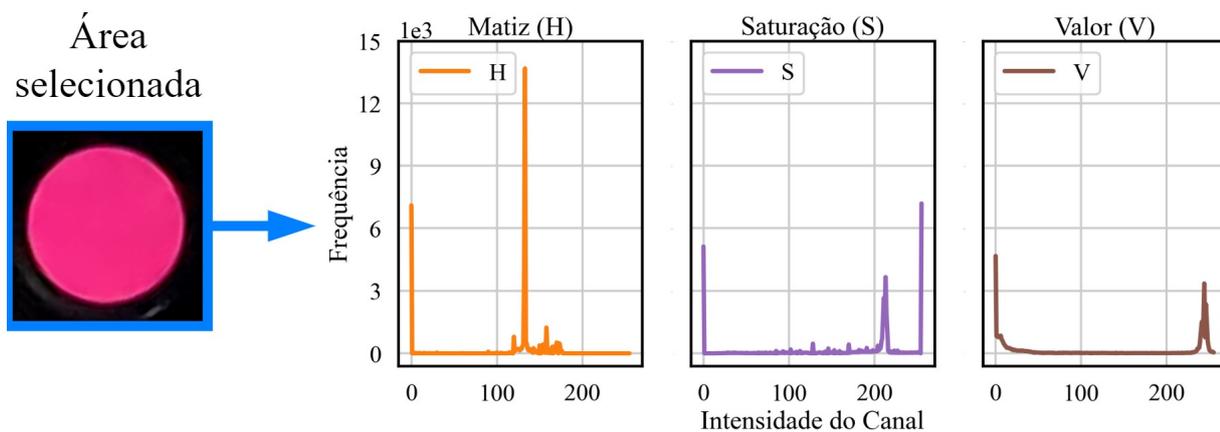
Figura 10 – Marcadores classificados



Fonte: o Autor

A definição dos valores HSV dos limites inferior superior para cada cor de marcador foi feita com o auxílio de uma função que retorna um histograma do valores HSV de uma área selecionada.

Figura 11 – Histograma HSV aplicado ao marcador Rosa



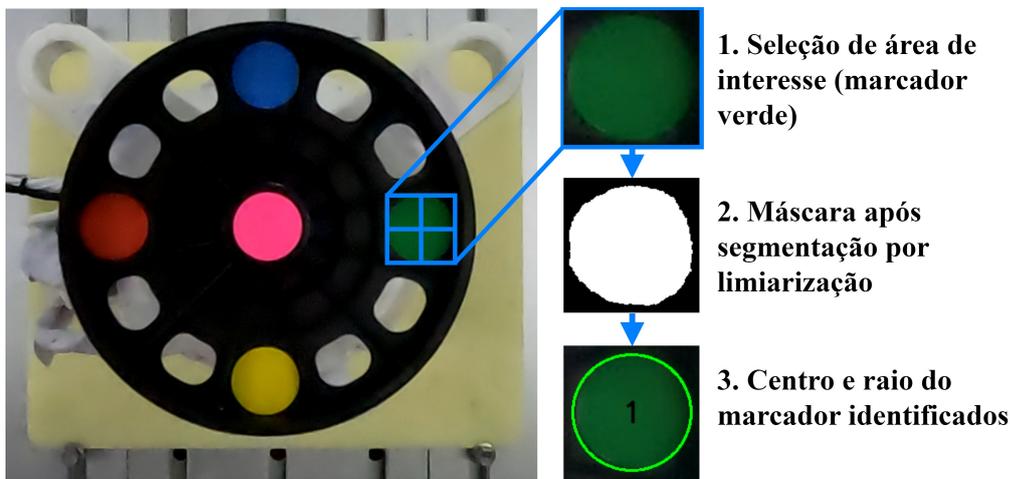
Fonte: o Autor

No exemplo da Figura 11, a ferramenta é aplicada para obter os valores HSV inferior e superior do marcador rosa. Embora existam outras cores na área selecionada, a pre-

dominância e homogeneidade da cor de rosa cria picos, os quais permitem determinar a distribuição de valores da cor que se deseja segmentar.

Após o processo de segmentação por limiarização, é obtida uma imagem binária, onde a área de interesse - caracterizada pela cor branca - corresponde aos pixels cujos valores HSV estão dentro dos limites mínimo e máximo especificados para a cor desejada, enquanto a área descartada - caracterizada pela cor preta - corresponde aos pixels cujos valores de cor estão fora destes limites, como exemplificado na Figura 12.

Figura 12 – Exemplo do processo de rastreamento



Fonte: o Autor

A posição do marcador é determinada pelo cálculo do centroide $C(x, y)$ da imagem binária, o qual é calculado pela Equação 3 (PEDRINI; SCHWARTZ, 2008):

$$C(x, y) = \left(\frac{M_{10}}{M_{00}}, \frac{M_{01}}{M_{00}} \right) \quad (3)$$

Sendo M_{10} e M_{01} momentos de primeira ordem e M_{00} o momento de ordem zero. O momento de ordem zero M_{00} é calculado somando-se a intensidade de todos os pixels na imagem binária, refletindo a área total do objeto de interesse. O momento de primeira ordem M_{10} é obtido somando-se o produto de cada coordenada x de um pixel pela sua intensidade, enquanto o momento de primeira ordem M_{01} é calculado somando-se o produto de cada coordenada y de um pixel pela sua intensidade correspondente. Esses momentos capturam informações sobre a distribuição espacial do objeto na imagem.

A partir disso, é calculado $M_{p,q}$ que representa o momento da imagem de ordem $(p + q)$, onde p e q são inteiros positivos. Sendo $f(x, y)$ a intensidade do pixel (x, y) , $M_{p,q}$ é calculado pela Equação 4 (PEDRINI; SCHWARTZ, 2008):

$$M_{p,q} = \sum_x \sum_y x^p y^q f(x, y) \quad (4)$$

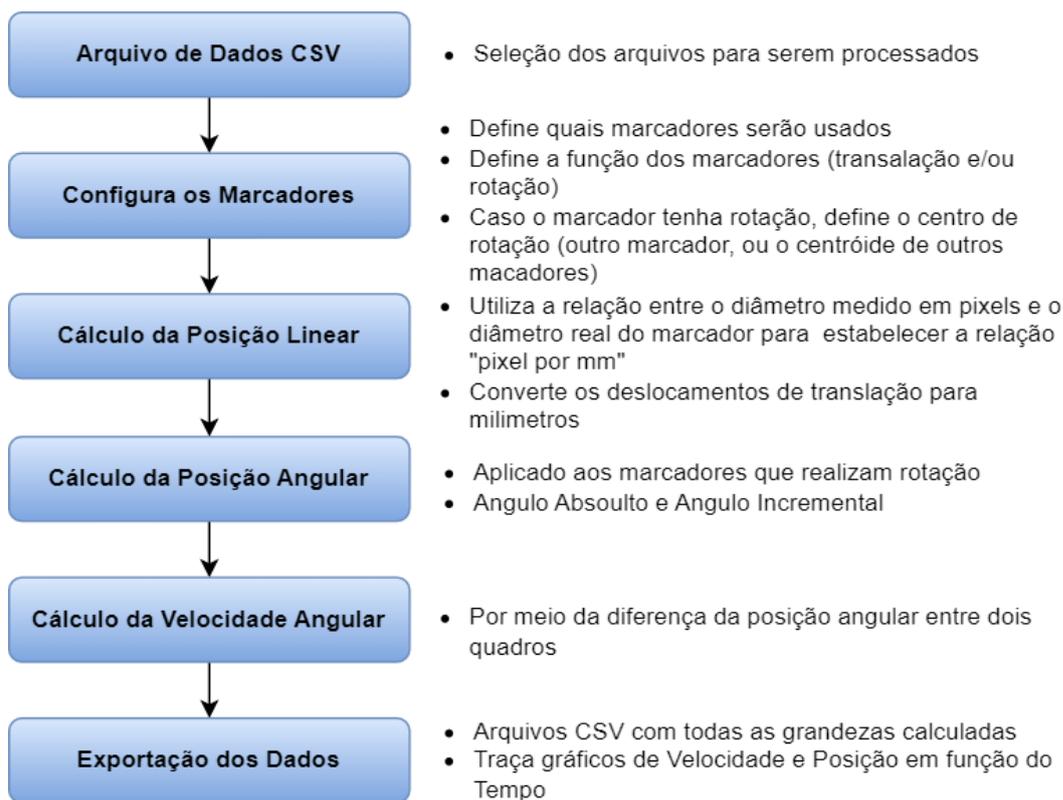
Desta forma, é possível realizar o processo de rastreamento. Tendo por base a imagem segmentada (região branca) são obtidas as coordenadas do pixel que representa o centroide do marcador e o raio estimado, possibilitando traçar um círculo sobre o marcador identificado.

Após o rastreamento de todos os marcadores em todos os quadros do vídeo, as coordenadas (x, y) e o raio da área de cada marcador, juntamente com a base de tempo, são exportados e armazenados em colunas de um arquivo CSV.

3.1.3 Exportação de Dados

Com base nos dados coletados na etapa anterior, o próximo passo envolve a interpretação das leituras para calcular os valores de posição angular, translacional e velocidade angular. O fluxograma apresentado na Figura 13 descreve as fases desta etapa específica.

Figura 13 – Ilustração do cálculo do Posicionamento Angular

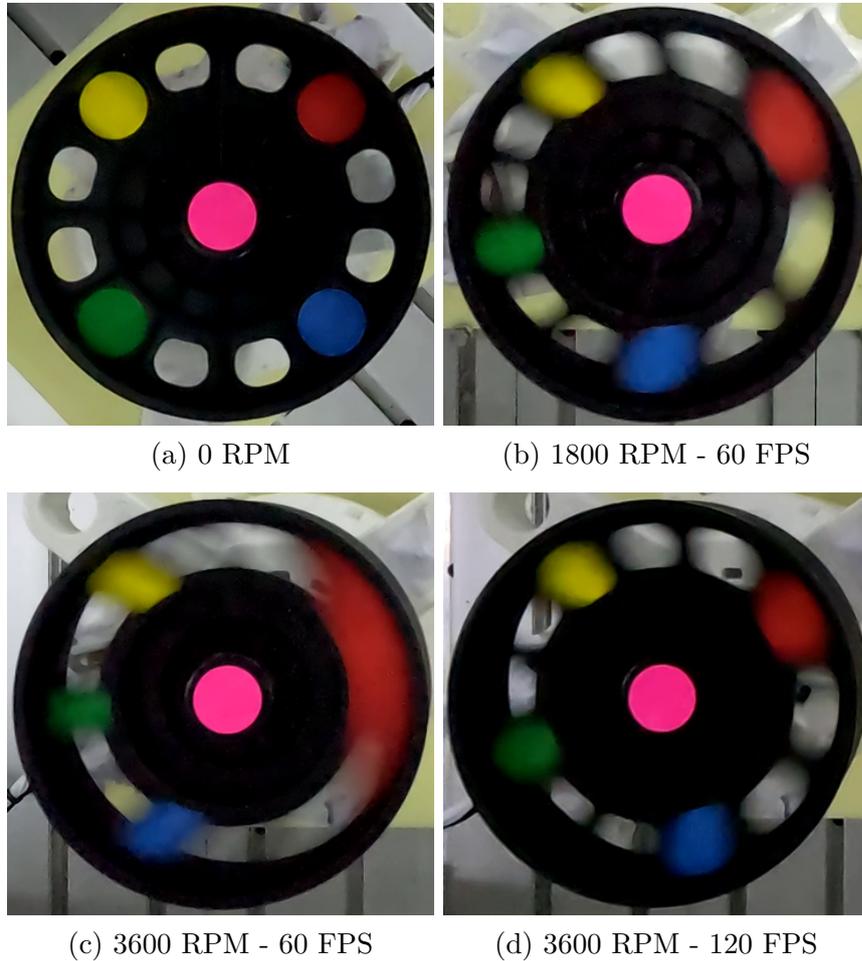


Fonte: o Autor

Embora todos os marcadores sejam rastreados de maneira uniforme, a classificação dos marcadores com base em seu tipo de movimento tem o propósito de limitar o cálculo da posição linear apenas aos que executaram uma translação. Isso ocorre porque a lógica empregada para estabelecer a relação entre pixels e milímetros depende da estimativa pre-

cisa do diâmetro do marcador circular. No entanto, essa estimativa se torna impraticável em objetos que estão girando rapidamente, devido ao desfoque causado pelo movimento. Esse efeito é ilustrado na Figura 14.

Figura 14 – Comparação entra diferentes taxas de quadros e rotações



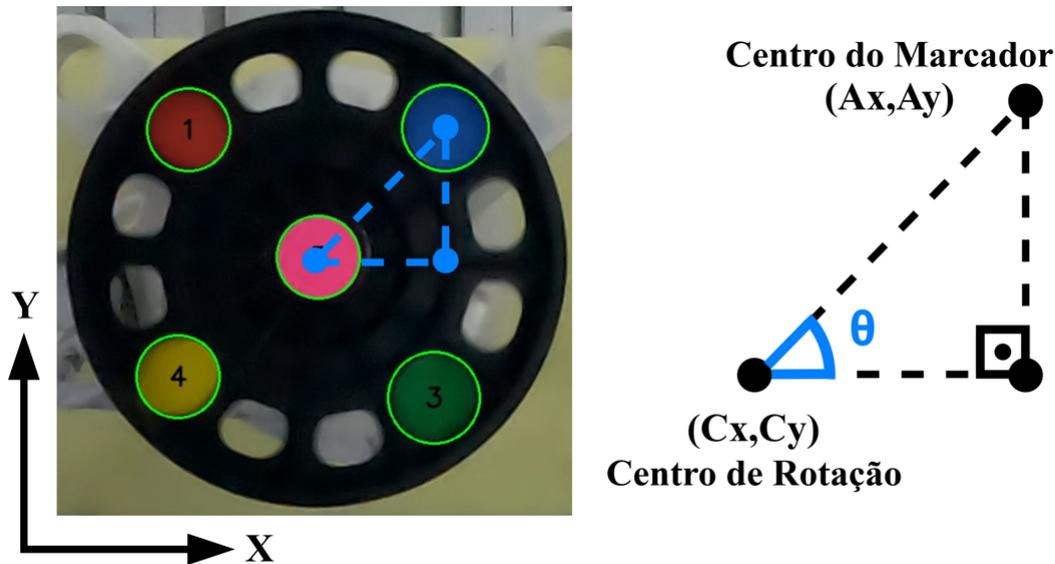
Fonte: o Autor

Uma vez classificados, a posição linear nada mais é que a conversão das coordenadas (x,y) de pixels para milímetros. Os marcadores são constituídos por círculos padronizados de 19 mm de diâmetro, e o diâmetro em pixel do marcador d_{pixels} é também conhecido, logo, a Coordenada em milímetros C_{mm} é dada pela Equação 5:

$$C_{milímetros} = \left(x_{pixels} * \frac{19}{d_{pixels}}, y_{pixels} * \frac{19}{d_{pixels}} \right) \quad (5)$$

Sequencialmente é calculado o ângulo em que cada marcador se encontra em relação ao eixo vertical da imagem. A Figura 15 ilustra a lógica empregada no cálculo do ângulo no qual o marcador 1 se encontra. Inicialmente é definida a coordenada do centro de rotação do marcador 1 como a coordenada do centróide entre os marcadores 2 e 3, uma vez que estes encontram-se cerca de 90 graus deslocados do marcador 1.

Figura 15 – Demonstração do cálculo do Posicionamento Angular



Fonte: o Autor

Por meio das coordenadas do marcador e do centro de rotação, o ângulo é obtido pelo cálculo do arco tangente dada pela Equação 6:

$$\theta = \arctan \left(\frac{Ay - Cy}{Ax - Cx} \right) \quad (6)$$

Por final, a velocidade angular é calculada pela diferença entre duas medidas sequenciais de posição dividida pelo tempo entre as duas amostragem. Com todas as grandezas calculadas, os dados são exportados para um arquivo CSV e gráficos de deslocamento e velocidade ao longo do tempo serão gerados.

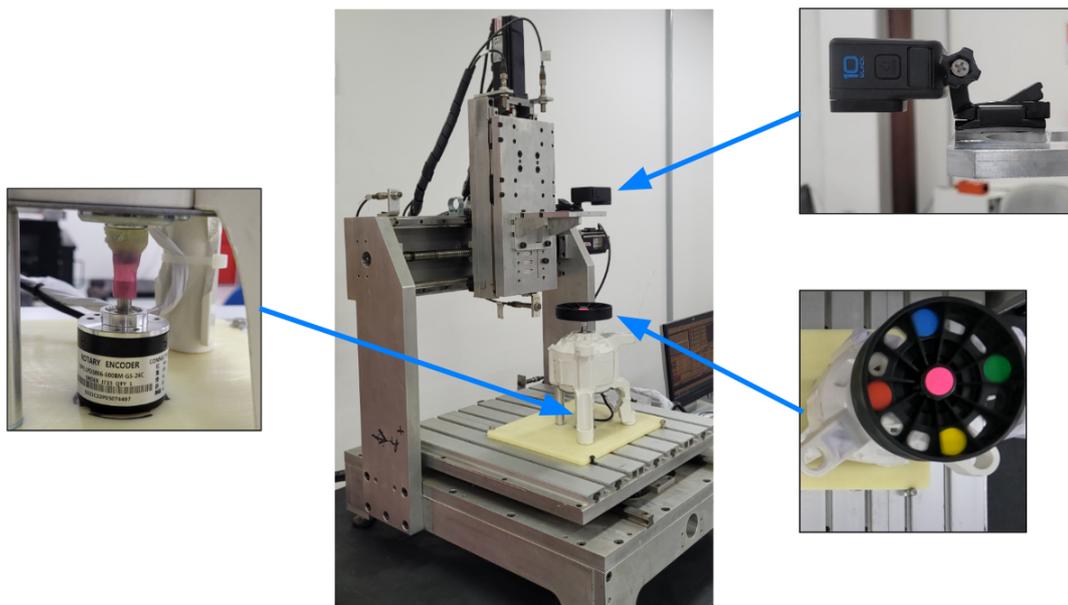
3.1.4 Experimentos de Verificação e Validação

Com o objetivo de avaliar a precisão e acurácia do sistema proposto, foram realizados experimentos controlados em ambiente de laboratório, com enfoque apenas na performance do sistema de visão, e como ele se comporta em relação às variações do objeto de análise (rotor). Para tal foi utilizada uma máquina de Controle Numérico Computadorizado (CNC) de 3 eixos, capaz de executar uma trajetória programada de forma precisa e consistente. Como referência para a velocidade angular, um encoder de 600 pulsos por revolução com 2 canais foi utilizado em modo de quadratura (ou seja, com 2400 pulsos por revolução) com a amostragem de 125 Hz.

A simulação do movimento de rotação da Lavadora é feita por meio de um motor elétrico controlado por uma placa inversora de frequência, capaz de controlar em velocidades de 100 a 17000 RPM e aceleração constante. Como dito anteriormente, a captura

da filmagem é feita por uma câmera GoPro 10. A Figura 16 mostra a configuração de teste utilizada.

Figura 16 – Configuração de teste

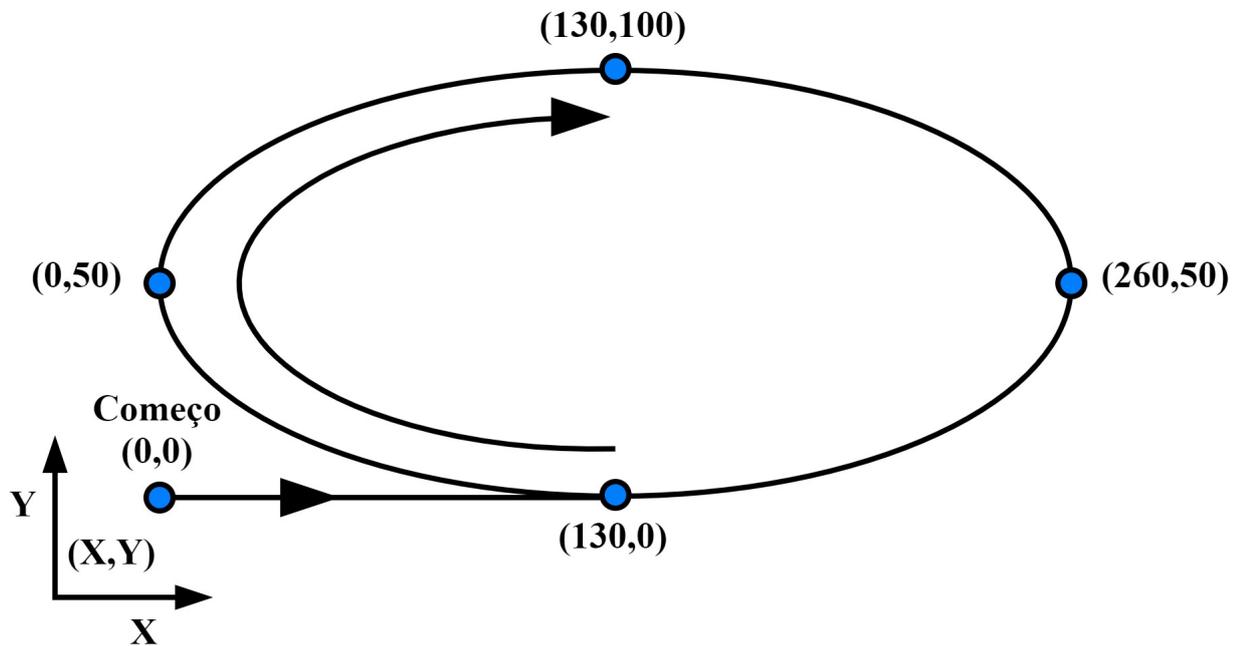


Fonte: o Autor

O primeiro experimento é projetado para avaliar a capacidade do sistema proposto em medir velocidades angulares em diferentes acelerações e configurações de câmera. Como representado na Figura 17, uma trajetória elíptica é proposta, enquanto o motor executa uma curva de aceleração constante. Simultaneamente, a medição da velocidade angular é realizada por meio do encoder óptico rotativo acoplado ao eixo do motor, visando a futura comparação com a saída do sistema proposto. Todas as combinações de configurações avaliadas neste experimento são detalhadas na Tabela 1.

A variação no parâmetro de resolução da câmera tem como objetivo analisar o impacto da qualidade da imagem capturada na precisão das medições. Em altas resoluções permitem mais grau de detalhamento, porém consomem mais memória de armazenado e demandam maior poder de processamento. Enquanto a taxa de quadros por segundo é entendida analogamente a taxa de amostragem do sinal. Taxas altas são utilizadas para capturar movimentos rápidos, enquanto taxas mais baixas podem ser suficientes para movimentos mais lentos. As configurações do obturador (*shutter*) determinam o tempo o qual o sensor óptico da câmera fica exposto à luz, tal configuração impacta diretamente na nitidez da imagem.

Figura 17 – Trajetória programada na máquina CNC - Experimento de Velocidade Angular e Configuração de Câmera



Fonte: o Autor

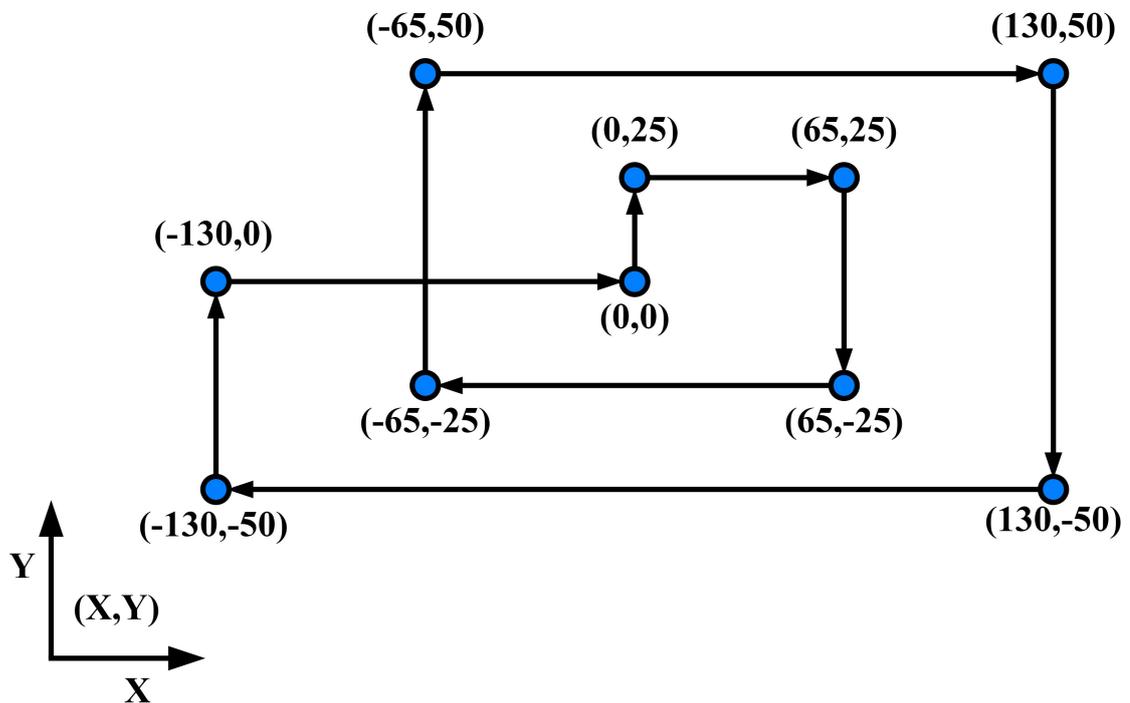
Tabela 1 – Configurações - Experimento de Velocidade Angular e Configuração de Câmera

Teste:	Resolução:	FPS:	ISO:	Shutter:	Velocidade Inicial (RPM):	Velocidade Final (RPM):	Aceleração (RPM/s):
1	2.7K	60	800-3200	1/960	100	3600	30
2	2.7K	60	800-3200	1/960	100	3600	60
3	2.7K	120	800-3200	1/1920	100	3600	60
4	2.7K	120	800-3200	1/1920	100	3600	30
5	1080	120	800-3200	1/1920	100	3600	30
6	1080	120	800-3200	1/1920	100	3600	60
7	1080	60	800-3200	1/960	100	3600	30
8	1080	60	800-3200	1/960	100	3600	60

Fonte: Autor

Sequencialmente, o segundo experimento tem como foco avaliar a capacidade do sistema em medir a posição linear dos marcadores. Para isso, foi programada uma trajetória em forma de “labirinto” na qual o marcador executa uma série de movimentos conhecidos que servirão como referência de posição. A Figura 18 ilustra a trajetória a ser percorrida, já a Tabela 2 mostra os pontos, trechos e suas respectivas distâncias percorridas, enquanto a Tabela 3 detalha as demais configurações.

Figura 18 – Trajetória programada na máquina CNC - Experimento de Posição Linear



Fonte: o Autor

Tabela 2 – Pontos da trajetória - Experimento de Posição Linear

Percursos:	Ponto Inicial (x,y):	Ponto Final(x,y):	Distância Percorrida:
1	(0,0)	(0,25)	25
2	(0,25)	(65,25)	65
3	(65,25)	(65,-25)	50
4	(65,-25)	(-65,-25)	130
5	(-65,-25)	(-65,50)	75
6	(-65,50)	(130,50)	195
7	(130,50)	(130,-50)	100
8	(130,-50)	(-130,-50)	260
9	(-130,-50)	(-130,0)	50
10	(-130,0)	(0,0)	130

Fonte: Autor

Tabela 3 – Configurações - Experimento de Posição Linear

Teste:	Resolução:	FPS:	ISO:	Shutter:	Velocidade do Motor (RPM):	Velocidade do CNC (mm/min):
1	2.7K	120	800-3200	1/1920	900	2500
2	2.7K	120	800-3200	1/1920	900	5000
3	2.7K	120	800-3200	1/1920	900	10000
4	2.7K	120	800-3200	1/1920	1800	2500
5	2.7K	120	800-3200	1/1920	1800	5000
6	2.7K	120	800-3200	1/1920	1800	10000
7	2.7K	120	800-3200	1/1920	3600	2500
8	2.7K	120	800-3200	1/1920	3600	5000
9	2.7K	120	800-3200	1/1920	3600	10000

Fonte: Autor

A velocidade de rotação do motor e a velocidade de translação da CNC são variadas a fim de examinar como o método proposto se comporta em diferentes regimes de movimento. A movimentação da CNC não tem uma velocidade constante, no qual a aceleração muda durante os movimentos de início e parada.

Como terceiro e último experimento, foi conduzido um ensaio com o intuito de avaliar a precisão e consistência das medições obtidas em diferentes velocidades estacionárias. Foram quantificados os erros relativos e o desvio padrão das medições, aplicando a configuração de melhor desempenho dentre os experimentos anteriores (120 FPS e shutter de 1/1920). O perfil de velocidades de rotação contempla o intervalo de 200 a 3600 RPM, com incrementos de 200 RPM entre cada medição, obtendo medições estáticas em cada uma das velocidades predefinidas por período de tempo específico.

A precisão das medições é expressa em termos de erro relativo, comparando as velocidades medidas com as velocidades de referência. A consistência do sistema de medição sob determinada condição foi representada pelo desvio padrão normalizado das velocidades medidas. As cores dos gráficos representam as cores reais dos marcadores. Para todos os experimentos, os demais parâmetros da câmera foram mantidos constantes durante o estudo. É importante ressaltar que a faixa de valores para o ISO foi estabelecida de 800 a 3200.

3.2 Modelagem por Redes Neurais

As RNAs inicialmente buscaram inspiração na arquitetura do cérebro humano para lidar com tarefas desafiadoras que algoritmos convencionais não conseguiam resolver eficazmente. No entanto, ao longo do tempo, essas redes se voltaram mais para melhorar resultados empíricos, deixando de lado a tentativa de manter uma fidelidade estrita às suas contrapartes biológicas. O poder das RNAs reside na sua capacidade de aprender e modelar relações complexas e não-lineares. Isso é alcançado através da conexão de neurônios de diferentes maneiras, permitindo que a saída de alguns neurônios se torne a entrada de outros. Isso resulta na formação de uma rede ponderada e direcionada (ANDREAS, 2003).

Estas redes são compostas essencialmente por neurônios simulados, cada um deles conectado a outros nós por meio de conexões semelhantes às conexões biológicas entre axônios, sinapses e dendritos. Todos esses nós conectados por meio de links recebem dados e os utilizam para realizar operações e tarefas específicas. Cada uma dessas conexões possui um peso que determina a intensidade da influência de um nó sobre outro, permitindo que esses pesos escolham o sinal transmitido entre os neurônios (WINSTON, 1992).

Historicamente, muitos conceitos na computação neural foram inspirados por estudos de redes biológicas. No entanto, a perspectiva do reconhecimento de padrões estatísticos

oferece um caminho muito mais direto e fundamentado para muitos dos mesmos conceitos. Por exemplo, o modelo de soma e limiar de um neurônio surge naturalmente como a função discriminante ótima necessária para distinguir duas classes cujas distribuições são normais com matrizes de covariância iguais. Da mesma forma, a conhecida função logística é precisamente a função necessária para permitir que a saída de uma rede seja interpretada como uma probabilidade, quando a distribuição das ativações das unidades ocultas é governada por um membro da família exponencial (BISHOP, 1995).

3.2.1 Arquitetura da Rede Neural

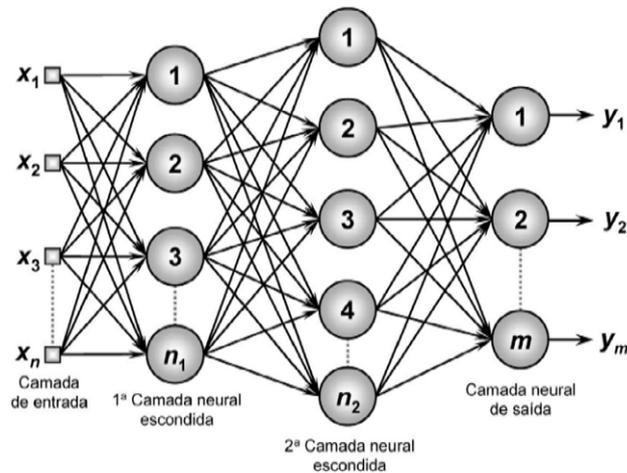
Nas RNAs, os neurônios costumam ser arranjados em diversas camadas, especialmente no contexto de *deep learning*. Em uma arquitetura neural, os neurônios de uma camada se conectam exclusivamente aos neurônios das camadas imediatamente anteriores e subsequentes. A camada que recebe os dados iniciais é chamada de camada de entrada, enquanto a camada que gera o resultado final é denominada camada de saída. Entre essas duas, podem existir zero ou mais camadas ocultas, que desempenham um papel intermediário no processamento da informação.

Existem também redes neurais que possuem apenas uma camada, bem como aquelas sem camadas ocultas. Entre duas camadas quaisquer, podem ocorrer diferentes padrões de conexão. Por exemplo, as conexões podem ser “totalmente conectadas”, o que significa que cada neurônio em uma camada se conecta a todos os neurônios na camada seguinte. Outra possibilidade é o agrupamento, onde um grupo de neurônios em uma camada se conecta a um único neurônio na camada seguinte, resultando em uma redução do número de neurônios nessa camada (CIRESAN et al., 2011).

É importante destacar que quando os neurônios têm conexões diretas apenas para as camadas anteriores, isso forma uma estrutura de grafo direcionado sem ciclos, conhecida como redes de alimentação direta (*FeedForward*) (ANDREAS, 2003). Por outro lado, redes que permitem conexões entre neurônios na mesma camada ou em camadas anteriores são chamadas de redes recorrentes (MILJANOVIC, 2012).

Na maioria dos trabalhos de aprendizado de máquina, são utilizadas três arquiteturas: rede neural convolucional (*CNN - Convolutional Neural Network*) ou rede neural totalmente convolucional (*FCNN - Fully Convolutional Neural Network*), rede neural profunda (DNN - Deep Neural Network) também conhecida como perceptron de múltiplas camadas (*MLP - Multi-Layer Perceptron*), e rede neural recorrente (*RNN - Recurrent Neural Network*) (WARRIER; AMURU, 2020).

Neste trabalho, a arquitetura utilizada é a direta (*FeedForward*) denominada MLP (*Multi-Layer Perceptron*), que devido a sua grande flexibilidade permite o ajuste do parâmetros, tais como número de camadas e neurônios em cada camada. Na Figura 19 é mostrado um exemplo de uma RNA *FeedForward* MLP.

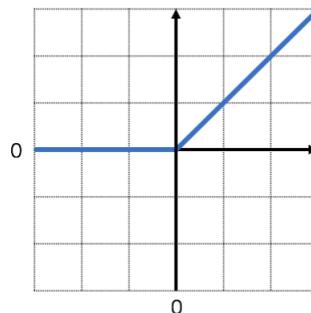
Figura 19 – Exemplo de uma rede *feedforward* multicamadas

Fonte: Silva, Spatti e Flauzino (2010, p. 48)

A MLP é uma rede neural de múltiplas camadas com conexões completas em todas as camadas. Em uma MLP, todos os *inputs* são tratados como independentes entre si. Portanto, as arquiteturas MLP são consideradas adequadas para casos em que os dados de entrada são independentes e distribuídos de forma idêntica. A implementação da RNA será feita por meio da biblioteca SKLearn, especificamente por meio da classe `sklearn.neural_network.MLPRegressor` (PEDREGOSA et al., 2011).

A função de ativação, como descrita por Loy (2019), desempenha uma importante papels nas RNAs. A qual pode ser correlacionada como a função de um transformador, onde valores recebidos como entrada são transformados pela função de ativação e transmitidos para a próxima camada. A biblioteca aplicada no atual projeto utiliza a função de ativação de Unidade Linear Retificada, em inglês Rectified Linear Unit (ReLU), como padrão. A Figura 20 ilustra o comportamento da função.

Figura 20 – Função de Ativação ReLu



Fonte: Loy (2019)

Os ajuste dos hiperparâmetros (quantidade de camadas e neurônios) será feita na fase experimental por meio de uma técnica chamada *Grid Search*. A configuração, ou topologia da RNA, ideal é encontrada por meio de um algoritmo que avalia todas as combinações possíveis por meio de alguma métrica. Embora trata-se de um algoritmo simples e eficiente, demanda um alto consumo de processamento computacional.

A avaliação de desempenho será feita por meio de validação cruzada (em inglês, *cross-validation*) (KOHAVI, 1995; RIPLEY, 1996), cuja ideia baseia-se em testar uma configuração com um conjunto de dados diferente dos dados utilizados no processo de treinamento.

Dentre as diferentes técnicas de validação cruzada, será empregada a técnica denominada validação cruzada por amostragem aleatória (em inglês, *random subsampling cross-validation*) em que o conjunto de dados é aleatoriamente dividido em duas partes: subconjunto de treinamento e subconjunto de validação. Tipicamente, de 60 a 90% dos dados são aleatoriamente selecionados para o subconjunto de treinamento, enquanto o restante é destinado ao subconjunto de validação. Esta sistemática deve ser repetidas por várias vezes a fim permitir que a configuração em teste tenha a oportunidade de ser avaliada com diferentes subconjuntos de dados, uma vez que a seleção é aleatória (SILVA; SPATTI; FLAUZINO, 2010).

Como métrica principal, será empregado o cálculo do R^2 (ou coeficiente de determinação) para comparação entre os vários ciclos de treinamento de uma determinada configuração, e sequencialmente, também na comparação entre diferentes configurações.

3.2.2 Parâmetros de Entrada

As entradas de uma RNA consistem nos padrões, em forma de parâmetros, que são apresentados a rede. O sucesso da “aprendizagem” de uma RNA depende de quão significativas as entradas são para o fenômeno que deseja modelar. Entradas sem conexão com o contexto são geralmente inúteis e podem prejudicar a precisão da RNA. Portanto, é importante que as entradas sejam cuidadosamente selecionadas.

É fato conhecido que a lavadora de roupas utilizada no experimento passa por duas frequências de ressonância durante a aceleração. A primeira frequência está localizada entre 70 e 90 RPM, enquanto a segunda ocorre entre 180 e 240 RPM. Portanto, a rampa de aceleração de 0 até 300 RPM foi selecionada para a extração das características críticas a serem utilizadas como entradas para a RNA.

A primeira variável entrada consiste no tempo gasto pela lavadora de roupas para acelerar de 10 a 250 RPM. É esperado que diferentes massas, impactem diretamente o tempo de aceleração necessário.

Outra variável importante ao fenômeno de desbalanceamento é o deslocamento da lavadora de roupas que ocorrem devido ao impacto do tanque com o gabinete, o qual ocorre

por grandes massas desbalanceadas. Logo, a segunda variável de entrada é composta pelo deslocamento ocorrido entre 10 e 250 RPM.

O perfil da órbita realizada pelo conjunto de massa suspensa (Tanque, Cesto e Cargas) durante a aceleração é impactado significativamente pela presença de massas em desbalanços. Logo, três variáveis de entrada serão extraídas do movimento orbital na aceleração de 0 a 250 RPM: o valor do maior deslocamento; a integral da curva, que tem como objetivo quantificar o número de oscilações do conjunto; e por final o desvio padrão da curva, o qual visa traduzir a distribuição das vibrações.

3.2.3 Parâmetros de Saída

As saídas de um RNA são as respostas que a rede produz após processar as entradas. Logo, no presente projeto as saídas são as características que queremos modelar:

1. Quantidade de massa (valor em Kg) de borracha em mantas balanceadas .
2. Quantidade de massa (valor em Kg) de borracha desbalanceada em cargas pontuais.
3. Altura da massa desbalanceadas de borracha (valor em Cm) em relação a base do cesto de roupas.

3.2.4 Plano de coleta de dados

Para modelar um sistema com uma RNA, o primeiro passo é coletar dados que descrevam o comportamento do sistema em diferentes condições. Esses dados incluem informações de entradas e saídas do sistema.

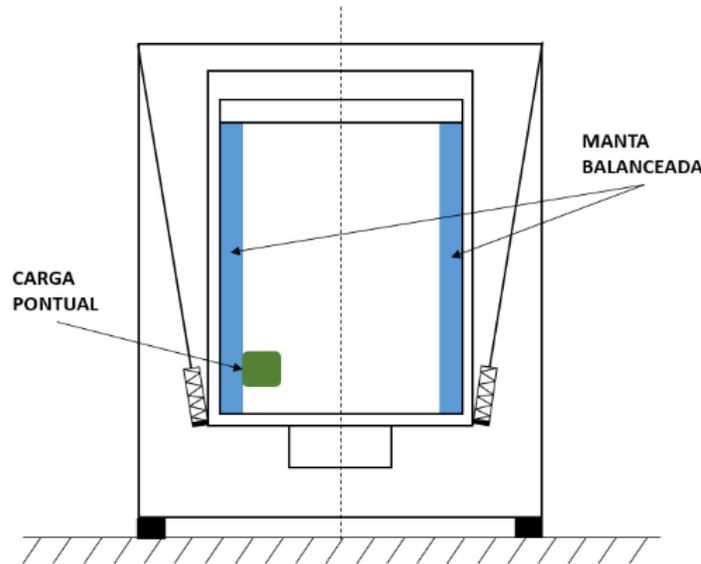
Como citado anteriormente, a simulação da composição de roupas após o processo de lavagem é feito por meio de cargas de borracha (mantas balanceadas e cargas pontuais) em diversas configurações. A Figura 21 demonstra como as cargas de borracha podem ser combinadas em uma lavadora de roupas.

A mantas balanceadas são compostas por tiras de borracha que preenchem todo a lateral do cesto, de forma a simular a inércia da quantidade de massa de tecidos média em cada nível de água (o qual normalmente tem quatro configurações: Extra Baixo, Baixo, Médio e Alto).

Para determinar a massa de uma manta de borracha balanceada, é necessário primeiro estimar o momento de inércia do cesto da máquina de lavar roupa, considerando que este pode ser aproximado à geometria de um cilindro maciço. Com a quantidade desejada de roupas estipulada e assumindo que os tecidos estão distribuídos de forma homogênea e com densidade constante, o momento de inércia de um cilindro maciço em torno de seu eixo de simetria é calculado pela equação:

$$I_{tecido} = \frac{1}{2} \cdot m_{tecido} \cdot r_{cesto}^2 \quad (7)$$

Figura 21 – Representação de cargas de borracha para simular desbalanceamento



Fonte: o Autor

Onde I_{tecido} é o momento de inércia, m_{tecido} é a massa do cilindro (ou massa de tecidos) e r_{cesto} é o raio do cilindro (ou raio do cesto da lavadora de roupas).

Já a manta de borracha balanceada tem a geometria aproximada de um cilindro oco, tendo o momento de inércia calculado pela equação:

$$I_{borracha} = \frac{1}{2} \cdot m_{borracha} \cdot (R_{manta}^2 + r_{manta}^2) \quad (8)$$

Onde $I_{borracha}$ é o momento de inércia, $m_{borracha}$ é a massa da manta de borracha e R_{manta} é o raio externo do cilindro e r_{manta} é o raio interno do cilindro. De tal modo que a espessura da parede da manta de borracha é dada por $R_{manta} - r_{manta}$.

Logo, Para obter a massa de borracha, a Equação 7 é igualada à Equação 8 e a massa da manta de borracha é isolada. A Tabela 4 demonstrada as massas de borracha a serem utilizadas por meio da correlação de inércia descrita.

Tabela 4 – Cálculo de Correlação de Inércia

Nível de Carga Simulado	Massa de Roupa Molhada [Kg]	Momento de Inércia Z Cilindro Sólido [Kg.m ²]	Massa de Borracha - 1 cm de espessura [Kg]
1 - Extra Baixo	0	0.000	0.00
2 - Baixo	12	0.395	5.94
3 - Médio	20	0.658	9.90
4 - Alto	26	0.855	12.87

Fonte: Autor

As cargas pontuais são pequenas tiras de borracha que podem ser dispostas em diferentes alturas ao longo do eixo vertical. A massa e a altura dessas cargas têm uma influência significativa na intensidade e no modo de vibração do sistema.

Entretanto, diferentemente da manta balanceada, para qual a correlação de inércia oferece uma estimativa simples e razoável, no caso da carga pontual não é possível correlacionar facilmente o efeito dos tecidos desbalanceados com borracha. Como descrito anteriormente, a natureza aleatória da composição e disposição dos tecidos após o processo de lavagem configura uma situação complexa de ser correlacionada e até mesmo estimada.

Desta forma, aplica-se a carga pontual empregando massas com incrementos sequenciais de 500 g ao longo do eixo vertical completo (base, meio e topo do cesto de roupas) que afetam a intensidade e o modo de vibração do sistema. O acréscimo de massa ocorre a cada iteração até o ponto em que a massa desbalanceada impeça a lavadora de roupas de acelerar devido aos choques do cesto de roupas com o gabinete externo (chamado colapso dinâmico).

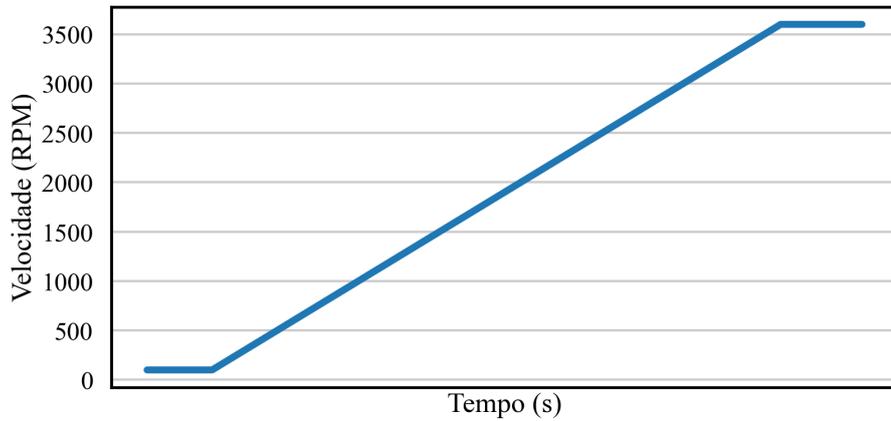
Capítulo 4

Resultados - Sistema de Visão Computacional

4.1 Experimento 1: Velocidade Angular e Configuração de Câmera

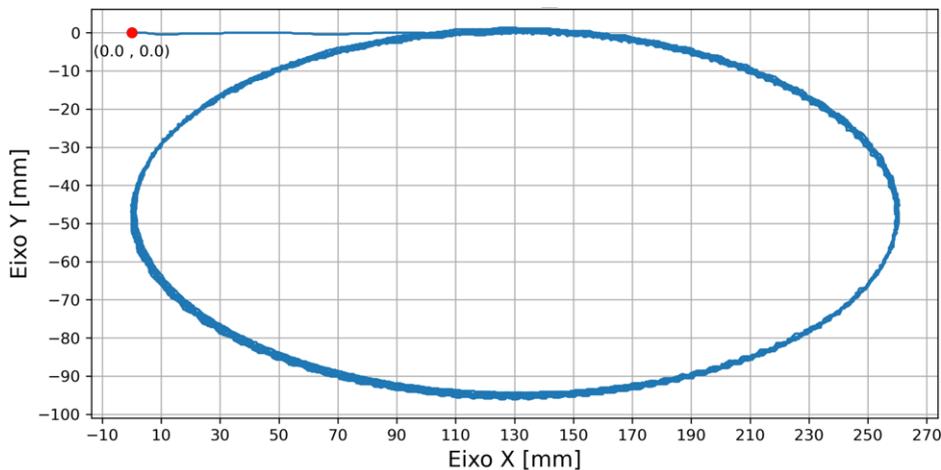
Como ponto de partida, é proposta uma trajetória elíptica de movimento contínuo enquanto o motor elétrico realiza uma rampa de aceleração, visto na Figura 22. Os esforços são concentrados na verificação da velocidade angular e o erro associado em relação ao valor referência (encoder óptico) para diferentes configurações de câmera. Sendo assim, a verificação da posição linear é limitada a inspeção visual da trajetória, como é demonstrada na Figura 23.

Figura 22 – Perfil de Velocidade do Motor para o estudo de velocidade angular



Fonte: o Autor

Figura 23 – Trajetória elíptica medida - Configuração 1

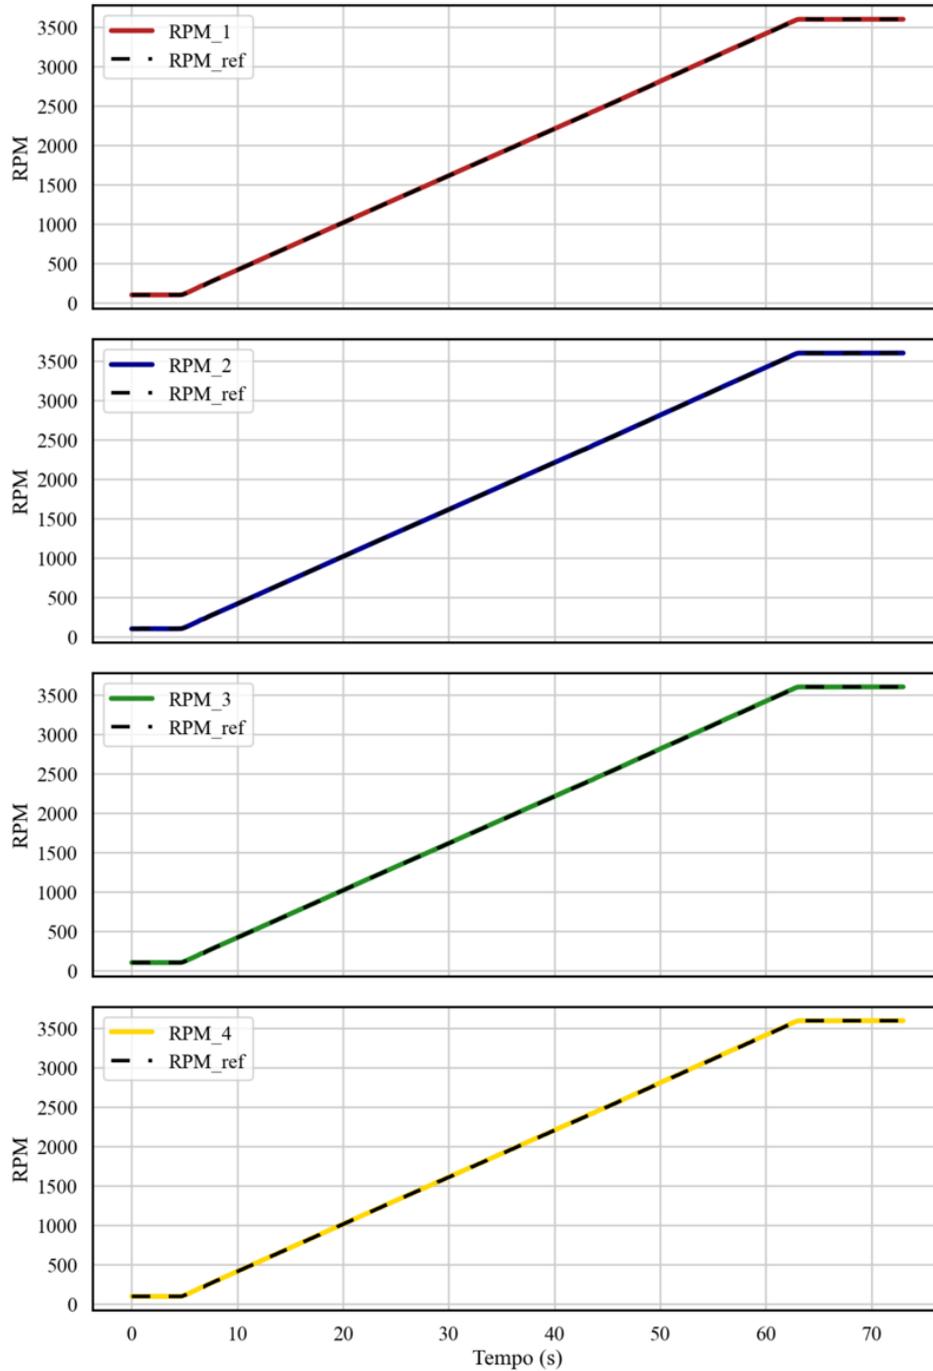


Fonte: o Autor

A classificação dos marcadores, mostrada anteriormente na Figura 10 permanece inalterada, enquanto na Tabela 1 da seção anterior são descritas as configurações de câmera e aceleração do motor a serem testadas. Por limitações de parametrização da câmera, no experimento atual a configuração de 60 FPS foi testada com o shutter de 1/960s, enquanto para 120s, o shutter foi de 1/1920s.

A Figura 24 utiliza como exemplo a configuração 3 para ilustrar os dados obtidos, na qual são vistas as medições de cada marcador individualmente em comparação com o velocidade rotacional referência.

Figura 24 – Experimento 1 - Resultados de velocidade da Configuração 3



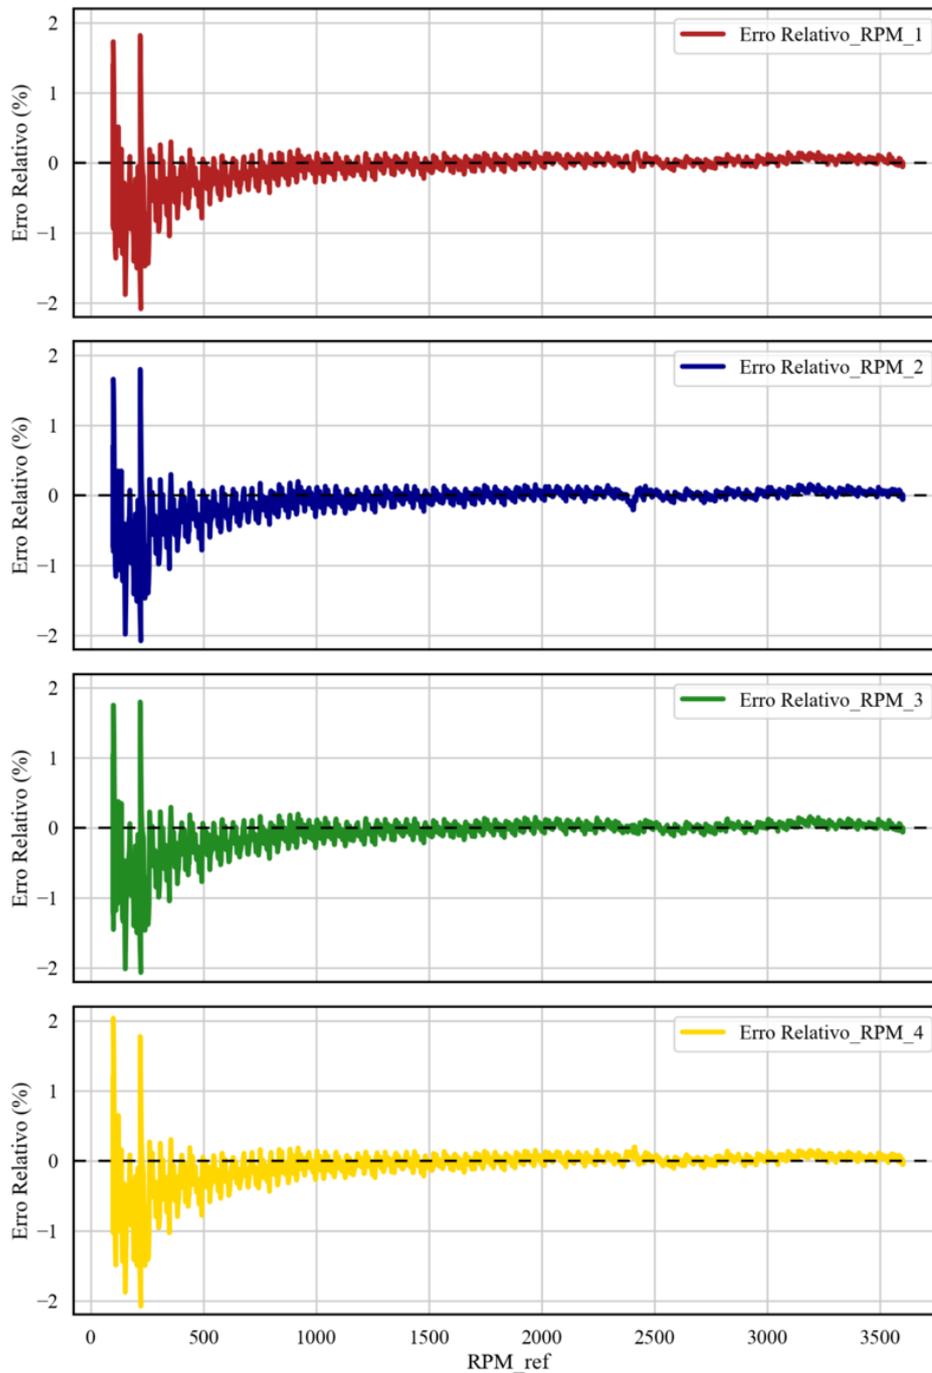
Fonte: o Autor

A acuracidade é verificada através do cálculo do erro relativo, o qual é expresso como a diferença entre o valor medido e o valor de referência, dividido pelo valor de referência, representado em forma percentual como demonstrado pela Equação 9:

$$Erro_{Relativo} = \left(\frac{Velocidade_{Encoder} - Velocidade_{Marcador}}{Velocidade_{Encoder}} \right) \cdot 100\% \quad (9)$$

De forma análoga, a Figura 25 também utiliza a configuração 3 para exemplificar o valor calculado do erro relativo.

Figura 25 – Experimento 1- Erro Relativo da Configuração 3



Fonte: o Autor

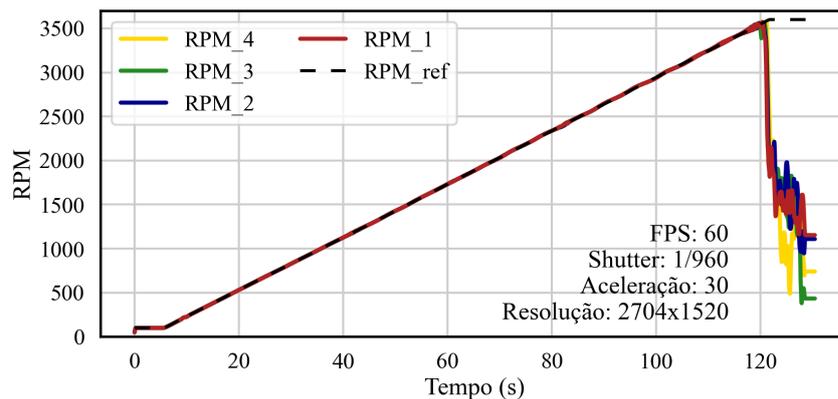
Os gráficos de comparação de velocidade angular e erro relativo de todas as 8 configurações estão disponíveis no Apêndice B. Sendo assim, as análises a seguir agrupam todos dos marcadores com o valor de referência a fim de permitir uma melhor comparação

entre as configurações testadas.

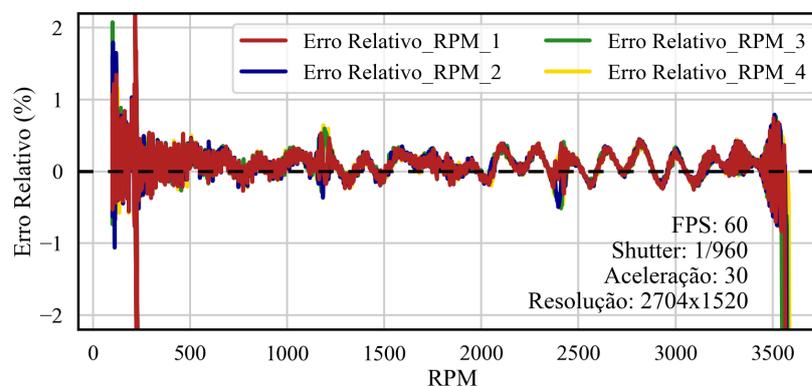
Em relação à comparação entre taxa de quadros e velocidade do obturador, as Figuras 26 e 27 demonstram, respectivamente, os resultados obtidos com configuração 1 e 4. Estas duas configurações possuem as mesmas configurações, exceto FPS e *shutter*. Ambos tratamentos mostraram uma boa acuracidade da leitura de velocidade, com a diferença de que a configuração 1 foi capaz de mensurar a velocidade até 3560 RPM, enquanto a configuração 4, até 3600 RPM (detalhe para um ruído observado na medida de velocidade do marcador verde em baixa velocidade).

Enquanto na avaliação do erro relativo, a configuração 1 apresentou valores entre ± 2 a $\pm 0.5\%$ com uma tendência decremental para faixa de 100 a 250 RPM, permanecendo em $\pm 0.5\%$ até velocidades abaixo de 3550 RPM. Já a configuração 4, o erro relativo para velocidades abaixo de 250 RPM permaneceu o mesmo, no entanto, para velocidades entre 250 e 700 RPM o erro foi reduzido para $\pm 0.4\%$, e para velocidades posteriores a esta o erro foi igual ou menor a $\pm 0.2\%$.

Figura 26 – Experimento 1 - Configuração 1



(a) Medições de Velocidade dos Marcadores e Encoder

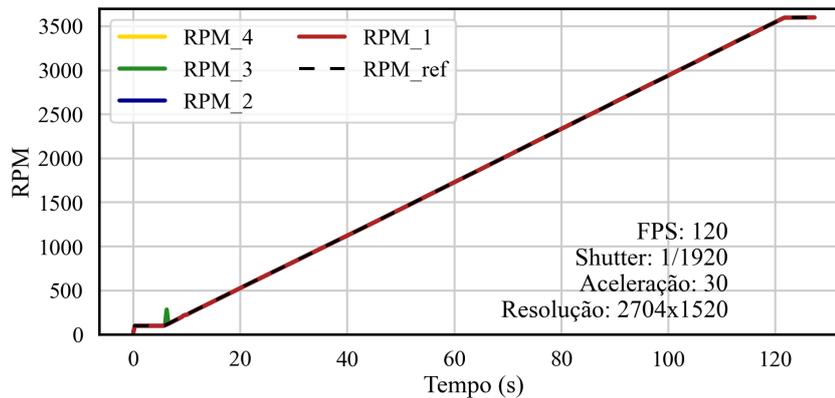


(b) Erro Percentual de Velocidade

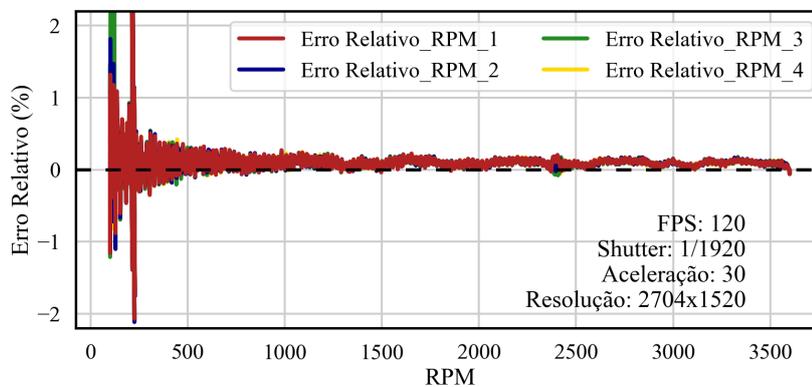
Fonte: o Autor

De forma análoga às configurações 1 e 4, as configurações 2 e 3 (que diferem do primeiro par apenas no valor de aceleração, 60 ao invés de 30 RPM/s) apresentaram resultados

Figura 27 – Experimento 1 - Configuração 4



(a) Medições de Velocidade dos Marcadores e Encoder



(b) Erro Percentual de Velocidade

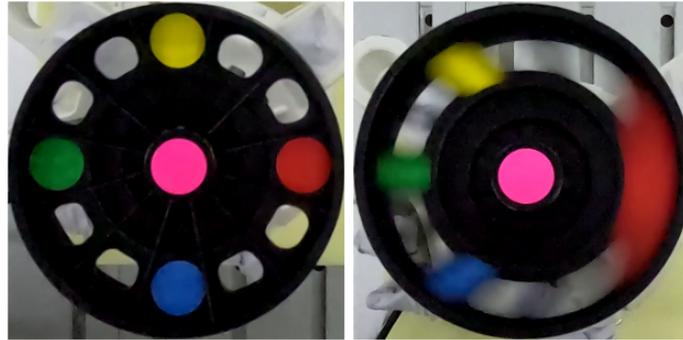
Fonte: o Autor

semelhantes. Sendo assim, é possível concluir que a melhoria na precisão e redução do erro relativo é atribuída a combinação de um shutter de 1/1920s e taxa de amostragem de 120 FPS.

Um ponto relevante observado é a distorção geométrica que ocorre nas imagens em alta velocidade. A Figura 28 mostra comparação entre um vídeo da configuração 1 (60 FPS) com um quadro a 100 RPM e outro a 3600 RPM (momento em que o método proposto não foi capaz de mensurar a velocidade rotacional). Tal efeito é atribuído ao ajuste do obturador (*shutter*), discutido por André et al. (2021), o qual realiza um estudo de variação angular utilizando uma câmera de aparelho celular.

De acordo com o critério de amostragem de *Nyquist*, a frequência de amostragem (taxa de quadros da câmera no atual contexto) deve ser pelo menos o dobro da frequência do sinal sendo amostrado para evitar o efeito de *aliasing* e capturar com precisão o sinal. No entanto, foi evidenciado no contexto experimental que o método proposto é capaz de fazer leituras de velocidade rotacionais em frequências de amostragem maiores que a metade da taxa de quadros ($fs/2$), aproximando-se da taxa de quadros (fs). Tal capacidade é alcançada quando a direção de rotação se mantém constante e é conhecida previamente,

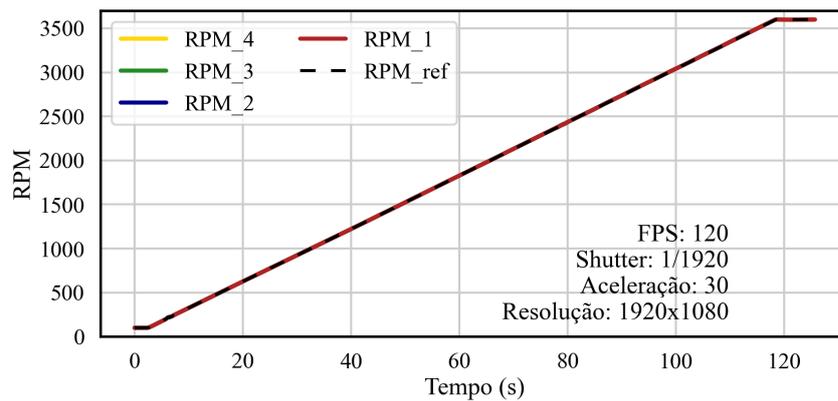
Figura 28 – Rotor a 100 RPM e 3600 RPM (60 fps)



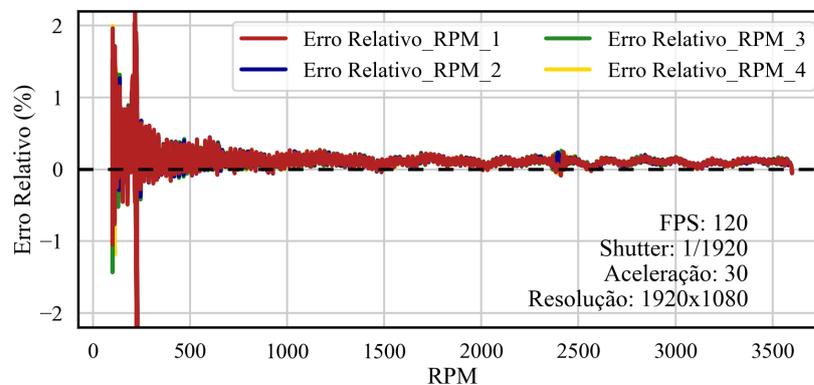
Fonte: o Autor

pois o método em questão não apenas quantifica as variações angulares, mas também incorpora a direção da rotação no cálculo da velocidade.

Figura 29 – Experimento 1 - Configuração 5



(a) Medições de Velocidade dos Marcadores e Encoder



(b) Erro Percentual de Velocidade

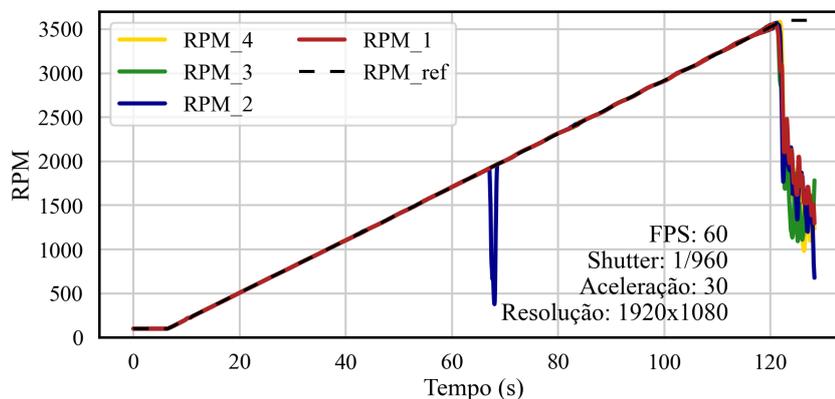
Fonte: o Autor

A seqüência da análise é baseada na resolução da câmera, a qual desempenha um papel

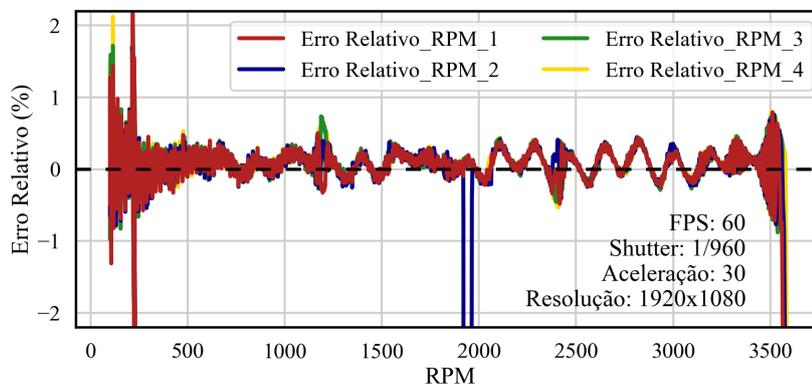
central na qualidade das medições obtidas. Resoluções mais elevadas oferecem imagens com um maior número de *pixels*, ou seja, mais informações a serem extraídas e analisadas.

Durante o estudo, observou-se que diferentes resoluções (1080p e 2700p) aparentemente têm um efeito pouco perceptível nos erros de medição. Isso pode ser explicado pela capacidade dos algoritmos de processamento de imagem e rastreamento em lidar com diferentes níveis de resolução. Fato este, demonstrado pela comparação entre as configurações mostradas nas Figuras 26 e 30, onde apenas a resolução é modificada. O mesmo se aplica às configurações vistas nas Figuras 27 e 29, fortalecendo esse ponto de vista.

Figura 30 – Experimento 1 - Configuração 7



(a) Medições de Velocidade dos Marcadores e Encoder



(b) Erro Percentual de Velocidade

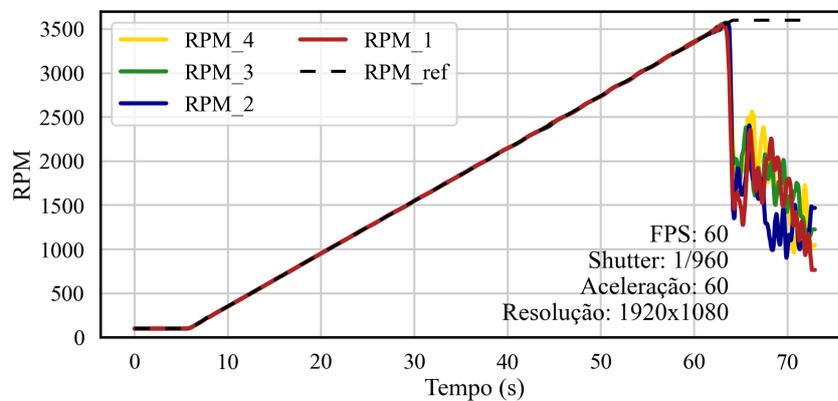
Fonte: o Autor

Logo, é possível concluir que embora as imagens de alta resolução tragam vantagens em termos de detalhes, a resolução não se mostrou significativa para o erro das medições durante a análise dos dados do experimento. Porém é preciso considerar a interação entre a resolução e a distância entre os objetos a serem rastreados. Enquanto a capacidade dos algoritmos de processamento de imagem pode compensar variações de resolução em curtas distâncias sem efeito prático, em cenários em que a separação entre os objetos é maior, resoluções mais baixas podem dificultar a detecção precisa e a medição de movimentos sutis.

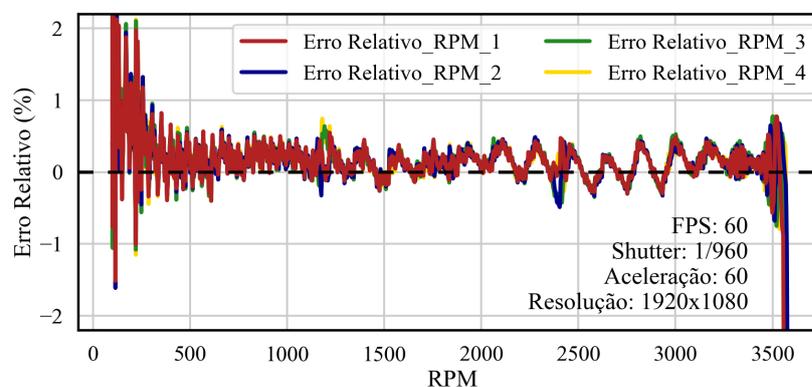
No ensaio da Figura 30 (assim como ocorreu no ensaio da Figura 27), houve um erro abrupto na leitura de um dos marcadores. Tal efeito ocorre pela perda momentânea do rastreamento de um dos marcadores, no entanto, é visto que a perda de um dos sinais não afeta os demais, o que justifica o uso de múltiplos marcadores de cores distintas para aumentar a robustez do sistema.

O último fator avaliado no Experimento 1 foi o efeito de diferentes taxas de aceleração rotacional (30 RPM/s e 60 RPM/s) durante a rampa de velocidade para testar como o sistema de medição responde a tais variações. Foi observado um incremento pouco significativo do erro relativo nas configurações que utilizam a amostragem de 60 FPS à medida que a aceleração aumentou de 30 para 60 RPM/s, como é evidenciado pelas Figuras 30 e 31. De forma análoga, o mesmo efeito foi constatado nas configurações realizadas com 120 FPS, experimento que pode ser visto na comparação entre as Figuras 29 e 32.

Figura 31 – Experimento 1 - Configuração 8



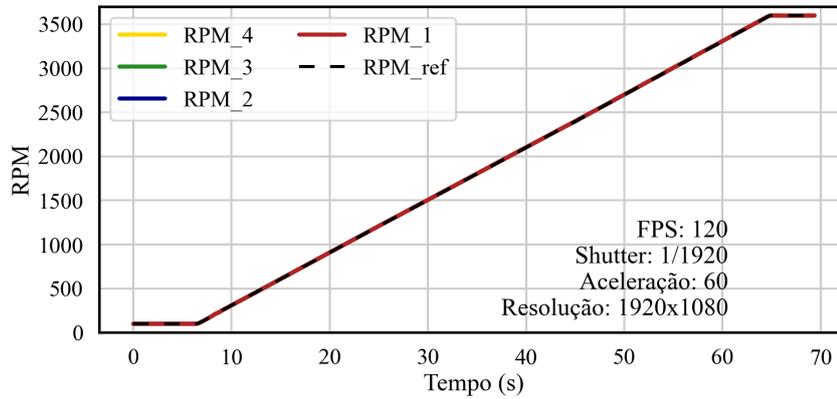
(a) Medições de Velocidade dos Marcadores e Encoder



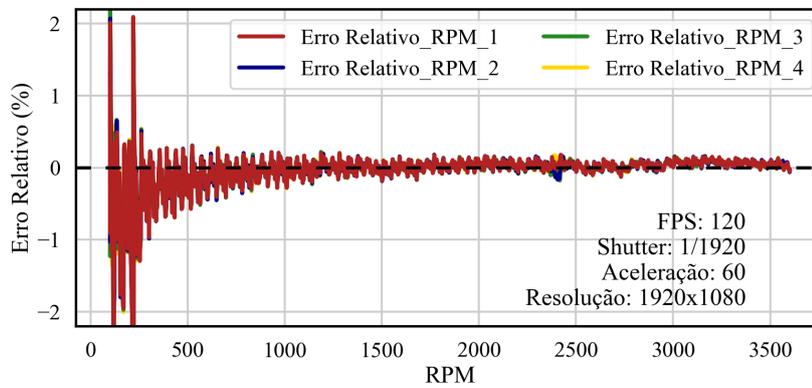
(b) Erro Percentual de Velocidade

Fonte: o Autor

Figura 32 – Experimento 1 - Configuração 6



(a) Medições de Velocidade dos Marcadores e Encoder



(b) Erro Percentual de Velocidade

Fonte: o Autor

4.2 Experimento 2: Posição Linear

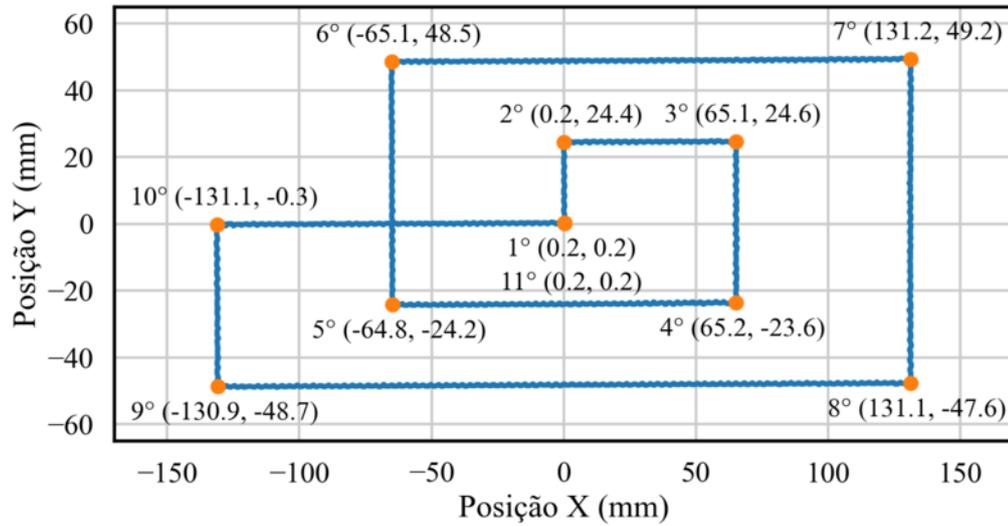
Diferente do experimento anterior, o foco do Experimento 2 está na análise da capacidade em medir a posição espacial (cartesiana) dos marcadores. Para as avaliações relacionadas à posição, o rotor do sistema permaneceu estacionário em pontos específicos (Figura 18) por um período específico durante as medições, o qual a minimiza possíveis oscilações ou instabilidades no sistema de medição devido ao movimento do equipamento.

A acuracidade é verificada por meio do erro de cada estimativa, o qual é definido como a subtração entre o valor referência e o valor medido, mostrado na Equação 10.

$$Erro_{(x,y)} = (x_{referência} - x_{medido}, y_{referência} - y_{medido}) \quad (10)$$

Na Figura 33 são mostrados os dados das coordenadas (X, Y) obtidos do vídeo da Configuração 3. Os pontos destacados em vermelho foram medidos para serem comparados a trajetória previamente programada na máquina CNC. Os gráficos de todas as configurações estão disponíveis no Apêndice A. A partir dos cálculos de erro para cada

Figura 33 – Deslocamento no Plano XY - Configuração 1

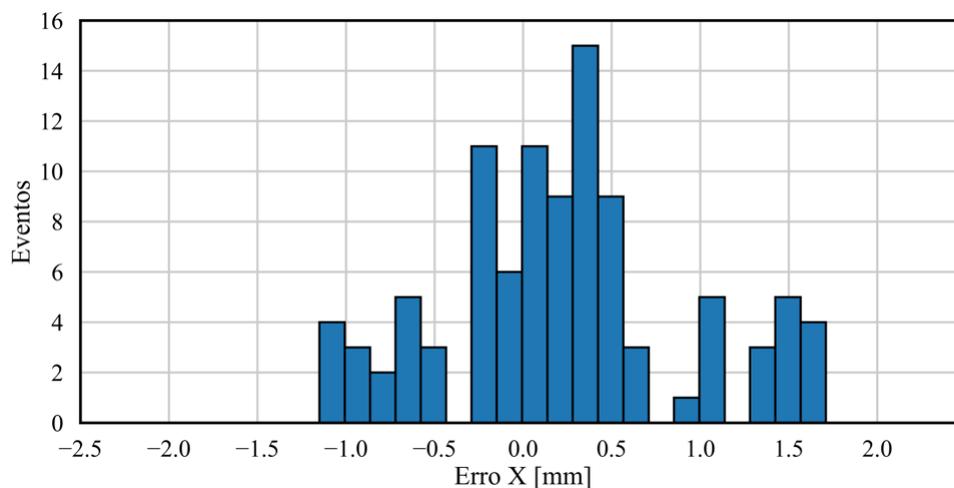


Fonte: o Autor

um dos 11 pontos de cada configuração de teste, é possível verificar o desempenho do mesmo para medições de deslocamento bidimensional. Os resultados são evidenciados nos histogramas com as distribuições dos erros para os eixos X na Figura 34 e Y na Figura 35.

Os valores médios de erro e desvio padrão no eixo X foram, respectivamente, 0,22 e 0,69 mm.

Figura 34 – Distribuição do Erro em X

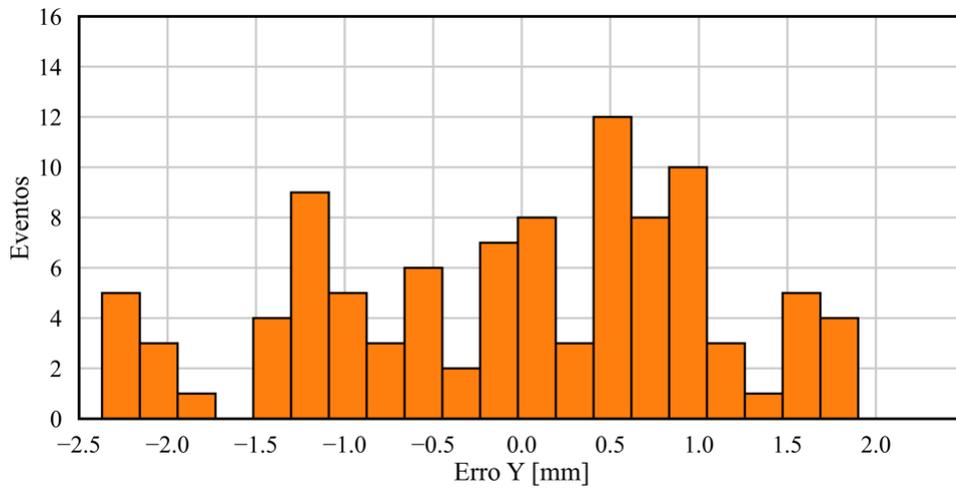


Fonte: o Autor

Os valores médios de erro e desvio padrão no eixo Y foram, respectivamente, -0,05 e

1.09 mm.

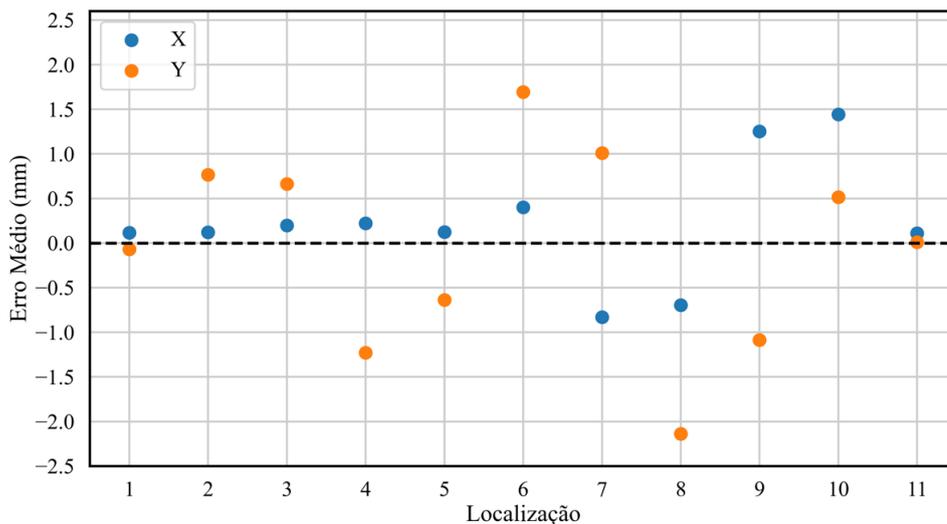
Figura 35 – Distribuição do Erro em Y



Fonte: o Autor

A partir do cálculo do erro médio para cada um dos pontos de referência, é possível constatar que existe uma correlação entre do erro médio e a distância do ponto de referência em relação ao centro da imagem. Tal fenômeno existe em ambas coordenadas, porém é mais acentuado na coordenada Y , como é visto na Figura 36.

Figura 36 – Erro Médio por Ponto de Referência



Fonte: o Autor

Embora a câmera de vídeo tenha sido configurada para capturar imagens com lente linear (lentes ópticas *fish-eye*, compensadas digitalmente) os resultados mostrados anteriormente sugerem que existe uma pequena distorção, mais significativa no eixo Y . Como

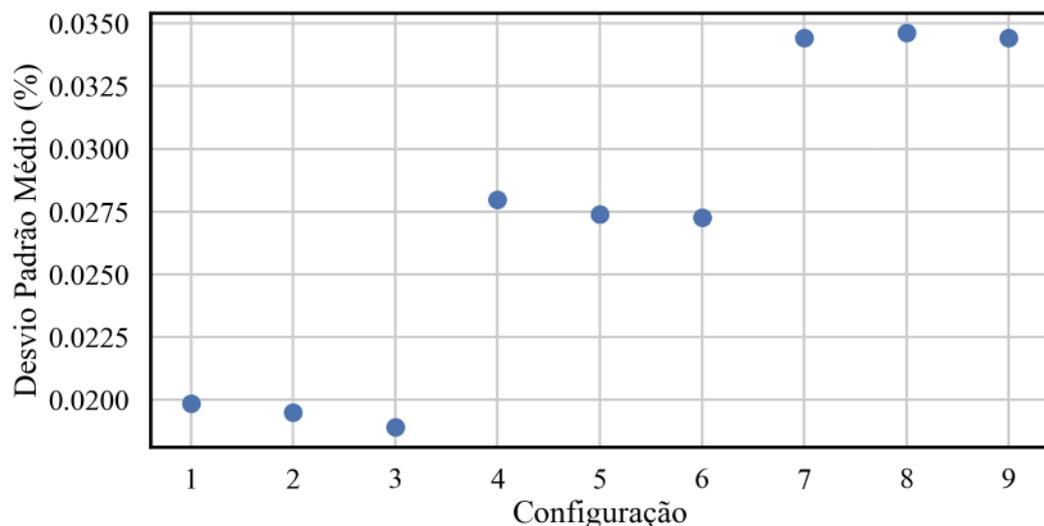
detalhado por Szeliski (2010b), há uma variedade de técnicas que podem ser usadas para estimar e corrigir a distorção causada pelas lentes. Para o presente trabalho, foi decidido seguir com o método atual de estimativa de posição e deixar a implementação de calibração da lentes como sugestão para trabalhos futuros.

Na análise dos resultados relacionados à medição da velocidade de rotação, foi encontrada uma variação de cerca de $\pm 0.015\%$ nos momentos estacionários de todas as configurações, ou seja, quando o equipamento ficou parado em um dos 11 pontos de referência. Um cenário distinto ocorreu durante as aferições de velocidade de rotação no momento em que a CNC se deslocava entre dois pontos de referência.

Foi observado que o valor do erro se alterou de acordo com as mudanças na velocidade translacional do eixo *Y*; à medida que o objeto rotor se move no eixo para sentidos positivos ou negativos verticalmente em relação ao vídeo, o valor de erro tende a valores negativos ou positivos respectivamente, como pode ser observado na Figura 38 onde são mostradas as configurações 2, 5 e 8 sequencialmente. Tal fenômeno não ocorre em movimentos laterais.

O aumento dos erros relativos do rotor dinâmico em relação ao estático foram de $\pm 0.06\%$ para 2500 mm/min (Figura 38a), $\pm 0.12\%$ para 5000 mm/min (Figura 38b) e $\pm 0.24\%$ para 10000 mm/min (Figura 38c). Ou seja, uma correlação de aumento linear e constante entre o erro relativo da velocidade rotacional e a velocidade translacional em *Y*, que também é evidenciada na Figura 37 por meio dos valores médios do desvio padrão de cada configuração do Experimento 2.

Figura 37 – Desvio padrão médio do Experimento 2

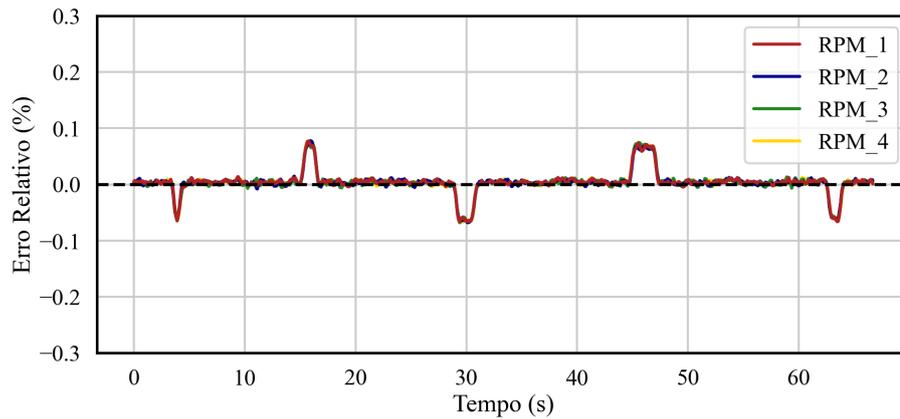


Fonte: o Autor

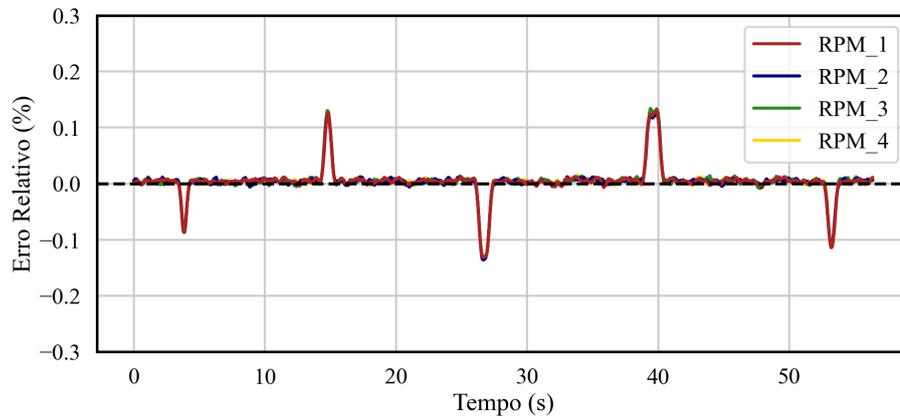
A teoria por trás desse fenômeno é a natureza física do obturador da câmera e como a imagem é processada. Dentro do intervalo de tempo entre o início e fim do processa-

mento da imagem enquanto o obturador está aberto, os marcadores se movem em um grau específico, e este deslocamento faz com que a posição deles não seja uma posição instantânea e estática. A comprovação de tal teoria é tema para futuros estudos, uma vez que necessita de estudos focados nesse fenômeno.

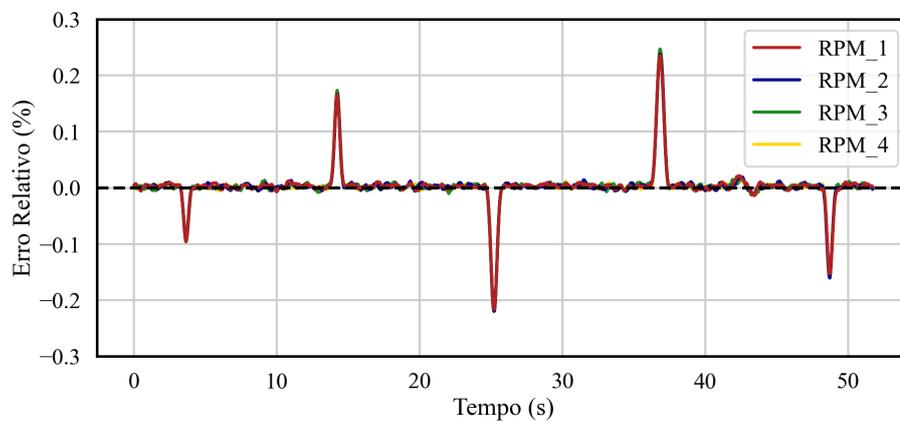
Figura 38 – Erros relativos do Experimento 2.



(a) Experimento 2 - Configuração 2



(b) Experimento 2 - Configuração 5



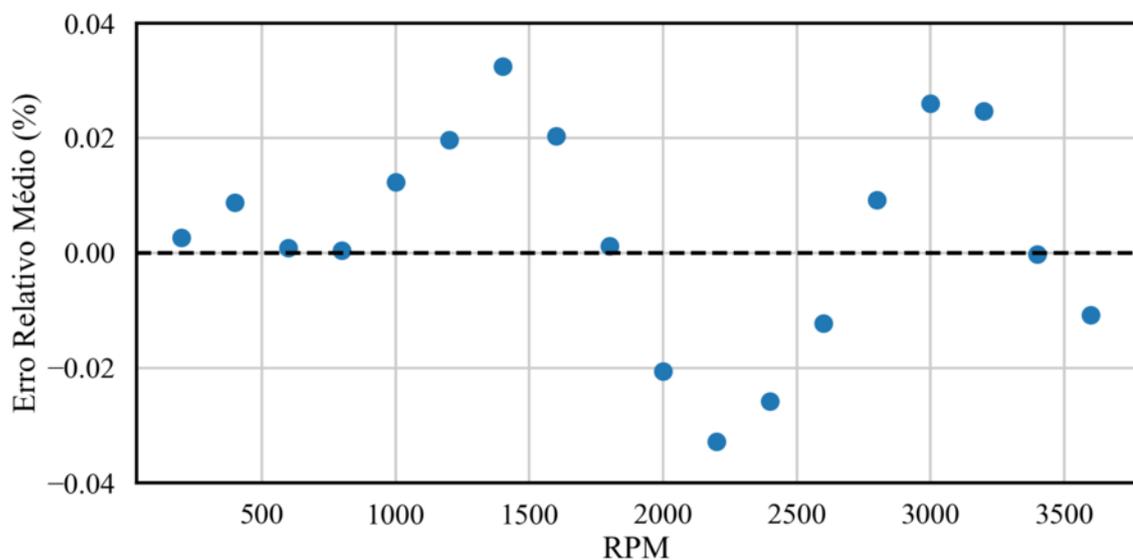
(c) Experimento 2 - Configuração 8

Fonte: o Autor

4.3 Experimento 3: Estabilidade e Consistência

Como o foco de avaliar a habilidade do sistema em manter precisão e estabilidade em situações que envolvem velocidade constantes em diferentes faixas sem movimento translacional, o Experimento 3 finaliza a série de avaliações sobre o método proposto. A Figura 39 demonstra o desvio padrão médio em cada das velocidades rotacionais avaliadas. É possível verificar um comportamento sistemático, semelhante a uma onda, à medida que a velocidade rotacional muda.

Figura 39 – Erro relativo por rotação.



Fonte: o Autor

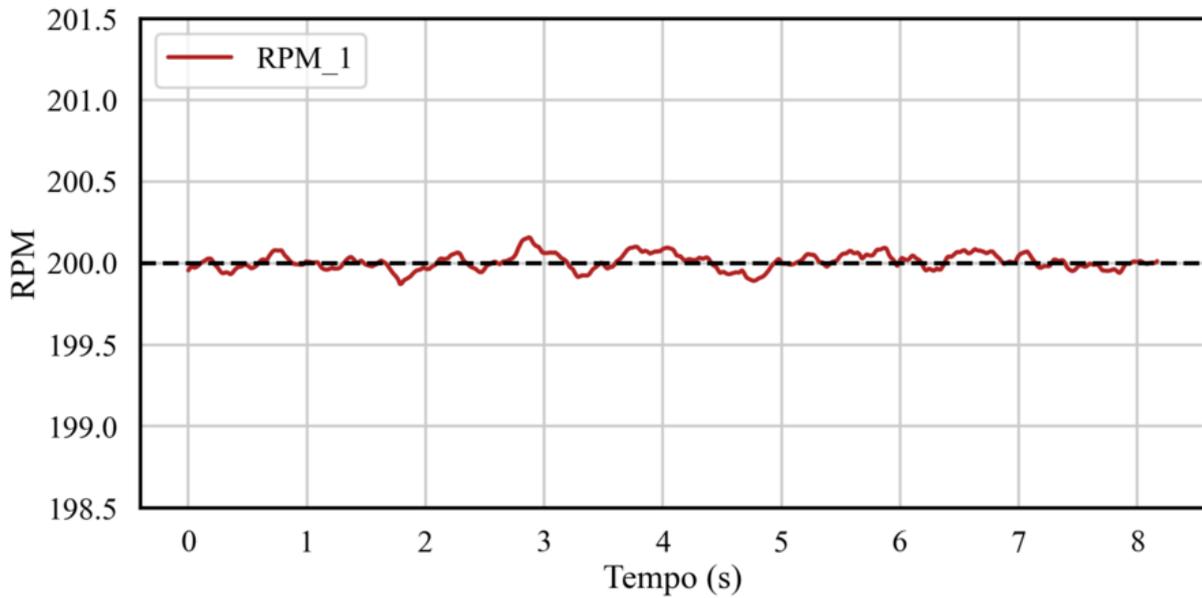
A observação destacada nos resultados é que em velocidades rotacionais específicas, como 200 RPM (Figura 40a) e 1800 RPM (Figura 40b), os erros relativos se assemelham e tendem a ser insignificantes (0,0004%).

No entanto, nos picos inversamente proporcionais de erro, a 1400 RPM (Figura 41a) e 2200 RPM (Figura 41b), os maiores valores de erro em regime estacionário (0,035%) são observados.

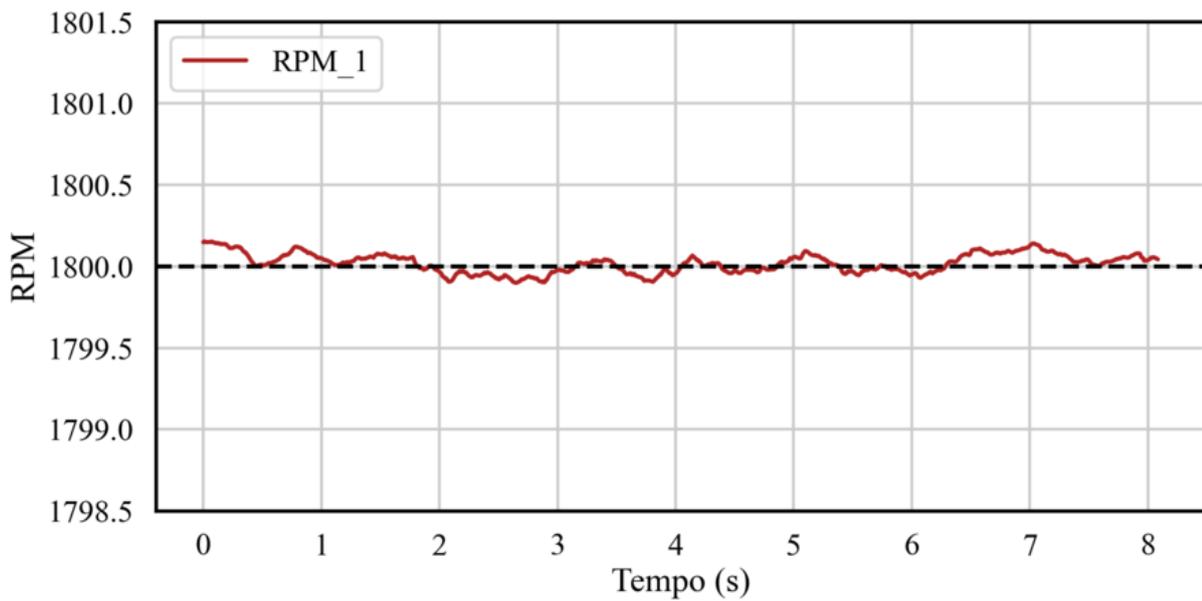
Ao prosseguir na avaliação do sistema de medição de velocidade angular em variados regimes de rotação, uma análise do desvio padrão foi realizada para compreender a estabilidade das medições obtidas, exibido na Figura 42. Os desvios padrão obtidos permaneceram consistentemente abaixo de 0,02% para a maioria das faixas de RPM investigadas, refletindo uma boa coerência nas medições em diferentes velocidades de rotação.

Porém um comportamento atípico foi identificado em relação a 2400 RPM. Nesse ponto específico, o desvio padrão se destacou, excedendo o padrão observado nas demais velocidades, estando em 0,1%. A Figura 43 demonstra em detalhe comportamento da

Figura 40 – Velocidades rotacionais por tempo



(a) Velocidade de 200 RPM

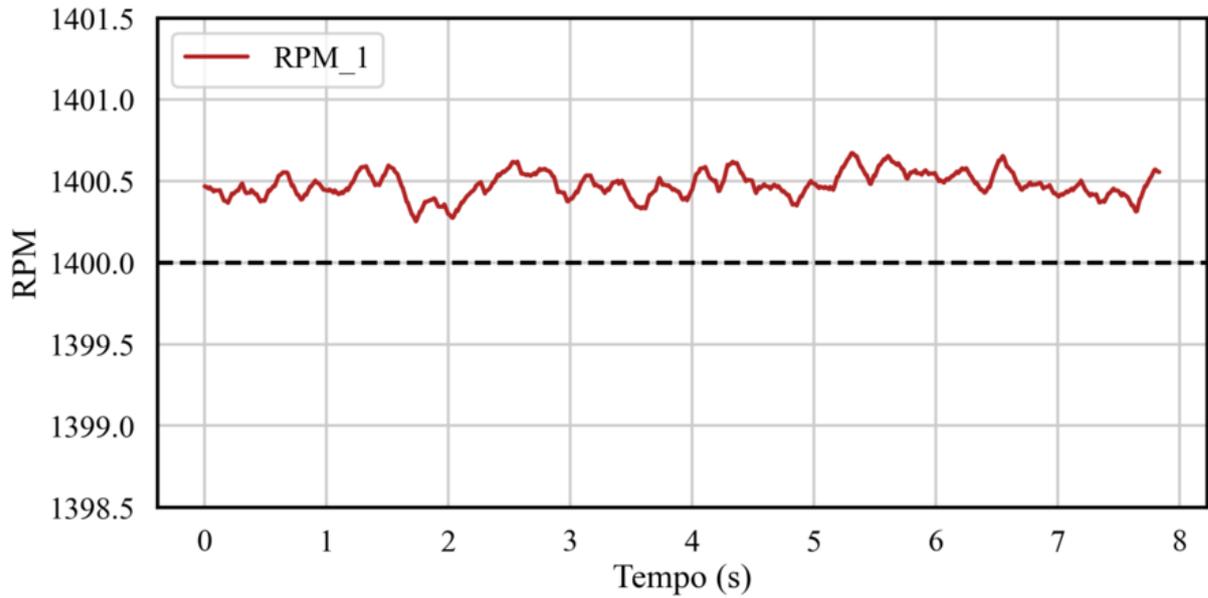


(b) Velocidade de 1800 RPM

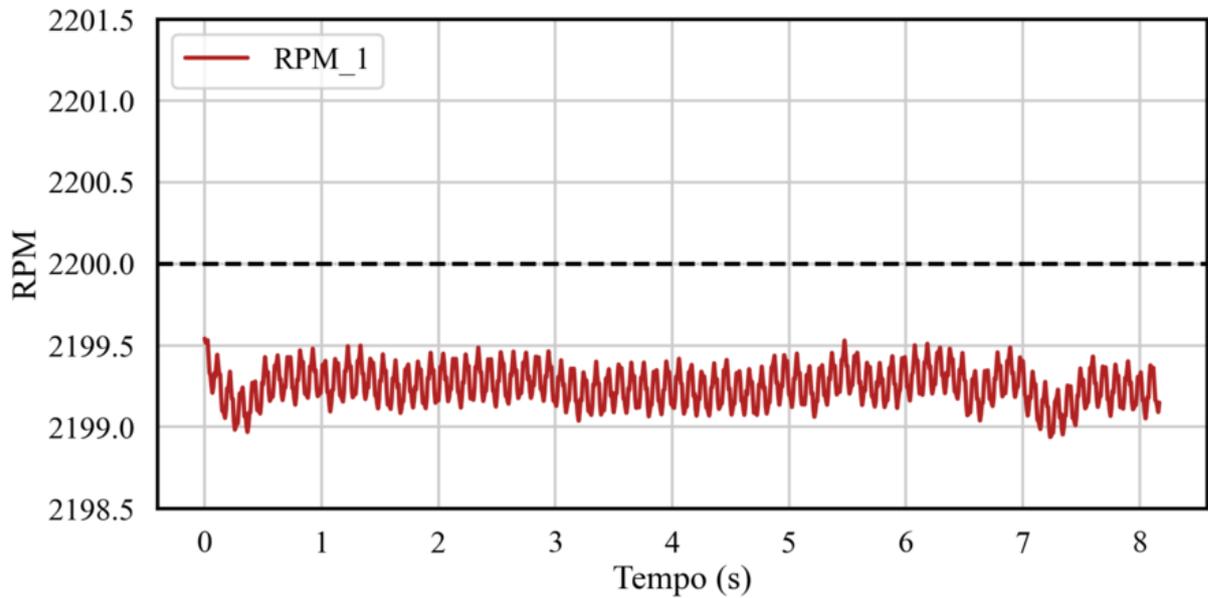
Fonte: o Autor

velocidade, é possível observar que o erro de velocidade apresenta um comportamento sistemático próximo de uma senoidal com período de cerca de 8.6 segundos.

Figura 41 – Velocidades rotacionais por tempo



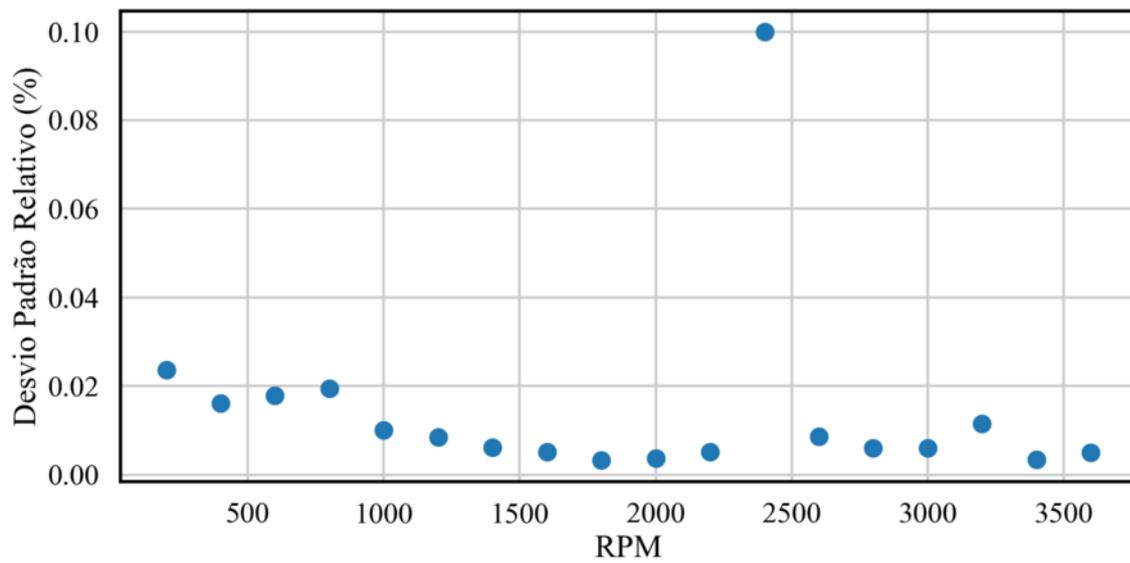
(a) Velocidade de 1400 RPM



(b) Velocidade de 2200 RPM

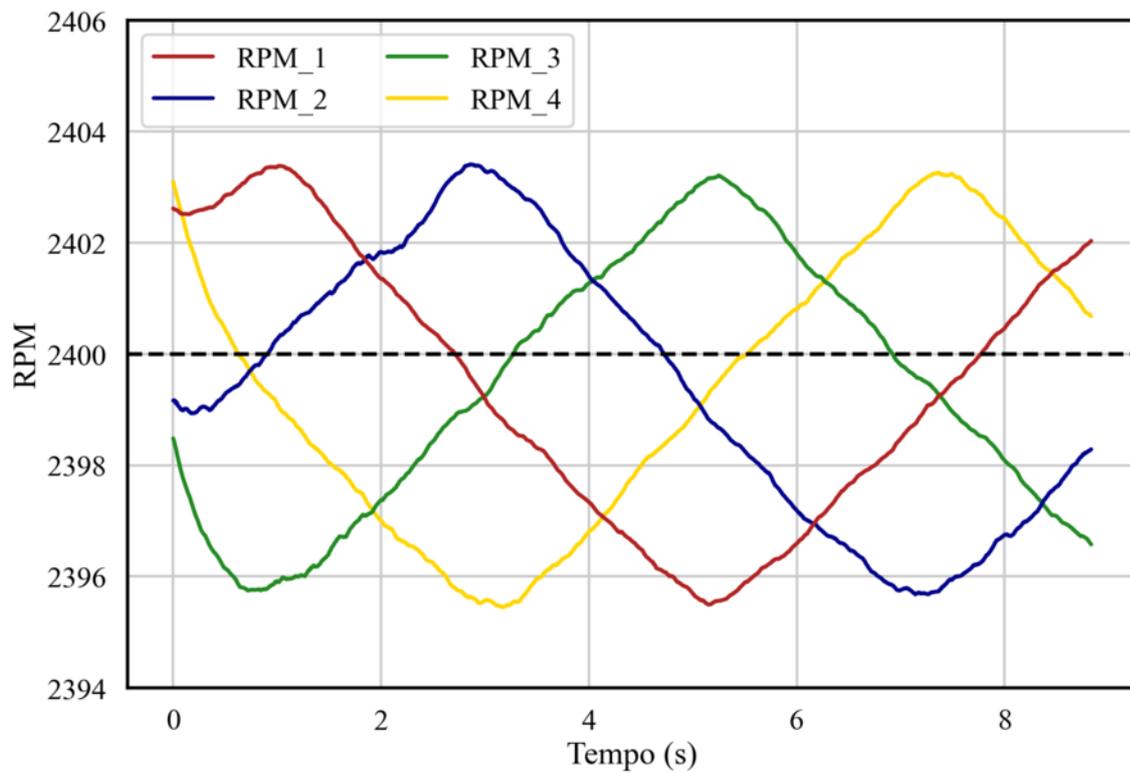
Fonte: o Autor

Figura 42 – Desvio padrão relativo médio por RPM.



Fonte: o Autor

Figura 43 – Velocidades rotacionais de 2400 RPM por tempo.



Fonte: o Autor

Capítulo 5

Resultados - Modelagem de Cargas Desbalanceadas

5.1 Plano e Coleta de Dados

Após validar o conceito do sistema de medição baseado em vídeo, este é empregado no experimento final que consiste em simular situações de massas em desbalanço a fim de extrair informações dinâmicas da lavadora de roupas.

5.1.1 Cabine de Filmagem

A fim de padronizar a configuração de filmagem e iluminação, foi desenvolvida uma cabine para realização das gravações, apresentada na Figura 44. Composta por uma estrutura de alumínio revestida com tecido branco em seu interior, isola o teste do ambiente externo.

A câmera *GoPro HERO 10* fica fixada no topo, de modo a capturar vídeos paralelamente a lavadora de roupas. A câmera é operada por meio de um aplicativo conectado por *bluetooth* a um aparelho celular.

Um sistema de iluminação com quatro lâmpadas LED de 15W fica posicionado acima da câmera, e por meio de um tecido translúcido homogeniza a iluminação, conforme visto na Figura 45.

A lavadora de roupas é posicionada dentro da cabine por meio de uma abertura frontal, a qual pode ser fechada de forma fácil por meio de velcros fixados nas extremidades. As marcações no piso da cabine garantem a padronização da posição inicial da lavadora de roupas em cada vídeo.

Figura 44 – Cabine de Filmagem



Fonte: o Autor

Figura 45 – Sistema de Iluminação

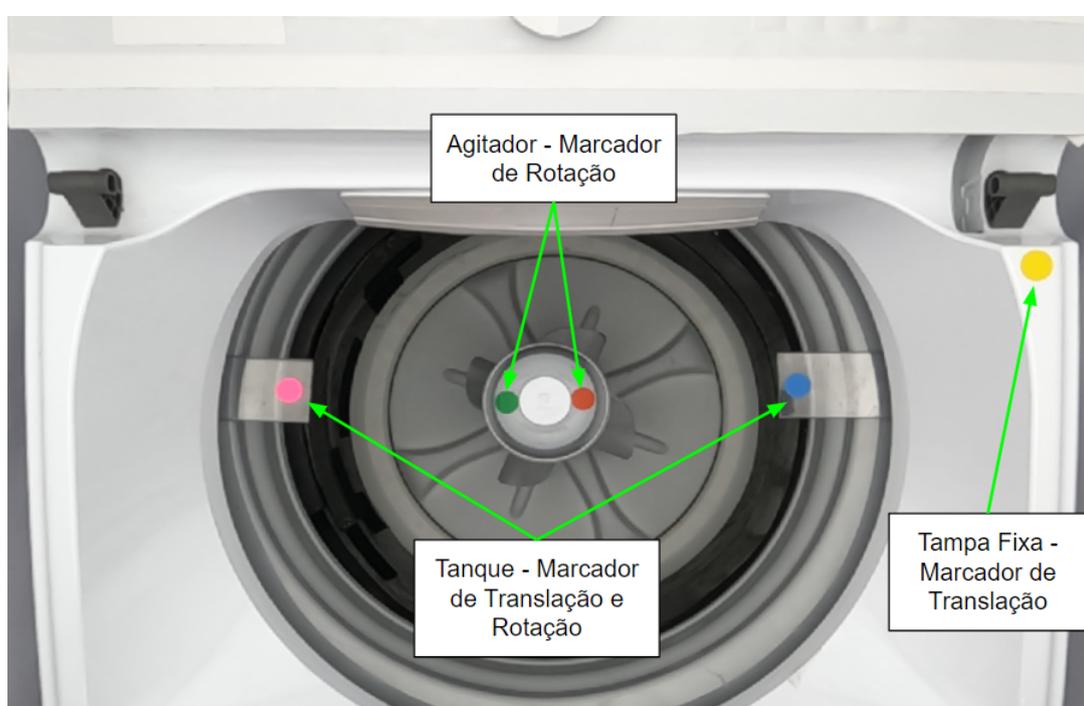


Fonte: o Autor

5.1.2 Configuração dos Marcadores

Os marcadores centrais, posicionados no topo do agitador de roupas, têm a função de capturar o sentido de rotação e velocidade angular durante a etapa de centrifugação. Já os marcadores cor de rosa e azul estão fixados no anel do tanque, além de indicar o movimento de translação (órbita elíptica) também fornecem informação sobre a torção (rotação) do conjunto de massa suspensa. E finalmente o marcador amarelo está fixado na tampa fixa, o qual habilita o rastreamento do movimento de translação de toda a lavadora de roupas.

Figura 46 – Marcadores aplicados na lavadora de roupas



Fonte: o Autor

5.1.3 Aquisição de Dados

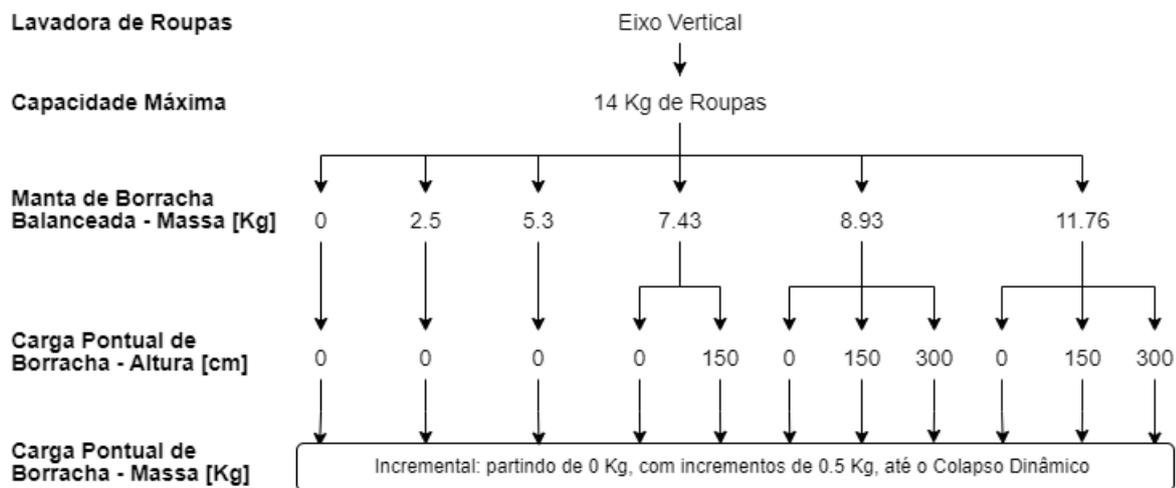
Através dos cálculos realizadas na seção de materiais e métodos, 4 valores de massas balanceadas foram determinados inicialmente. Posteriormente, devido as restrições impostas pela espessura e densidade da borracha e diâmetro do cesto, foi possível confeccionar 6 configurações de mantas balanceadas: 0, 2.5, 5.3, 7.43, 8.93 e 11.76 Kg.

Os níveis de manta de borracha 0, 2.5 e 5.3 Kg representam as cargas de tecidos extra-baixo e baixo, nos quais não há possibilidade de cargas pontuais desbalanceadas acima da base do cesto. Enquanto o nível que conta com 7.53 Kg já representa o nível de tecidos médios, preenchendo em média até o centro do cesto, cerca de 150 mm de altura. Já

os níveis que representam o nível o alto, 8.93 e 11.76 Kg, permitem a geração de cargas desbalanceadas ao longo de toda extensão do cesto (até 300 mm de altura).

Assim, a estratégia experimental utiliza mantas de borracha balanceadas que representam as diferentes capacidades da lavadoras de roupa enquanto a carga pontual de borracha é incrementada em diferentes alturas no cesto de roupas. A Figura 47 ilustra o plano de teste para a coleta de dados.

Figura 47 – Plano de coleta de dados



Fonte: o Autor

No total foram executadas 168 aquisições de vídeo, sendo 56 configurações de cargas com 3 réplicas cada. A Tabela 6 localizada no Apêndice D mostra todos os dados coletados.

5.2 Rede Neural Artificial

A RNA é um sistema de aprendizado de máquina supervisionado, ou seja, que utiliza um conjunto de dados de treinamento com rótulos pré-definidos para realizar previsões ou classificações em novos conjuntos de dados. O processo começa com a alimentação do algoritmo com um conjunto de dados de treinamento que inclui tanto as variáveis de entrada quanto as saídas esperadas. Com base nesses dados, o algoritmo cria um modelo matemático que pode prever a saída correta para novos dados de entrada.

5.2.1 Extração das Variáveis de Entrada

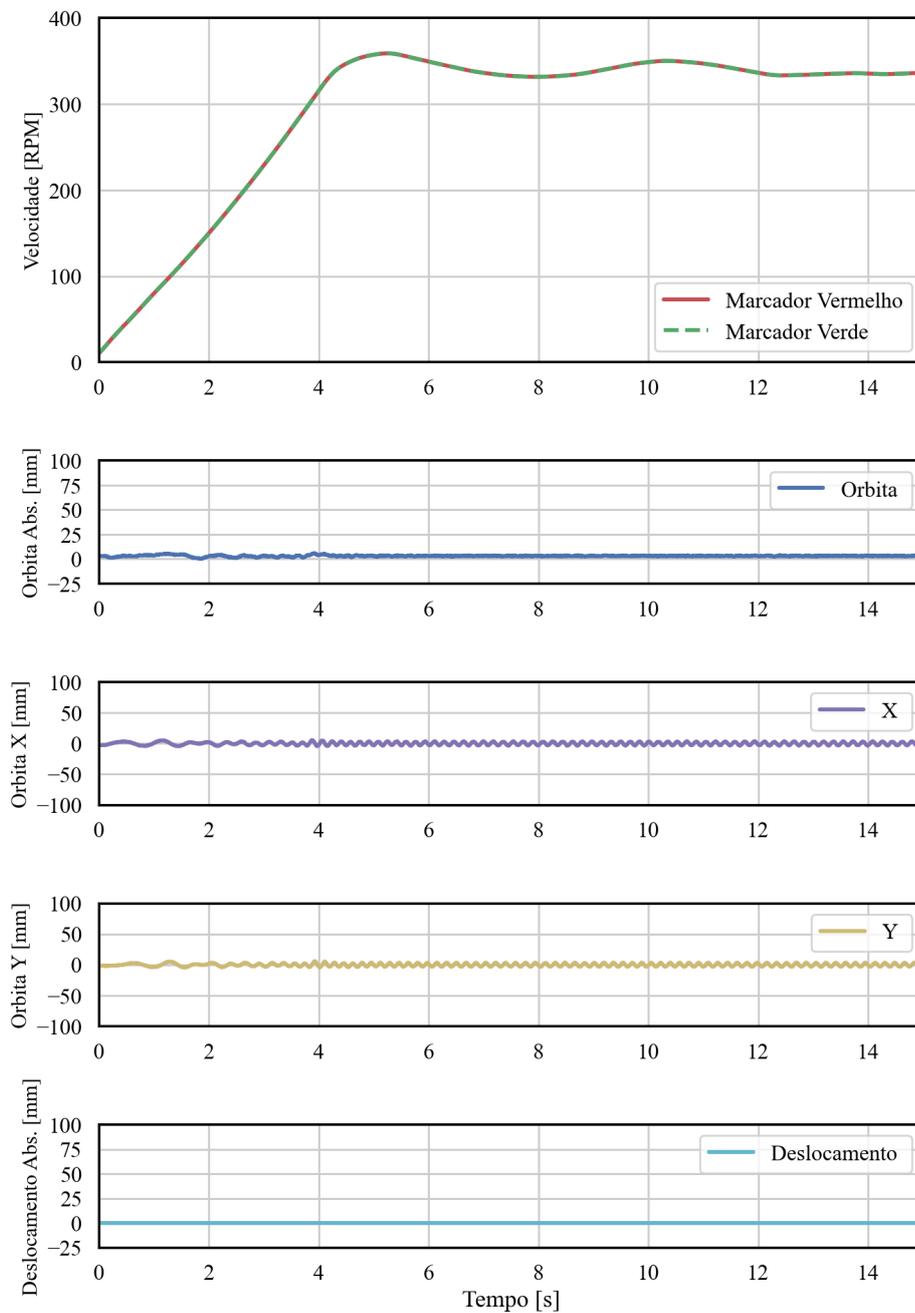
Como discutido anteriormente, as variáveis de entrada têm um papel crucial na efetividade da RNA em descrever o fenômeno desejado. Na subseção 3.2.2 foram descritas as

características críticas dos dados coletados.

Além do algoritmo de cálculo de velocidade mencionado anteriormente, foram incorporadas novas funções específicas durante a etapa de processamento de imagens para extrair as variáveis que servirão como entradas para a RNA.

Na Figura 48 é observado um caso em que a lavadora de roupas encontra-se totalmente vazia, situação de maior equilíbrio dinâmico. Não há deslocamento do produto, enquanto a órbita se mantém estável apenas com mínimas perturbações.

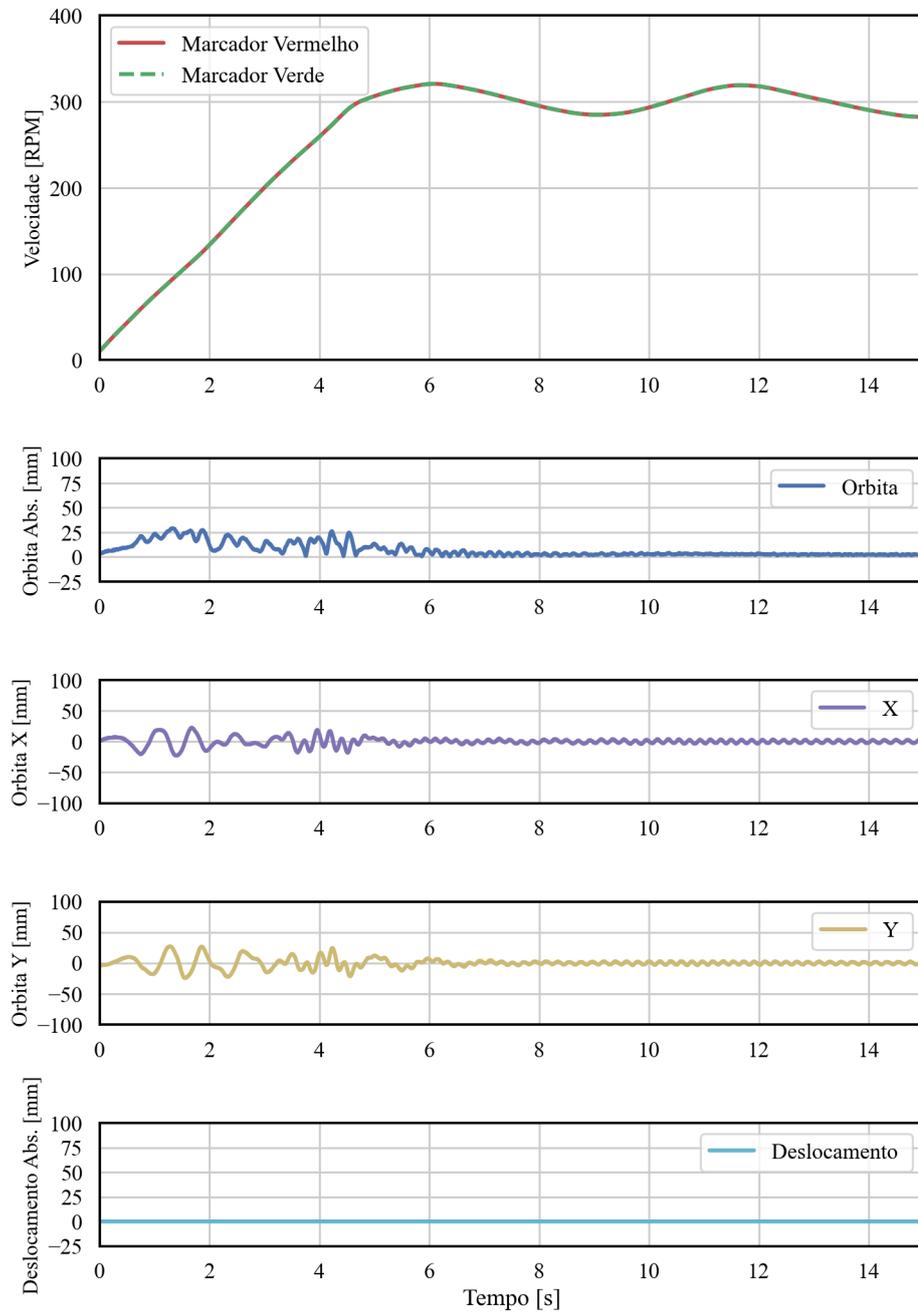
Figura 48 – 0 kg de Manta Balanceada e 0 kg de Carga Desbalanceada



Fonte: o Autor

No entanto, quando adicionamos 1 kg de massa em desbalanço à parte inferior do cesto, notamos uma maior oscilação, enquanto o tempo de aceleração e o deslocamento absoluto permanecem semelhantes ao caso anterior(Figura 48).

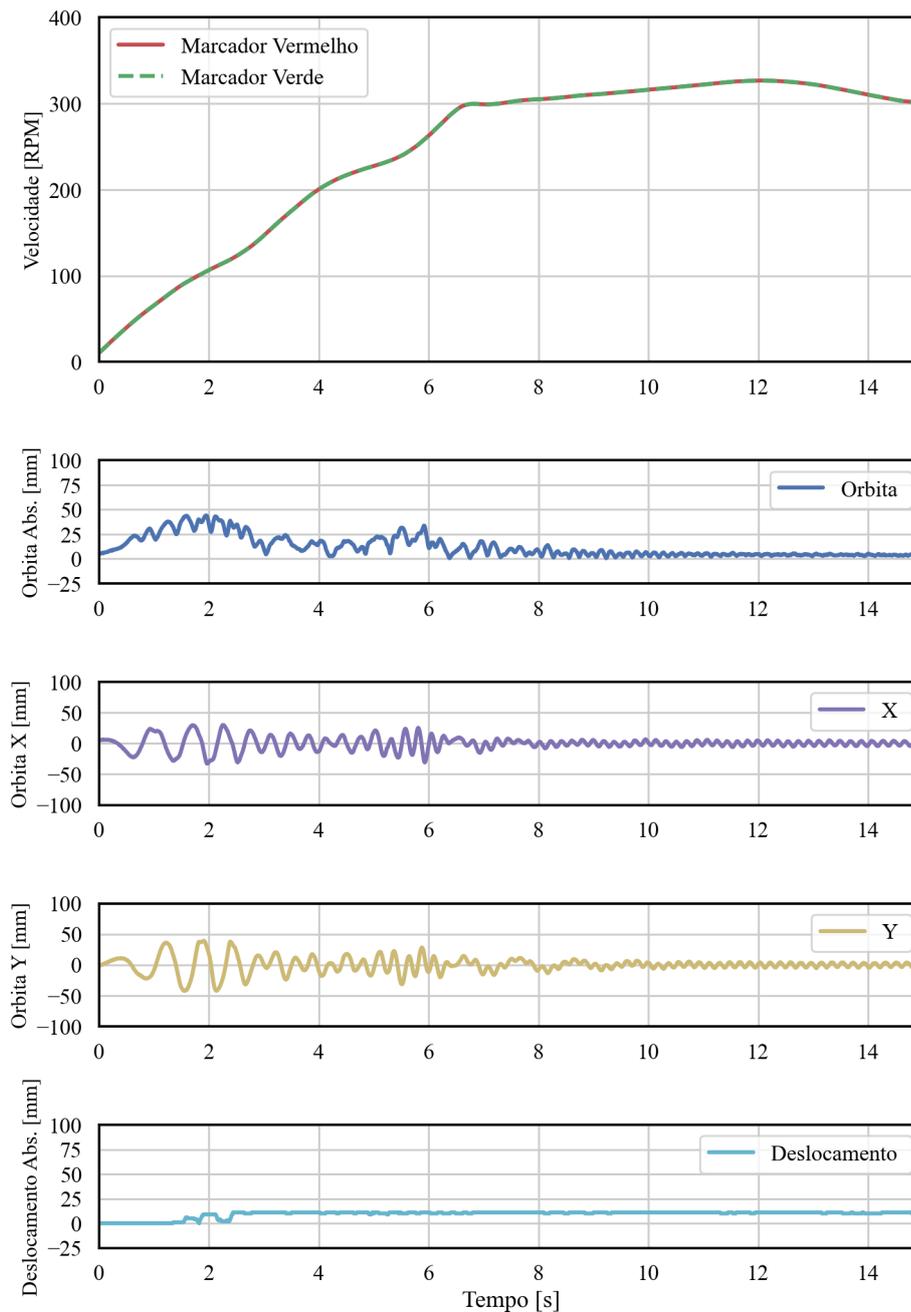
Figura 49 – 0 kg de Manta Balanceada e 1 kg de Carga Desbalanceada na base do cesto



Fonte: o Autor

Uma situação completamente distinta se apresenta quando a massa desbalanceada atinge 2 kg. A medição de velocidade revela um tempo mais prolongado necessário para atingir 250 RPM. Além disso, nota-se um aumento súbito no deslocamento absoluto, sugerindo a possibilidade de choques entre o conjunto suspenso e o gabinete.

Figura 50 – 0 kg de Manta Balanceada e 2 kg de Carga Desbalanceada na base do cesto



Fonte: o Autor

As variáveis extraídas, as quais serão empregadas como entrada na RNA, encontram-se estratificadas em sua totalidade na Tabela 7 localizada no Apêndice D.

5.2.2 Consolidação do Conjunto de Dados

Como mencionado nas seções anteriores, o modelo de RNA tem como objetivo classificar a performance dinâmica de modo a quantificar a quantidade de massa balanceada e quantidade e altura de massa desbalanceadas. Tal quantificação expressa valores em cargas de borracha, o mesmo tipo utilizado como fator na etapa de treinamento.

Logo, a consolidação do conjunto de dados é feita com a junção da Tabela 6, a qual contém as saídas desejadas (nomeadas com o prefixo Y1, Y2 e Y3), com a Tabela 7, com as variáveis de entrada (nomeadas com o prefixo X1, X2, X3, X4 e X5).

5.2.3 Divisão do Conjunto de Dados

Antes de iniciar o treinamento de uma RNA, o conjunto dados deve ser separado em conjuntos de treinamento, validação e teste. Uma eficiente divisão busca ampliar a capacidade de generalização da RNA. Isso é importante porque o objetivo final da rede neural é fazer previsões como novos dados, diferente dos utilizados no treinamento.

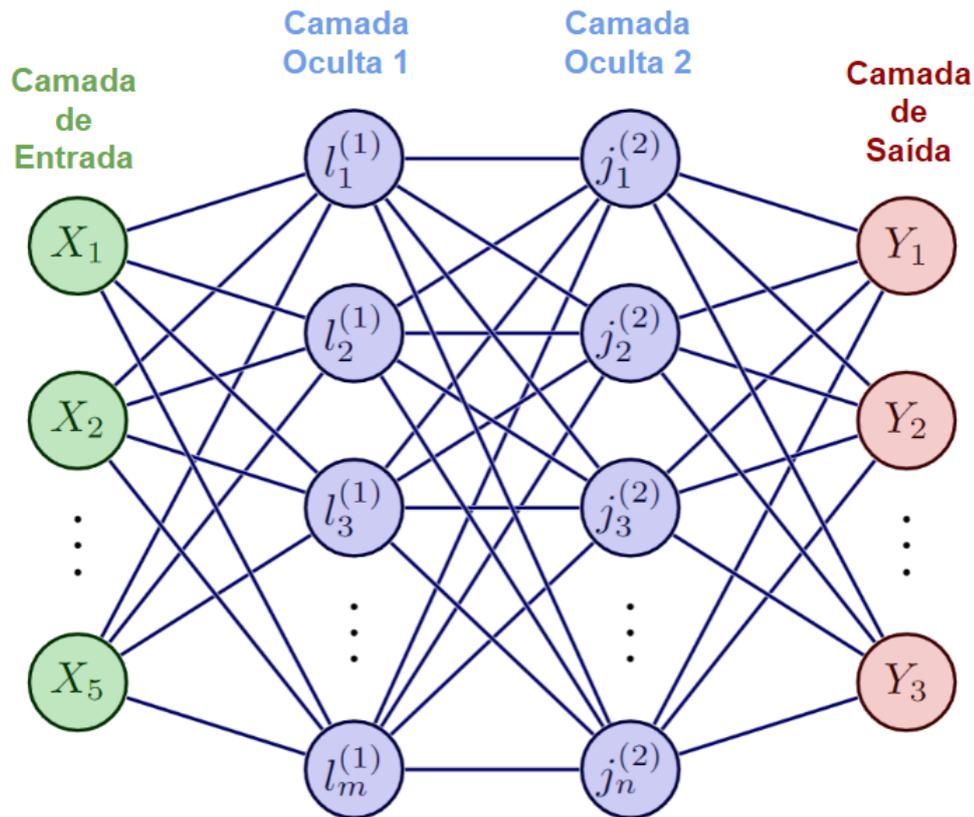
O conjunto de treinamento, como o próprio nome sugere, é utilizado no treinamento do modelo. Enquanto o conjunto de validação é usado para comparação de diferentes modelos e hiperparâmetros. Já o conjunto de teste é usado para comprovar a funcionalidade do modelo com dados os quais ele não foi exposto previamente.

Para o presente estudo, 116 conjuntos de dados foram separados para a etapa de treinamento e validação cruzada (dos quais são divididos na proporção de 70% e 30% respectivamente a cada tentativa de treinamento), e 52 conjuntos segregados para a etapa de teste.

5.2.4 Seleção dos hiperparâmetros

Com o objetivo de determinar a configuração mais eficaz em termos de camadas e neurônios para a RNA, foram conduzidas simulações e comparações entre diversas combinações. A Figura 54 oferece uma visão geral das combinações exploradas, onde as variações nos parâmetros foram aplicadas às camadas ocultas da RNA. O limite máximo estabelecido foi de duas camadas ocultas, cada uma com capacidade de conter até 15 neurônios (variando de 1 a 15 para m e de 0 a 15 para n). Mediante um processo iterativo, todas as combinações possíveis foram avaliadas.

Figura 51 – Esquemático genérico da RNA MLP



Fonte: o Autor

Para cada nova configuração da RNA, o processo que envolve a divisão do conjunto de dados entre conjuntos de treinamento e validação, juntamente com o treinamento do modelo, foi repetido 50 vezes consecutivas. Essa abordagem foi implementada com a finalidade de assegurar a otimização do modelo dentro da configuração de RNA sob análise. A configuração ideal da RNA foi selecionada com base no valor de R^2 priorizando o maior valor próximo a 1, obtido através do conjunto de dados de validação. Essa configuração foi então armazenada para avaliação posterior, utilizando o conjunto de dados de teste.

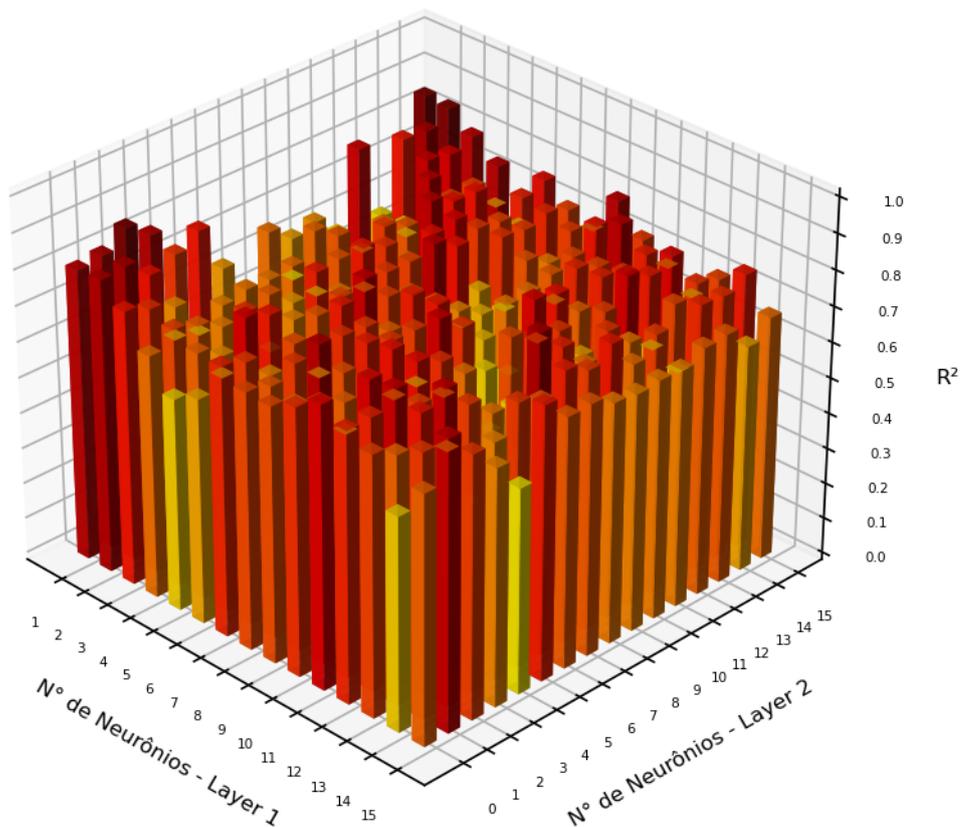
Ao término desse processo, um total de 240 combinações de camadas ocultas e número de neurônios foram geradas, resultando em um total de 12.000 treinamentos para identificação das melhores configurações..

5.2.5 Treinamento e Seleção dos Modelos

Por meio dos conjuntos de dados empregados no processo de treinamento e validação, realizou-se uma avaliação das configurações de camadas e neurônios para cada uma das três saídas do experimento.

A Figura 52 ilustra os melhores valores de R^2 obtidos para cada uma das 240 combinações da RNA referentes à saída de Massa Balanceada ($Y1$). A combinação de 3 neurônios em cada uma das duas camadas ocultas se destaca como a melhor configuração dentro do espaço de inferência avaliado.

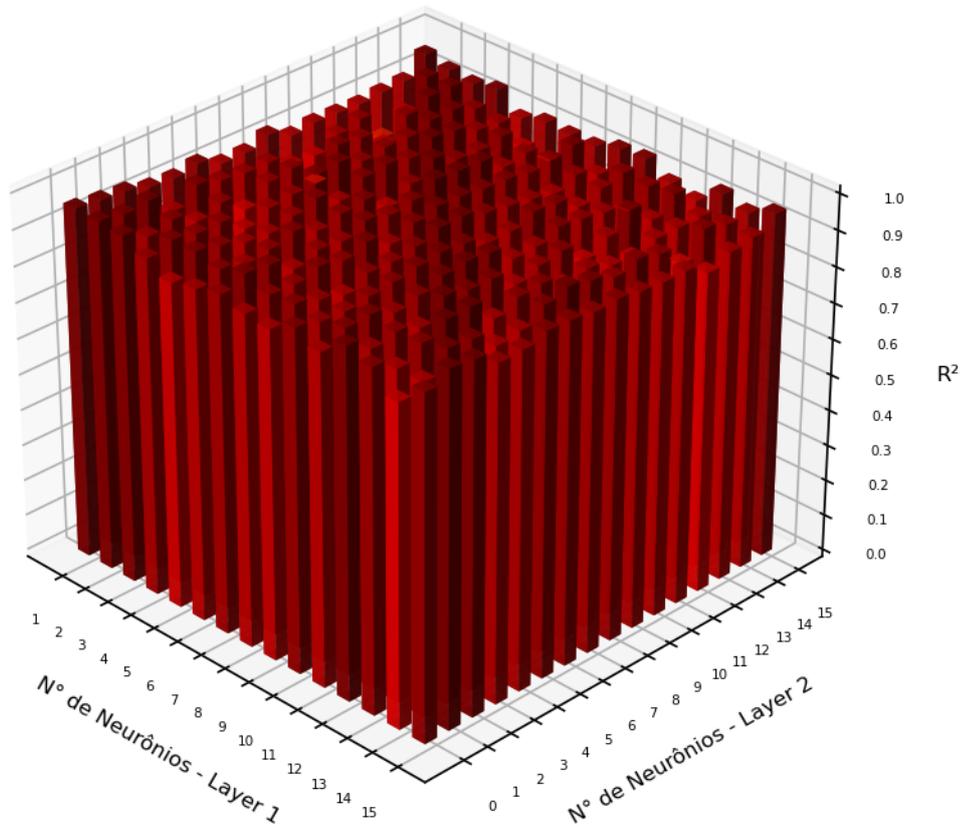
Figura 52 – R^2 de Modelos para $Y1$ (Massas Balanceadas) com conjunto de dados de Treinamento e Validação



Fonte: o Autor

Para a variável Massa Desbalanceada ($Y2$), a Figura 53 ilustra uma grande homogeneidade entre os valores de R^2 calculados. Com valores entre 0.8 e 0.9, a variável $Y2$ tem grande parte da variação gerada explicada pelo modelo.

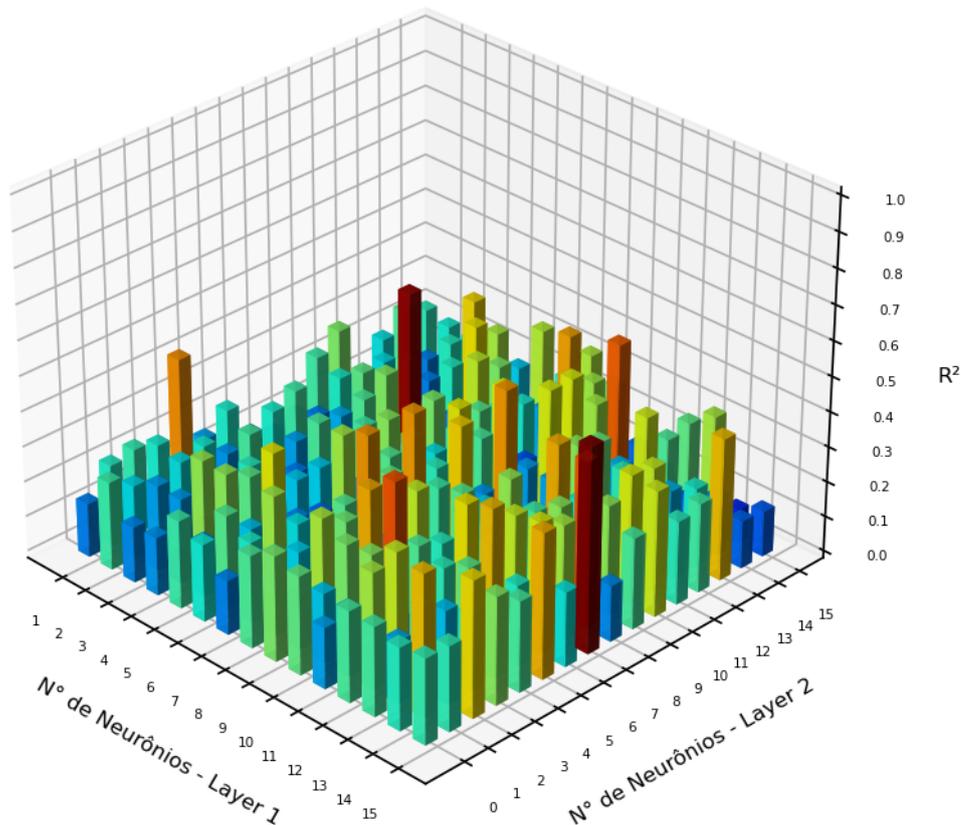
Figura 53 – R^2 de Modelos para Y2 (Massa Desbalanceada) com conjunto de dados de Treinamento e Validação



Fonte: o Autor

De forma totalmente oposta, a variável Altura da Massa Desbalanceada ($Y3$) apresentou R^2 abaixo de 0.4, indicando que nenhum dos modelos de RNA pode ser utilizado para a estimativa da mesma.

Figura 54 – R^2 de Modelos para Y3 (Altura da Massas Desbalanceada) com conjunto de dados de Treinamento e Validação



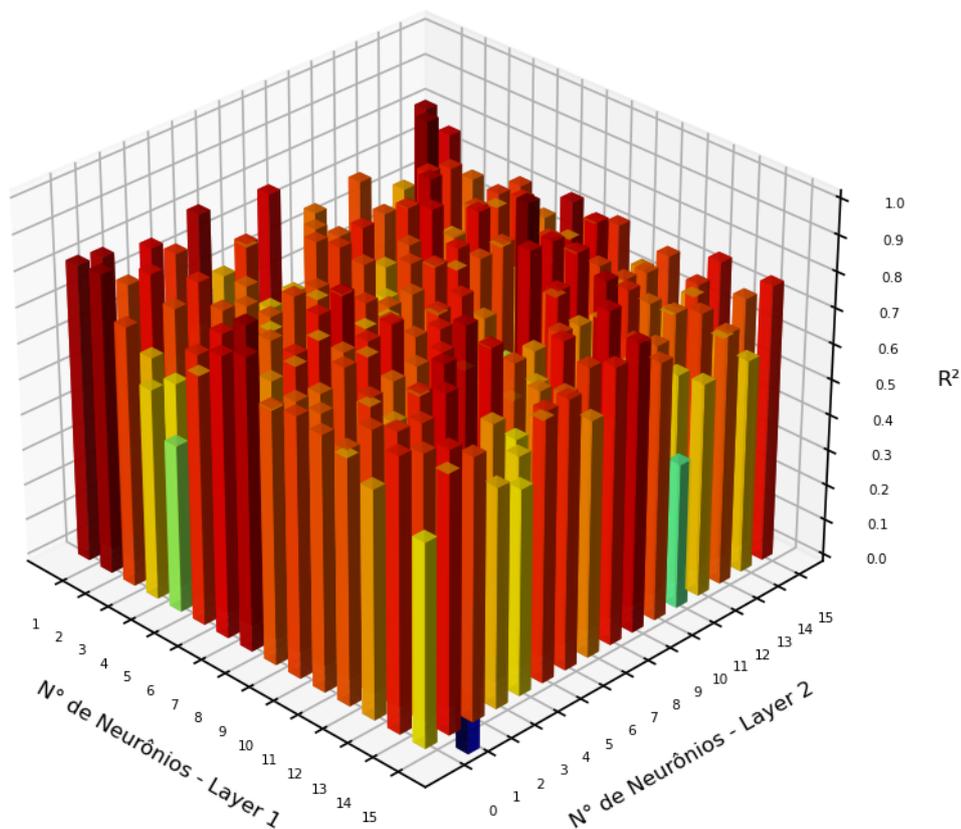
Fonte: o Autor

Logo, de acordo com o espaço de inferência utilizado no processo de treinamento e validação, é possível afirmar que a RNA é capaz de estimar a quantidade de massa balanceada com boa precisão, a quantidade de massa desbalanceada com ótima precisão, enquanto a altura da massa desbalanceada não pode ser prevista de forma confiável

5.2.6 Validação dos Modelos

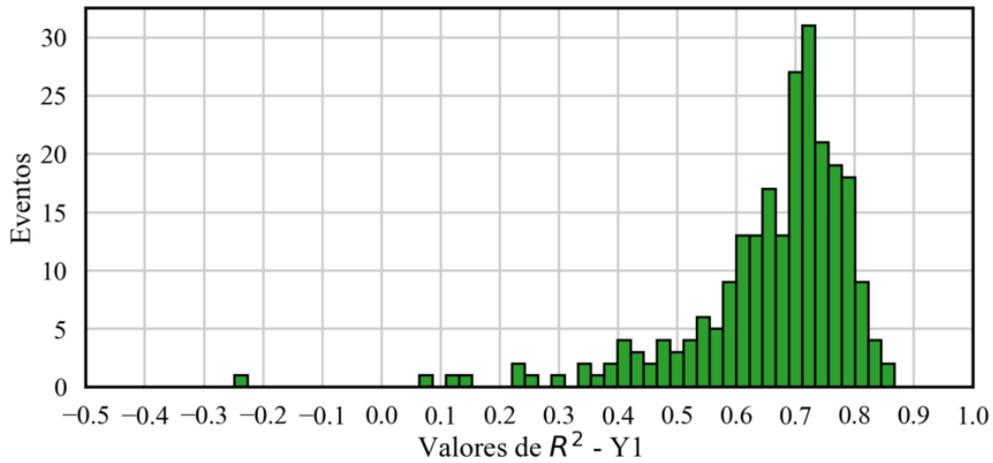
Na fase de teste final, os modelos de RNA previamente selecionados são submetidos ao conjunto de dados de teste, ou seja, a dados aos quais não foram previamente expostos. Isso permite avaliar a capacidade dos modelos de fazer estimativas precisas em novas circunstâncias.

De maneira semelhante ao conjunto de dados anterior (treinamento e validação), observou-se que as variáveis Y1 (Figura 55) e Y2(Figura 59) apresentaram valores de R^2 ligeiramente menores, porém próximos. Por outro lado, a variável Y3(Figura 63) chegou a exibir combinações com valores de R^2 negativos, o que fortalece a afirmação de que essa característica não pode ser estimada adequadamente pelos modelos de RNA.

Figura 55 – R^2 de Modelos para Y1 (Massas Balanceadas) com conjunto de dados de Teste

Fonte: o Autor

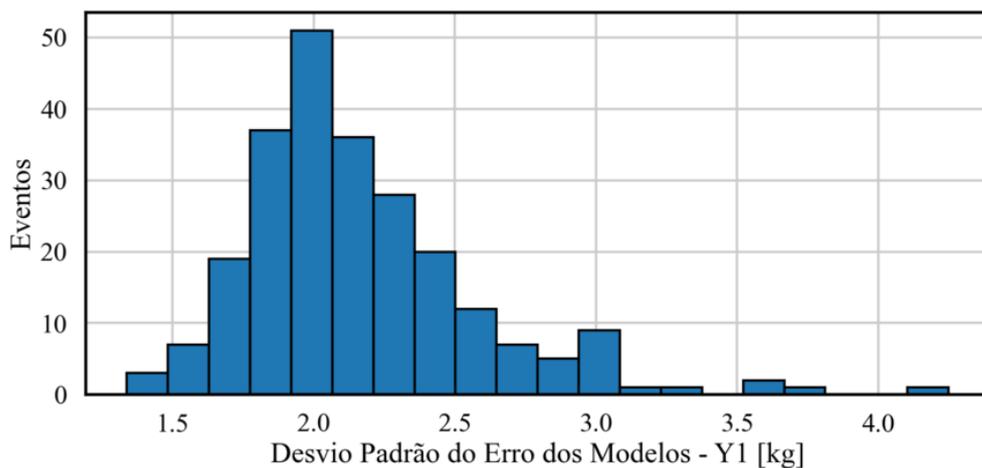
Com o intuito de proporcionar uma visualização mais clara dos resultados obtidos por meio das diversas configurações da RNA, são apresentados nas Figuras 56, 60 e 64 os histogramas dos valores de R^2 para as saídas Y1, Y2 e Y3 respectivamente. Essa representação gráfica permite uma análise mais abrangente e uma compreensão mais precisa do desempenho dessas configurações em relação às diferentes saídas do modelo.

Figura 56 – Histograma dos valores de R^2 para Y1 (Massas Balanceadas)

Fonte: o Autor

Outra forma de avaliação do modelo é análise dos erros de previsão. As Figuras Figura 57, Figura 61 e Figura 65 representam as a distribuição do valores de desvio padrão das configurações de RNAs testas. Quanto menor o valor de desvio padrão, melhor é a assertividade do modelo.

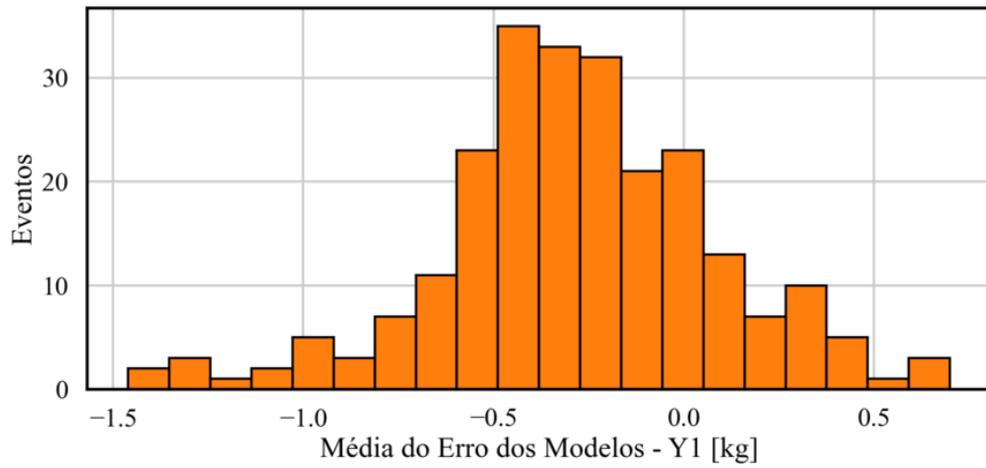
Figura 57 – Histograma do Desvio Padrão dos Erros dos Modelos para Y1 (Massas Balanceadas)



Fonte: o Autor

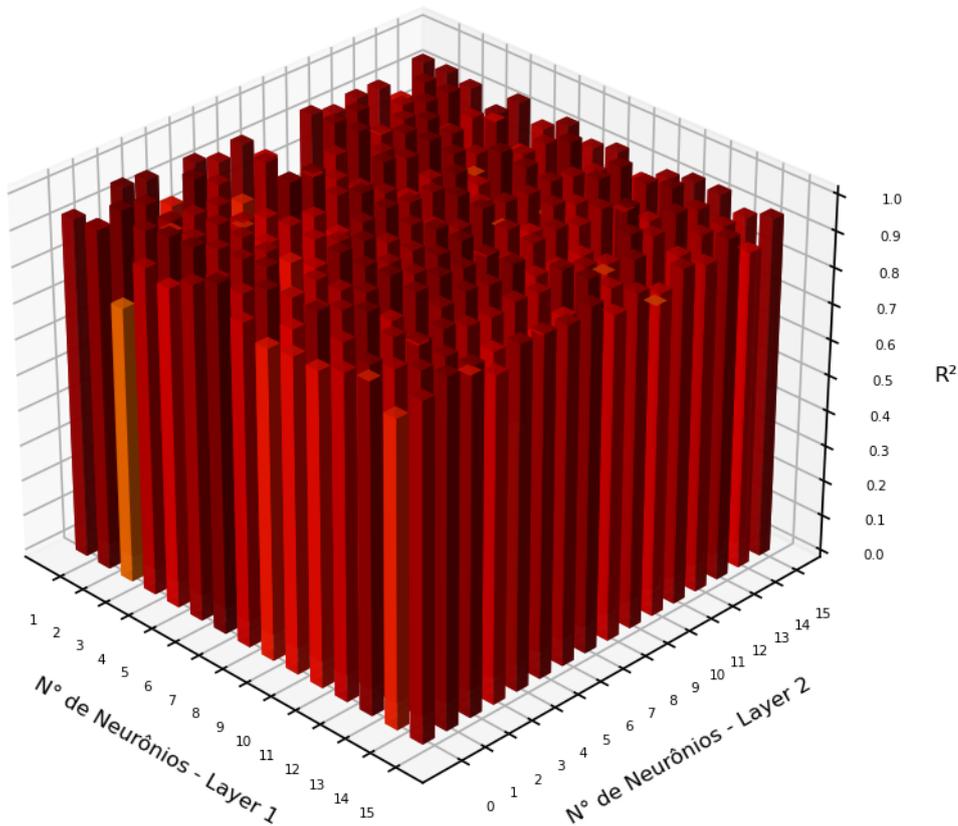
Outra forma de avaliação do modelo é análise dos erros de previsão. As Figuras Figura 57, Figura 61 e Figura 65 representam as a distribuição do valores de desvio padrão das configurações de RNAs testadas. Quanto menor o valor de desvio padrão, melhor é a assertividade do modelo.

Figura 58 – Histograma da Média dos Erros dos Modelos para Y1 (Massas Balanceadas)

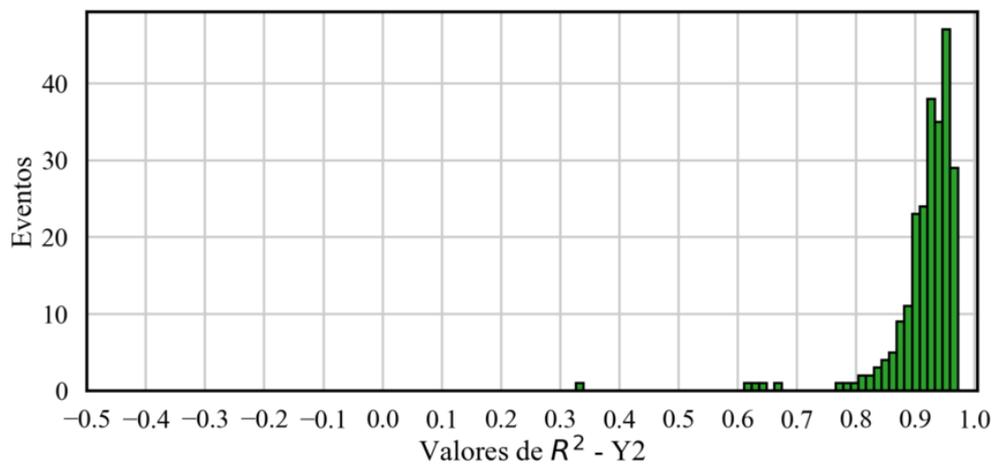


Fonte: o Autor

De forma complementar, o historiograma com a média dos erros de previsão, vistos nas Figuras Figura 58, Figura 62 e Figura 66, ilustram a distribuição do erro médio dos modelos explorados. É desejável que o erro médio seja próximo de zero, indicando que o modelo não apresenta nenhum *offset*.

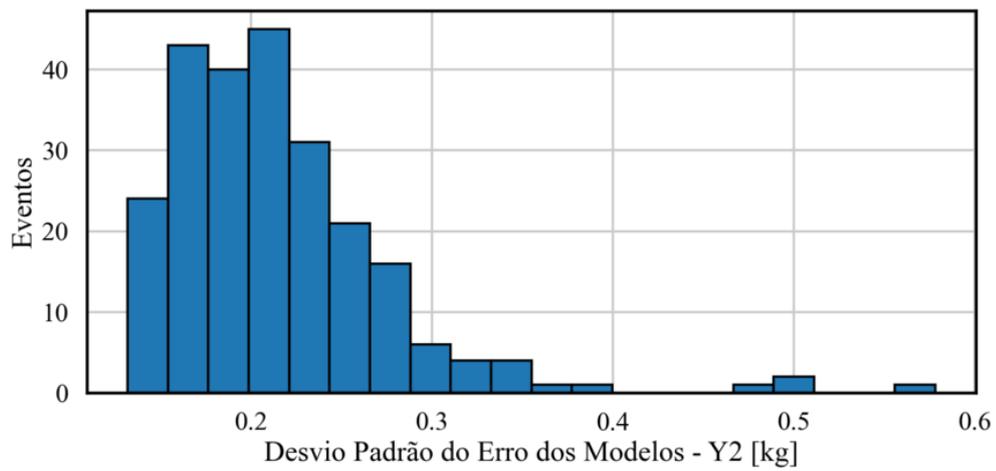
Figura 59 – R^2 de Modelos para Y2 (Massas Desbalanceadas) com conjunto de dados de Teste

Fonte: o Autor

Figura 60 – Histograma dos valores de R^2 para Y2 (Massas Desbalanceadas)

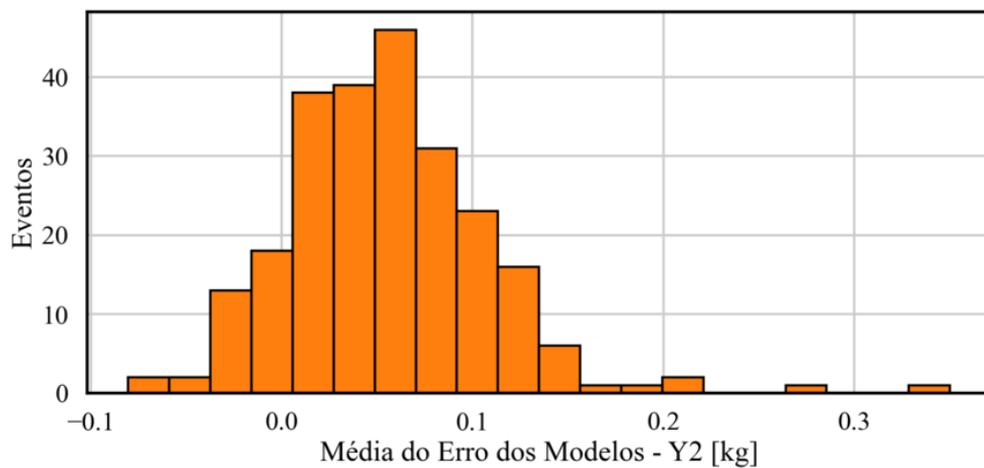
Fonte: o Autor

Figura 61 – Histograma do Desvio Padrão dos Erros dos Modelos para Y2 (Massas Desbalanceadas)



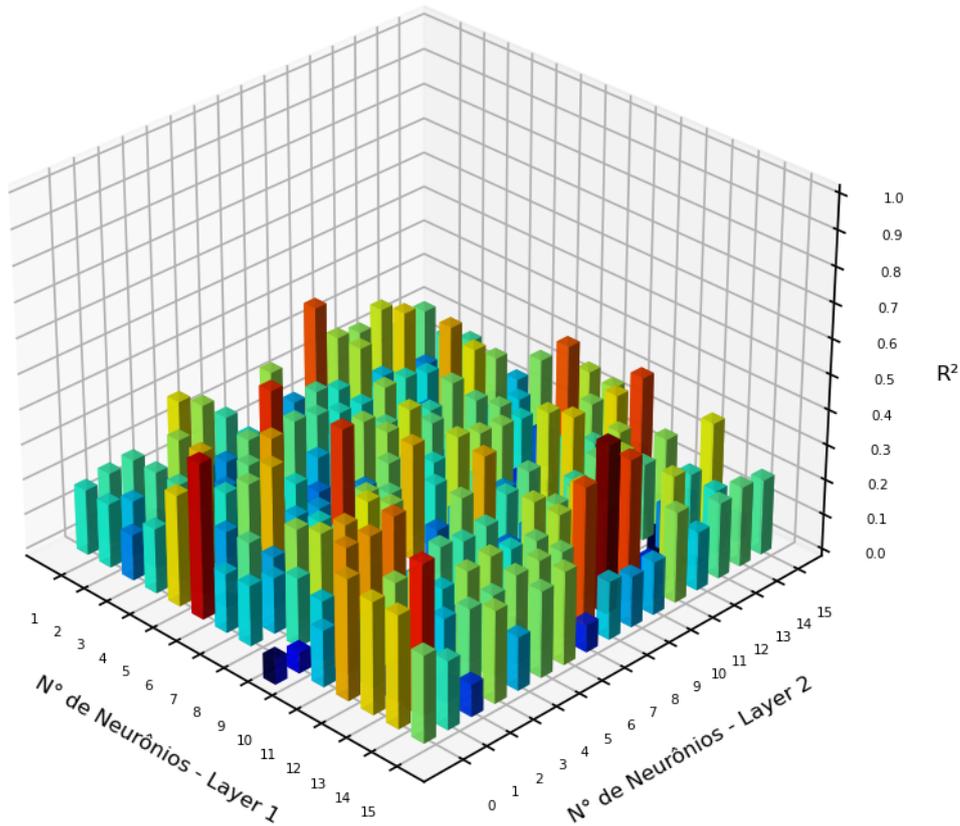
Fonte: o Autor

Figura 62 – Histograma da Média dos Erros dos Modelos para Y2 (Massas Desbalanceadas)



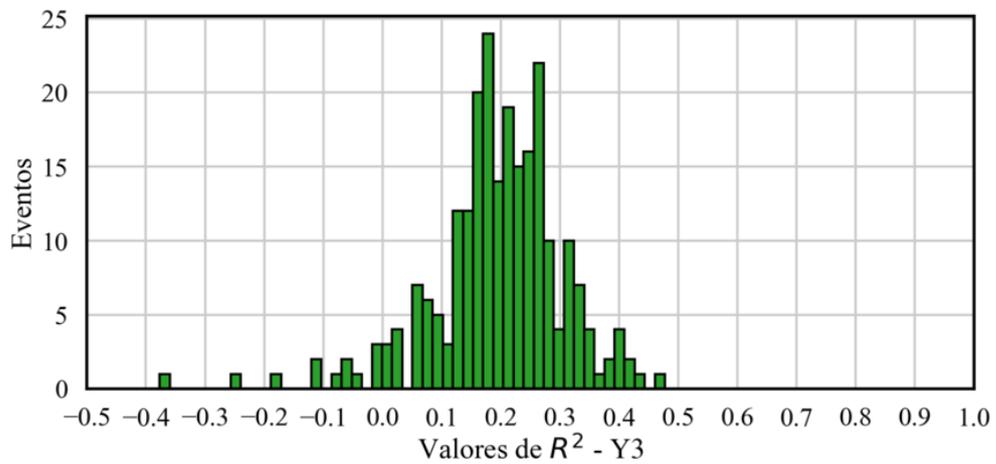
Fonte: o Autor

Figura 63 – R^2 de Modelos para Y3 (Altura da Massas Desbalanceada) com conjunto de dados de Treinamento e Validação



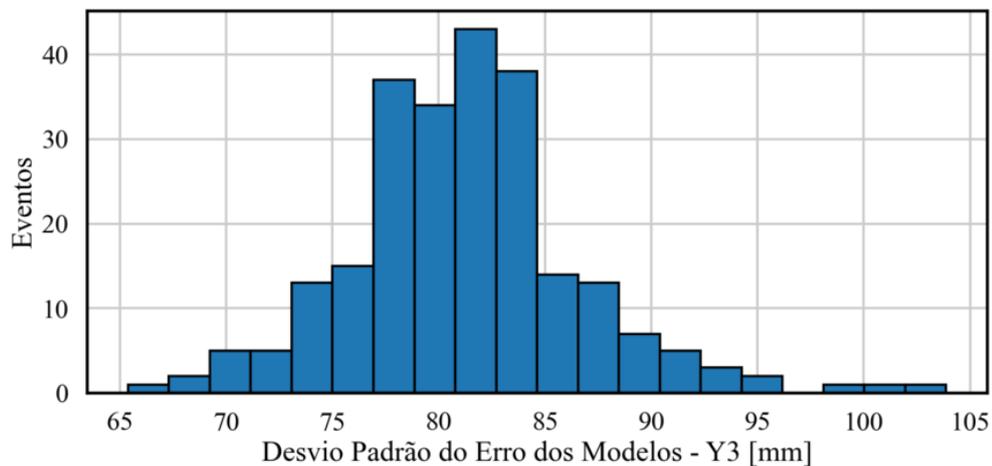
Fonte: o Autor

Figura 64 – Histograma dos valores de R^2 para Y3 (Altura das Massas Desbalanceadas)



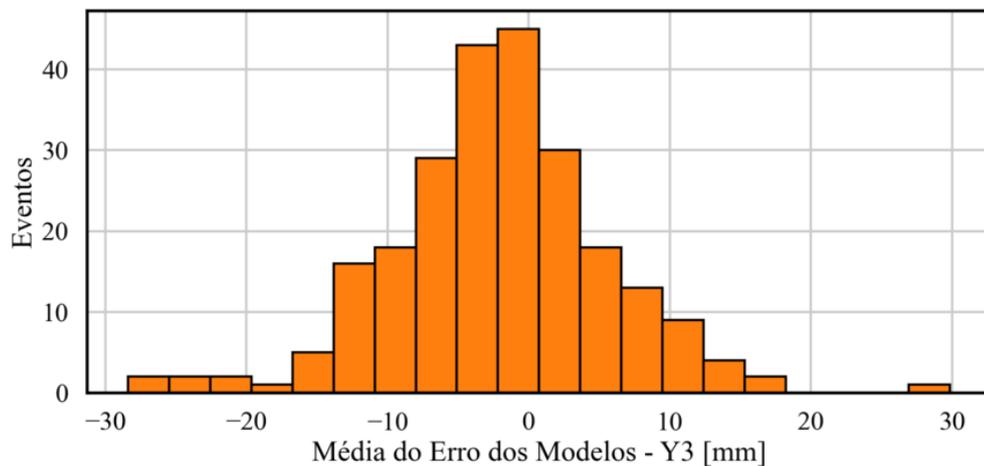
Fonte: o Autor

Figura 65 – Histograma do Desvio Padrão dos Erros dos Modelos para Y3 (Altura das Massas Desbalanceadas)



Fonte: o Autor

Figura 66 – Histograma da Média dos Erros dos Modelos para Y2 (Altura das Massas Desbalanceadas)



Fonte: o Autor

5.2.7 Modelos Selecionados

Na análise conclusiva, foram escolhidas quatro configurações de RNA para a avaliação do erro de previsão em relação ao conjunto de dados de teste. Além dos critérios de R^2 , também foram considerados o desvio padrão e a média do erro de previsão. É relevante salientar que, durante o processo de seleção, apenas as saídas Y1 e Y2 foram contempladas, visto que os modelos associados a Y3 não obtiveram resultados satisfatórios. Na Tabela 5

são listadas as configurações de modelos selecionadas juntamente com seus respectivos indicadores de performances.

Tabela 5 – Modelos Selecionados

Neurônios Camada Oculta 1	Neurônios Camada Oculta 2	R^2 (Y1)	Desvio Padrão do Erro de Predição (Y1)	Média do Erro de Predição (Y1)	R^2 (Y2)	Desvio Padrão do Erro de Predição (Y2)	Média do Erro de Predição (Y1)
2	1	0,84	1,5283	-0,2198	0,95	0,1637	0,0755
2	11	0,81	1,5778	-0,5430	0,95	0,1716	0,0358
5	8	0,87	1,3373	-0,4241	0,95	0,1736	0,0263
3	0	0,72	1,9553	-0,6232	0,97	0,1318	0,0372

Fonte: Autor

Portanto, para futuras experimentações, nas quais a intenção é empregar o sistema de visão computacional desenvolvido para avaliar o desempenho dinâmico de lavadoras de roupa de eixo vertical carregadas com tecidos, em vez de pesos de borracha, os modelos de RNA listados serão empregados e submetidos a uma comparação.

Capítulo 6

Conclusão

No presente trabalho, foi apresentado inicialmente um método de rastreamento de marcadores desenvolvido para a medição precisa da velocidade rotacional instantânea e do movimento translacional de um rotor. Uma série de experimentos foi conduzida para validar o referido método em diversas condições de velocidade, abrangendo cenários de velocidade fixa em um ponto estático, velocidade fixa em um ponto dinâmico, velocidade variável em um ponto estático e velocidade variável em um ponto dinâmico.

Os resultados obtidos demonstraram que o erro relativo médio na medição da velocidade rotacional permaneceu, em grande parte, dentro da faixa de $\pm 0.02\%$ para pontos estáticos, $\pm 0.2\%$ em condições dinâmicas com uma taxa de quadros de 120 FPS e um tempo de exposição de $1/1920$ s, e $\pm 0.5\%$ a 60 FPS com um tempo de exposição de $1/960$ s. Importante notar que, em condições dinâmicas extremas, com rotações abaixo de 250 RPM, o erro relativo aumentou para $\pm 2\%$. Esse aumento no erro pode ser atribuído à ocorrência de movimentos simultâneos, resultando no fenômeno de arrasto nas imagens.

Adicionalmente, nos ensaios estáticos realizados para diferentes configurações de rotação, observou-se um desvio padrão relativo médio de 0.02% . Uma das principais características destacadas deste sistema reside em sua notável precisão, aliada à capacidade de medir movimentos translacionais.

Chama a atenção o fato de que a resolução da câmera, surpreendentemente, não exerceu um impacto significativo nos resultados deste estudo. Além disso, o sistema demonstrou competência em medir rotações consistentes de até 3560 RPM com uma taxa de quadros de 60 FPS, assim como em lidar com velocidades superiores a essa faixa com uma taxa de quadros de 120 FPS.

Estes achados realçam a robustez e a versatilidade do método de rastreamento de marcadores proposto, apresentando-se como uma solução para a aplicação em experimentos

com lavadoras de roupas vertical.

Após a conclusão do processo de validação do sistema de visão computacional, foi proposto um algoritmo de aprendizado com base em uma rede neural do tipo MLP. A rede em questão é um modelo de aprendizado do tipo FeedForward, operando sob supervisão total. Uma arquitetura adaptativa foi usada, permitindo a configuração de até duas camadas ocultas, cada uma com 15 neurônios. O desempenho das RNAs foi avaliado por meio do processo de *Grid Search*, ou seja uma varredura das possíveis combinações, com o objetivo de identificar a configuração mais eficaz em termos de neurônios e camadas, utilizando o valores R^2 como métrica de referência.

A implementação da cabine de filmagem proporcionou um processo de coleta de dados eficiente e uniforme, totalizando a aquisição de 168 arquivos de vídeo com diferentes configurações de massas. Embora o conjunto de dados tenha abrangido de maneira satisfatória o espaço de inferência desejado (combinação de diferentes massa balanceadas e desbalanceadas), inclusive com a inclusão de réplicas, recomenda-se enriquecer o modelo de Redes Neurais Artificiais (RNA) por meio da aquisição de um volume mais substancial de dados, sobretudo de outras unidades do mesmo modelo de lavadoras de roupas.

O processamento dos vídeos ocorreu de forma automatizada, facilitado pela uniformidade da iluminação, o que possibilitou a calibração das cores dos marcadores ser executada apenas uma vez no início do experimento.

As características extraídas do comportamento dinâmico, representadas pelos dados empíricos ($X1$, $X2$, $X3$, $X4$ e $X5$), demonstraram ser entradas eficazes para os modelos das RNAs, especialmente para a previsão das saídas $Y1$ - *Massa Balanceadas* e $Y2$ - *Massas Desbalanceadas*. No entanto, em relação à variável $Y3$ - *Altura da Massa Desbalanceada*, tornou-se evidente a necessidade de identificar novas características dinâmicas que permitam prever com precisão esse fenômeno.

A realização de um grande número de simulações possibilitou explorar diversas configurações de RNAs MLP (variando número de camadas ocultas e suas respectivas quantidades de neurônios), permitindo a identificação das configurações que apresentaram o melhor desempenho em termos de R^2 , Desvio Padrão do Erro de Previsão e Média do Erro de Previsão. Os modelos selecionados demonstraram valores de R^2 superiores a 0,72 e 0,95 para $Y1$ e $Y2$, respectivamente.

Os modelos de RNA desenvolvidos serão submetidos a testes futuros em situações do mundo real, ou seja, com vídeos de ciclos de lavagem de roupas e tecidos. Isso representa um avanço significativo em direção à aplicação prática dessa tecnologia no contexto da identificação de massas desbalanceadas e sua caracterização.

Referências

AHMED, R. et al. Automotive internal-combustion-engine fault detection and classification using artificial neural network techniques. **IEEE Transactions on Vehicular Technology**, v. 64, p. 21–33, 01 2015.

AKCABAY, D. T.; DOWLING, D. R.; SCHULTZ, W. W. Clothes washing simulations. **Computers & Fluids**, v. 100, p. 79–94, 2014. ISSN 0045-7930. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045793014001911>>.

ALLOGHANI, M. et al. A systematic review on supervised and unsupervised machine learning algorithms for data science. In: _____. **Supervised and Unsupervised Learning for Data Science**. Cham: Springer International Publishing, 2020. p. 3–21. ISBN 978-3-030-22475-2. Disponível em: <https://doi.org/10.1007/978-3-030-22475-2_1>.

ANDREAS, Z. **Simulation Neuronaler Netze**. [S.l.]: Oldenbourg, Munchen, 2003. ISBN 9783486243505.

ANDREEV, Y. S.; TRETYAKOV, S. D.; MIKHAILOV, A. B. Objects geometry comparative analysis method for industrial robot vision system. p. 1–5, 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8742984>>.

ANDRÉ, H. et al. Using a smartphone camera to analyse rotating and vibrating systems: Feedback on the survishno 2019 contest. **Mechanical Systems and Signal Processing**, v. 154, p. 107553, 2021. ISSN 0888-3270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327020309390>>.

ANJOS, A.; SHAHBAZKIA, H. Bi-level image thresholding - a fast method. In: . [S.l.: s.n.], 2008. v. 2, p. 70–76.

BARCHA, W. A. M. **Estudo do Comportamento Dinâmico e do Fenômeno de Deslocamento em Lavadoras de Roupas de Eixo Vertical**. Tese (Doutorado) — Wladimir Alex Magalhães Barcha, São Carlos - SP, Brasil, 2004. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/18/18135/tde-20052016-102316/pt-br.php>>. Acesso em: 3.7.2011.

BISHOP, C. M. **Neural networks for pattern recognition**. [S.l.]: Oxford University Press, USA, 1995.

BLOCK, S. B. et al. Inspection of imprint defects in stamped metal surfaces using deep learning and tracking. **IEEE Transactions on Industrial Electronics**, v. 68, n. 5, p. 4498–4507, 2021. Disponível em: <<https://ieeexplore.ieee.org/document/9062515>>.

BONNARDOT, F. et al. High frequency demodulation technique for instantaneous angular speed estimation. **Mechanical Systems and Signal Processing**, v. 159, p. 107745, 2021. ISSN 0888-3270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327021001400>>.

CIRESAN, D. et al. Flexible, high performance convolutional neural networks for image classification. In: . [S.l.: s.n.], 2011. p. 1237–1242.

CONRAD, D. C. **The fundamentals of automatic washing machine design based upon dynamic constraints**. Tese (Doutorado) — Purdue University., Enschede, The Netherlands, 1994. Disponível em: <<https://docs.lib.purdue.edu/dissertations/AAI9725673/>>. Acesso em: 3.7.2011.

COSIJNS, S. J.; JANSEN, M. J.; HAITJEMA, H. 10 - advanced optical incremental sensors: Encoders and interferometers. In: NIHTIANOV, S.; LUQUE, A. (Ed.). **Smart Sensors and MEMs (Second Edition)**. Second edition. Woodhead Publishing, 2018, (Woodhead Publishing Series in Electronic and Optical Materials). p. 245–290. ISBN 978-0-08-102055-5. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780081020555000103>>.

DaBEK, P. et al. Measurement of idlers rotation speed in belt conveyors based on image data analysis for diagnostic purposes. **Measurement**, v. 202, p. 111869, 2022. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224122010661>>.

FERNANDES, A. O.; MOREIRA, L. F. E.; MATA, J. M. Machine vision applications and development aspects. p. 1274–1278, 2011. Disponível em: <<https://ieeexplore.ieee.org/document/6138014>>.

GLANTZ, S.; SLINKER, B.; NEILANDS, T. **Primer of Applied Regression & Analysis of Variance 3E**. McGraw Hill LLC, 1996. ISBN 9780071822442. Disponível em: <<https://books.google.com.br/books?id=E73NCwAAQBAJ>>.

GOEL, A.; GOEL, A. K.; KUMAR, A. The role of artificial neural network and machine learning in utilizing spatial information. **Spatial Information Research**, v. 31, n. 3, p. 275–285, Jun 2023. ISSN 2366-3294. Disponível em: <<https://link.springer.com/article/10.1007/s41324-022-00494-x>>.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. Upper Saddle River, NJ, USA: Prentice Hall, 2002.

HARDYMENT, C. **From Mangle To Microwave: Mechanization of the Household**. New York, NY, USA: Polity Press, 1988.

HUTMACHER, F. Why is there so much more research on vision than on any other sensory modality? **Frontiers in Psychology**, v. 10, 10 2019.

- IORIATTI, A. S. **Estudo da dinâmica de lavadora de eixo vertical utilizando sistemas multicorpos**. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, Brasil, 2007. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18149/tde-07012016-162506/publico/Dissert_Ioriatti_AdrianoS.pdf>. Acesso em: 25.10.2020.
- JIA, H.-K. et al. Compensation of rotary encoders using fourier expansion-back propagation neural network optimized by genetic algorithm. **Sensors**, v. 20, n. 9, 2020. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/20/9/2603>>.
- JOSHI, P. **OpenCV with Python by Example: Build Real-world Computer Vision Applications and Develop Cool Demos Using OpenCV for Python**. New York, NY, USA: Packt Publishing, 2015.
- KANG, H.-C. et al. Hsv color-space-based automated object localization for robot grasping without prior knowledge. **Applied Sciences**, v. 11, p. 7593, 08 2021. Disponível em: <<https://www.mdpi.com/1234098>>.
- KIM, H. et al. Visual encoder: robust and precise measurement method of rotation angle via high-speed rgb vision. **Opt. Express**, Optica Publishing Group, v. 24, n. 12, p. 13375–13386, Jun 2016. Disponível em: <<https://opg.optica.org/oe/abstract.cfm?URI=oe-24-12-13375>>.
- KLETTE, R. **Concise Computer Vision: An Introduction into Theory and Algorithms**. Springer London, 2014. ISBN 978-1-4471-6319-0. Disponível em: <<https://link.springer.com/book/10.1007/978-1-4471-6320-6>>.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. (IJCAI'95), p. 1137–1143. ISBN 1558603638.
- KONSTANTINIDIS, F. K.; MOUROUTSOS, S. G.; GASTERATOS, A. The role of machine vision in industry 4.0: an automotive manufacturing perspective. p. 1–6, 2021. Disponível em: <<https://ieeexplore.ieee.org/document/9651453>>.
- LIAO, Y.-H.; WANG, L.; YAN, Y. Instantaneous rotational speed measurement of wind turbine blades using a marker-tracking method. p. 1–5, 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9806658>>.
- LIBERALI, V. et al. A digital self-calibration circuit for absolute optical rotary encoder microsystems. **IEEE Transactions on Instrumentation and Measurement**, v. 52, n. 1, p. 149–157, 2003. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/1191423>>.
- LOY, J. **Neural Network Projects with Python: The ultimate guide to using Python to explore the true power of neural networks through six projects**. Packt Publishing, 2019. ISBN 9781789133318. Disponível em: <<https://books.google.com.br/books?id=6AuLDwAAQBAJ>>.
- MILJANOVIC, M. Comparative analysis of recurrent and finite impulse response neural networks in time series prediction. **Indian Journal of Computer Science and Engineering**, v. 3, 02 2012.

- OPEN SOURCE COMPUTER VISION LIBRARY. **OpenCV**. [S.l.], 2022. Disponível em: <<https://opencv.org/about/>>. Acesso em: 31.7.2022.
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62–66, 1979. Disponível em: <<https://ieeexplore.ieee.org/document/4310076>>.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.
- PEDRINI, H.; SCHWARTZ, W. **Análise de imagens digitais: princípios, algoritmos e aplicações**. [S.l.]: CENGAGE, 2008.
- PYTHON SOFTWARE FOUNDATION. **Python**. [S.l.], 2022. Disponível em: <<https://www.python.org/>>. Acesso em: 10.9.2022.
- QU, Y.; JIANG, J. Dynamic modeling and simulation of washing machine suspension system. **2019 IEEE 10th International Conference on Mechanical and Aerospace Engineering (ICMAE)**, p. 470–474, 2019.
- RIPLEY, B. **Pattern Recognition and Neural Networks**. Cambridge University Press, 1996. ISBN 9780521460866. Disponível em: <<https://books.google.com.br/books?id=2SzT2p8vP1oC>>.
- RUNXUAN, Z. **Efficient Sequential and Batch Learning Artificial Neural Network Methods for Classification Problems**. Tese (Doutorado) — School of Electrical & Electronic Engineering, Nanyang Technological University, Singapore, 2005. Disponível em: <<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.100.5801&rep=rep1&type=pdf>>. Acesso em: 10.11.2020.
- SEZGIN, M.; SANKUR, B. Survey over image thresholding techniques and quantitative performance evaluation. **Journal of Electronic Imaging**, v. 13, p. 146–168, 01 2004.
- SHANNON, C. Communication in the presence of noise. **Proceedings of the IRE**, v. 37, n. 1, p. 10–21, 1949. Disponível em: <<https://ieeexplore.ieee.org/document/1697831>>.
- SHAPIRO, L.; STOCKMAN, G. **Computer Vision**. Prentice Hall, 2001. ISBN 9780130307965. Disponível em: <<https://books.google.com.br/books?id=FftDAQAAIAAJ>>.
- SILVA, I. N. d.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.
- SOLOMON, C.; BRECKON, T. **Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab**. New York, NY, USA: Wiley Blackwell, 2011.
- SPYDER IDE. **Spyder IDE**. [S.l.], 2022. Disponível em: <<https://www.spyder-ide.org/>>. Acesso em: 10.9.2022.
- STEEL, R.; TORRIE, J. **Principles and Procedures of Statistics: With Special Reference to the Biological Sciences**. McGraw-Hill, 1960. ISBN 9780070609259. Disponível em: <<https://books.google.com.br/books?id=o6FpAAAAMAAJ>>.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. 1st. ed. Berlin, Heidelberg: Springer-Verlag, 2010. ISBN 1848829345.

_____. **Computer Vision: Algorithms and Applications**. [S.l.]: Springer, 2010.

WANG, T. et al. Rotational speed measurement through image similarity evaluation and spectral analysis. **IEEE Access**, v. 6, p. 46718–46730, 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8443343>>.

WANG, Y.; WANG, L.; YAN, Y. Rotational speed measurement through digital imaging and image processing. p. 1–6, 2017. Disponível em: <<https://ieeexplore.ieee.org/document/7969697>>.

WARRIER, A. N.; AMURU, S. How to choose a neural network architecture? – a modulation classification example. In: **2020 IEEE 3rd 5G World Forum (5GWF)**. [S.l.: s.n.], 2020. p. 413–417.

WINSTON, P. H. **Artificial Intelligence (3rd Ed.)**. USA: Addison-Wesley Longman Publishing Co., Inc., 1992. ISBN 0201533774.

YACHIDA; TSUJI. A versatile machine vision system for complex industrial parts. **IEEE Transactions on Computers**, C-26, n. 9, p. 882–894, 1977. Disponível em: <<https://ieeexplore.ieee.org/document/1674936>>.

ZHAO, G. et al. High speed rotation estimation with dynamic vision sensors. 2022. Disponível em: <<https://arxiv.org/abs/2209.02205>>.

ZHOU, Y. et al. Rotational speed measurement based on lc wireless sensors. **Sensors**, v. 21, n. 23, 2021. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/21/23/8055>>.

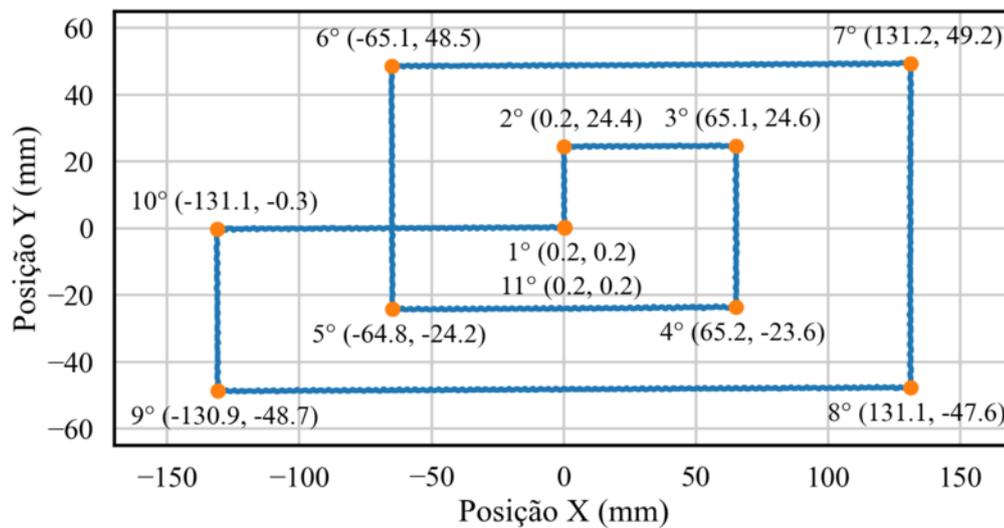
Apêndices

APÊNDICE A

Gráficos - Experimento 2: Posição Linear

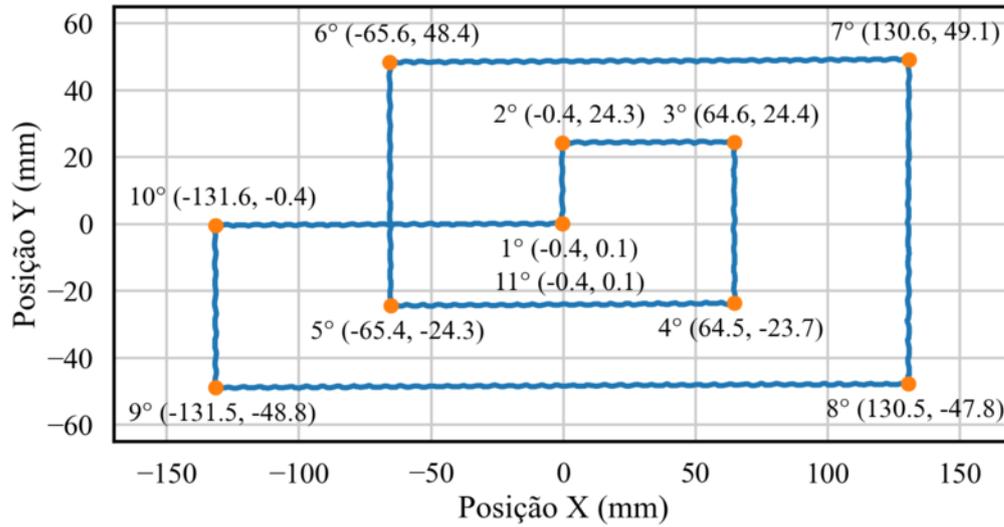
A.1 Gráficos de Deslocamento no plano XY

Figura 67 – Deslocamento Estimado para Configuração 1



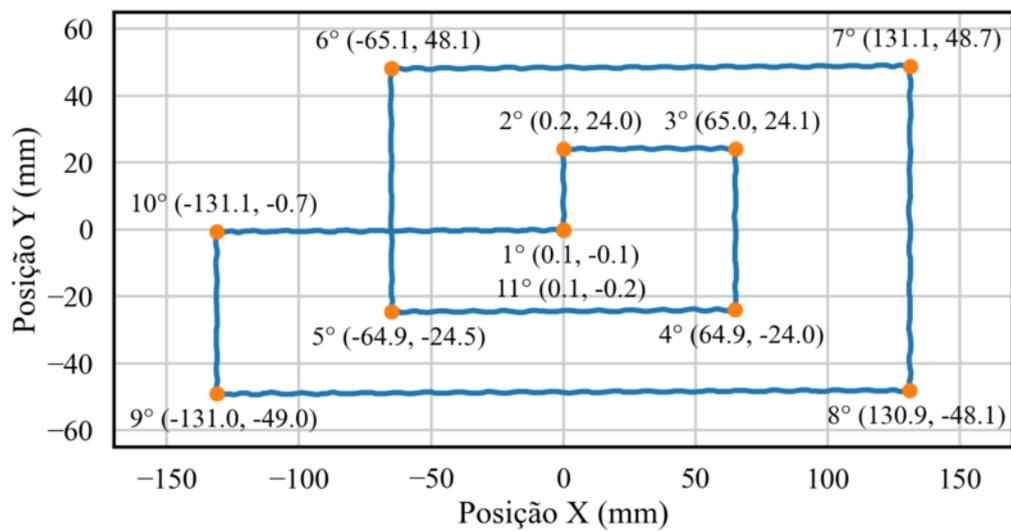
Fonte: Autor

Figura 68 – Deslocamento Estimado para Configuração 2



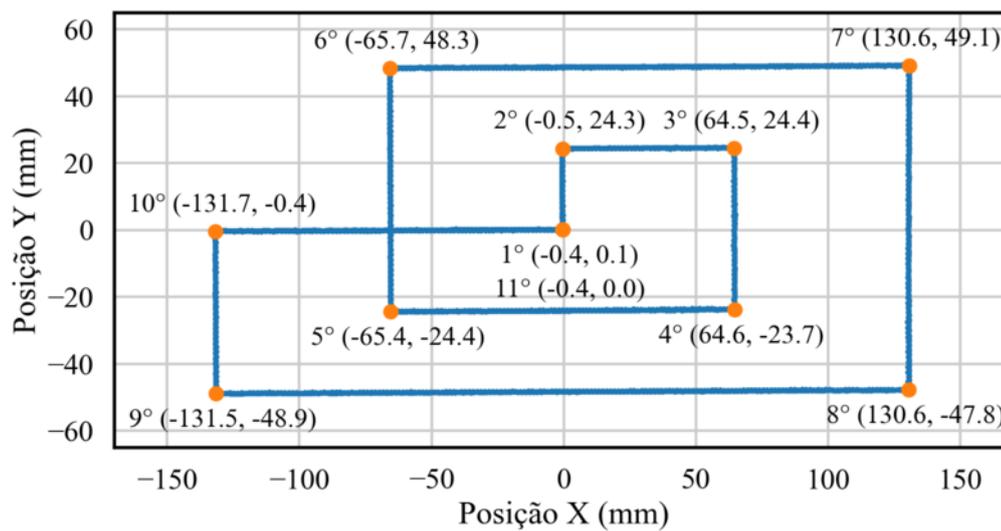
Fonte: Autor

Figura 69 – Deslocamento Estimado para Configuração 3



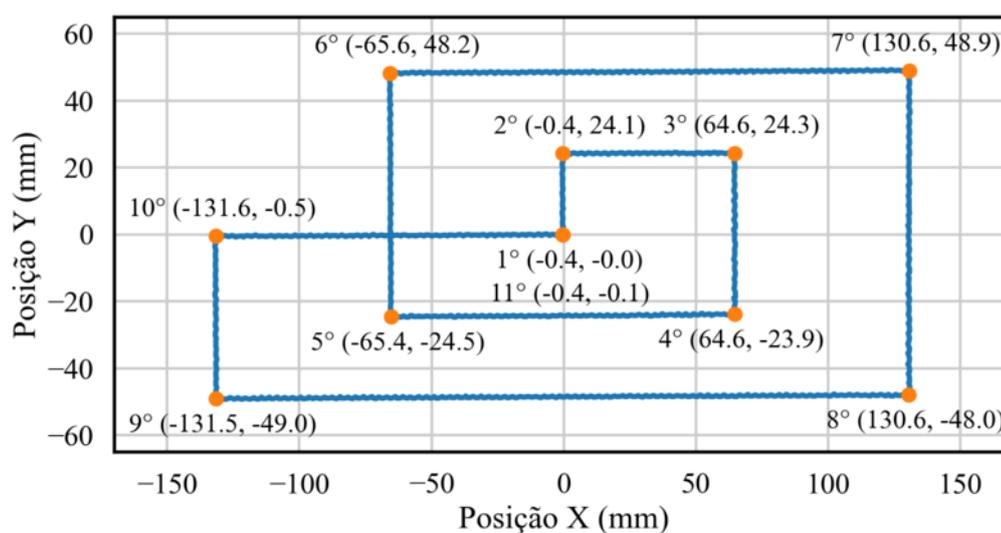
Fonte: Autor

Figura 70 – Deslocamento Estimado para Configuração 3



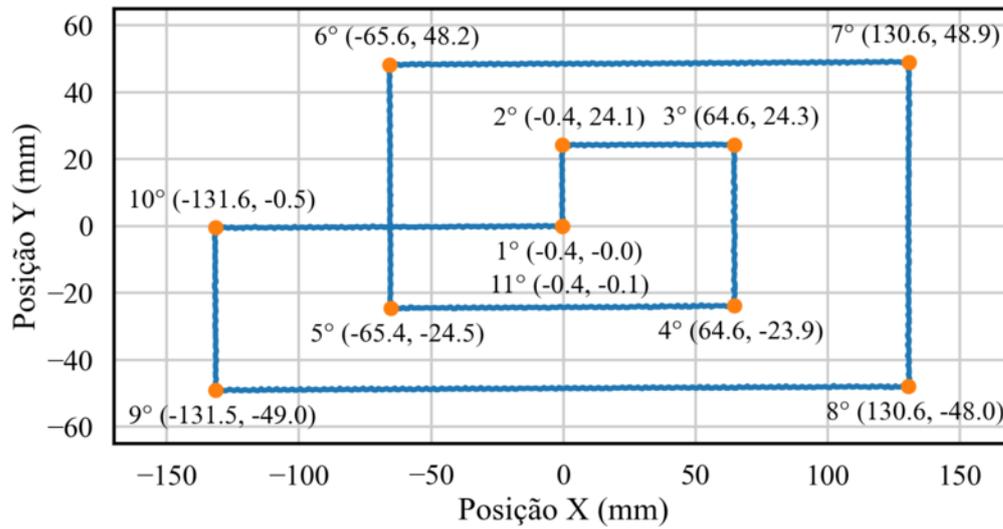
Fonte: Autor

Figura 71 – Deslocamento Estimado para Configuração 4



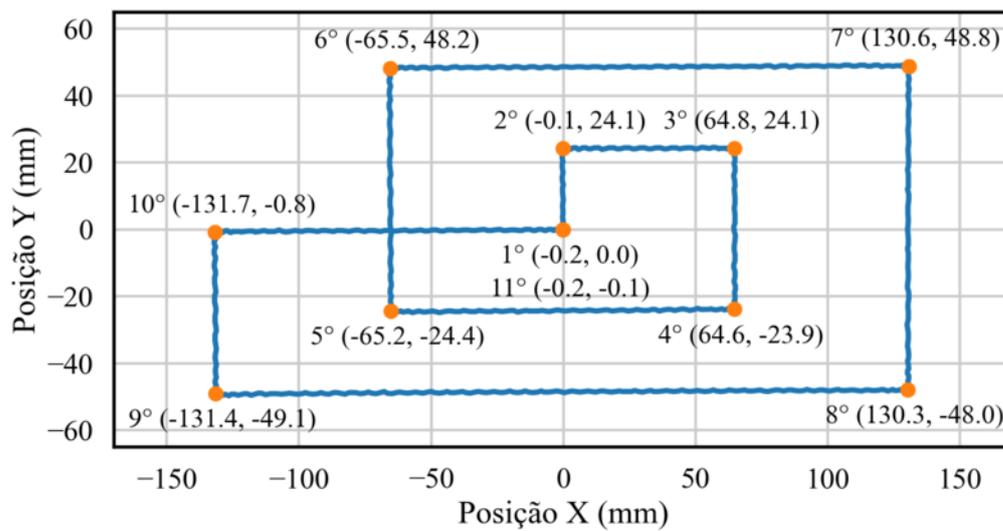
Fonte: Autor

Figura 72 – Deslocamento Estimado para Configuração 5



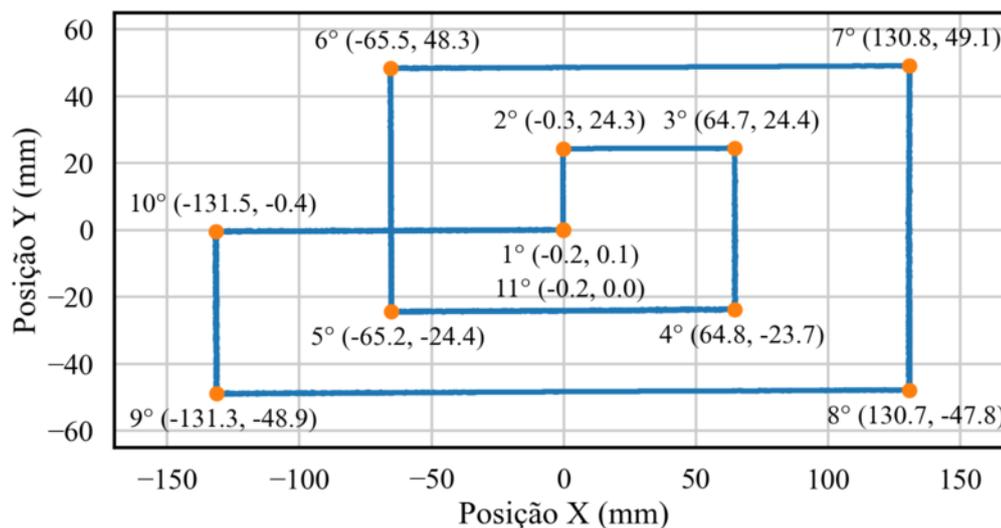
Fonte: Autor

Figura 73 – Deslocamento Estimado para Configuração 6



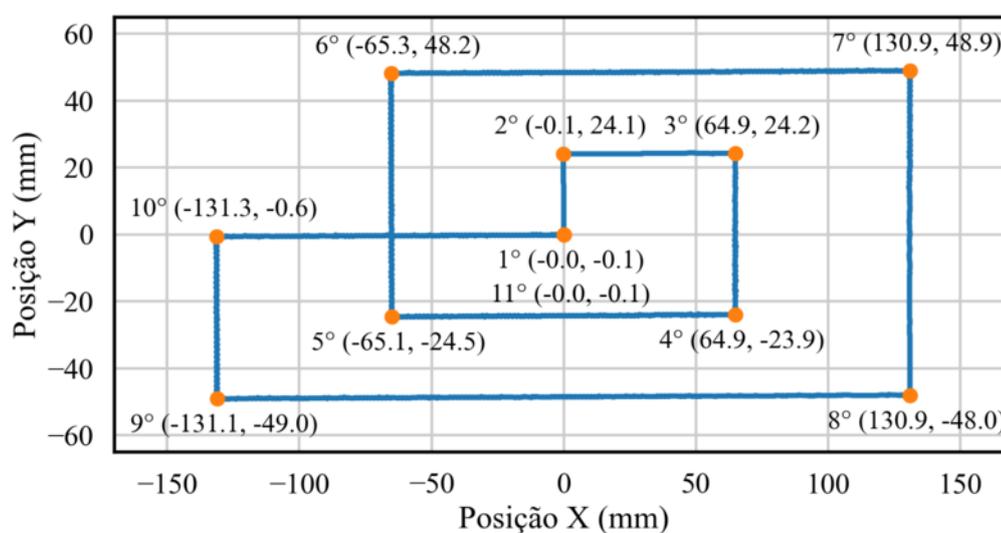
Fonte: Autor

Figura 74 – Deslocamento Estimado para Configuração 7



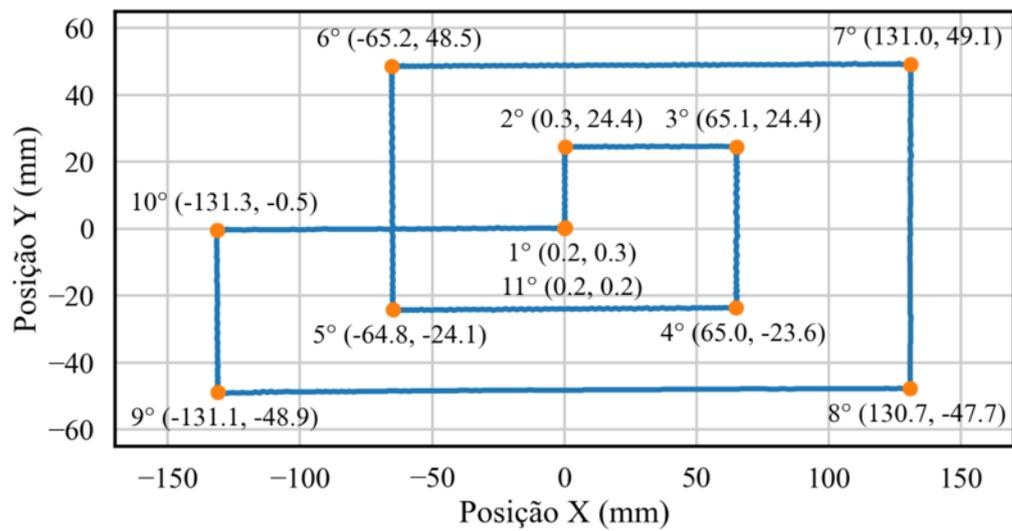
Fonte: Autor

Figura 75 – Deslocamento Estimado para Configuração 8



Fonte: Autor

Figura 76 – Deslocamento Estimado para Configuração 9



Fonte: Autor

APÊNDICE B

Gráficos - Experimento 1:

**Velocidade Angular e Configuração
de Câmera**

B.1 Gráficos de Velocidade

Figura 77 – Perfil de Velocidade - Configuração 1

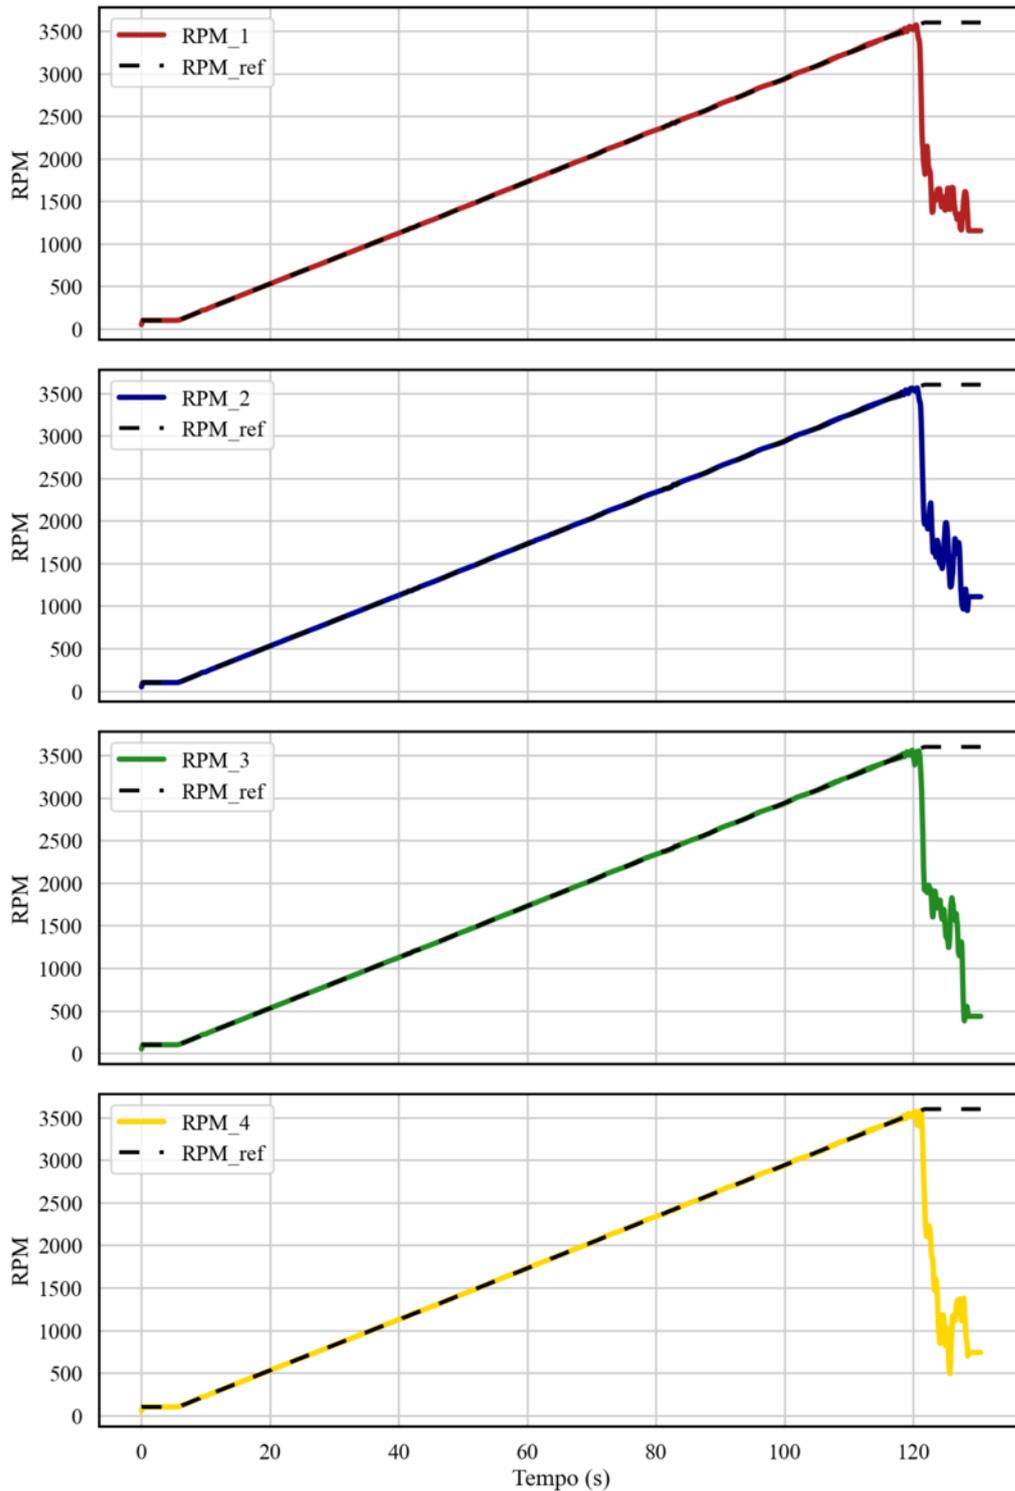
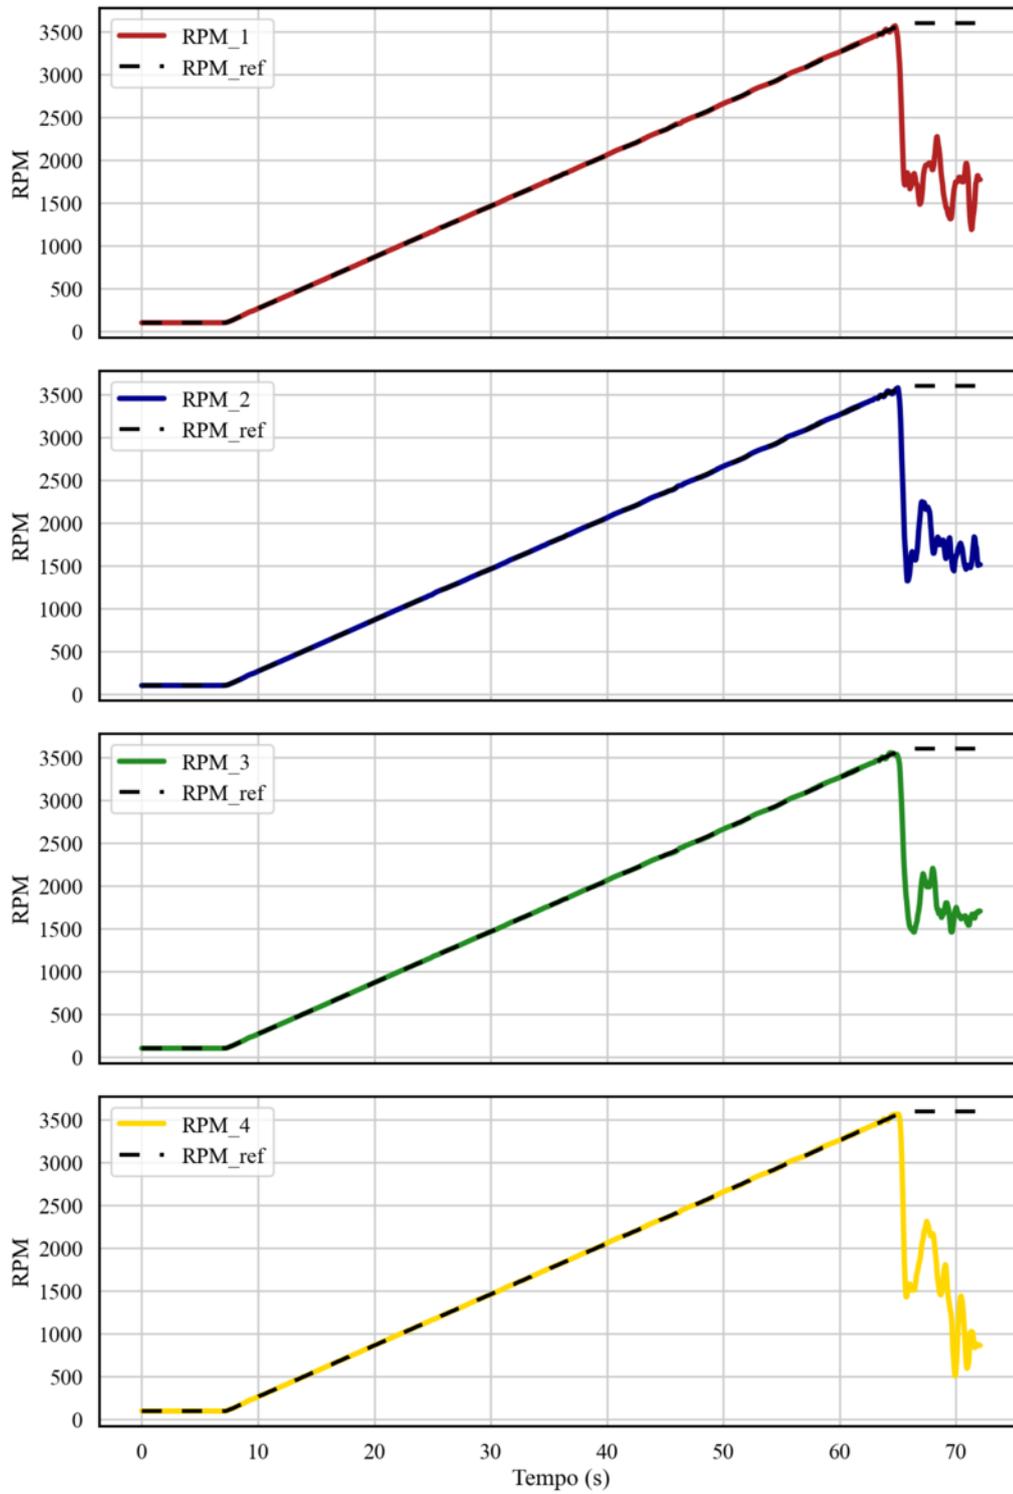
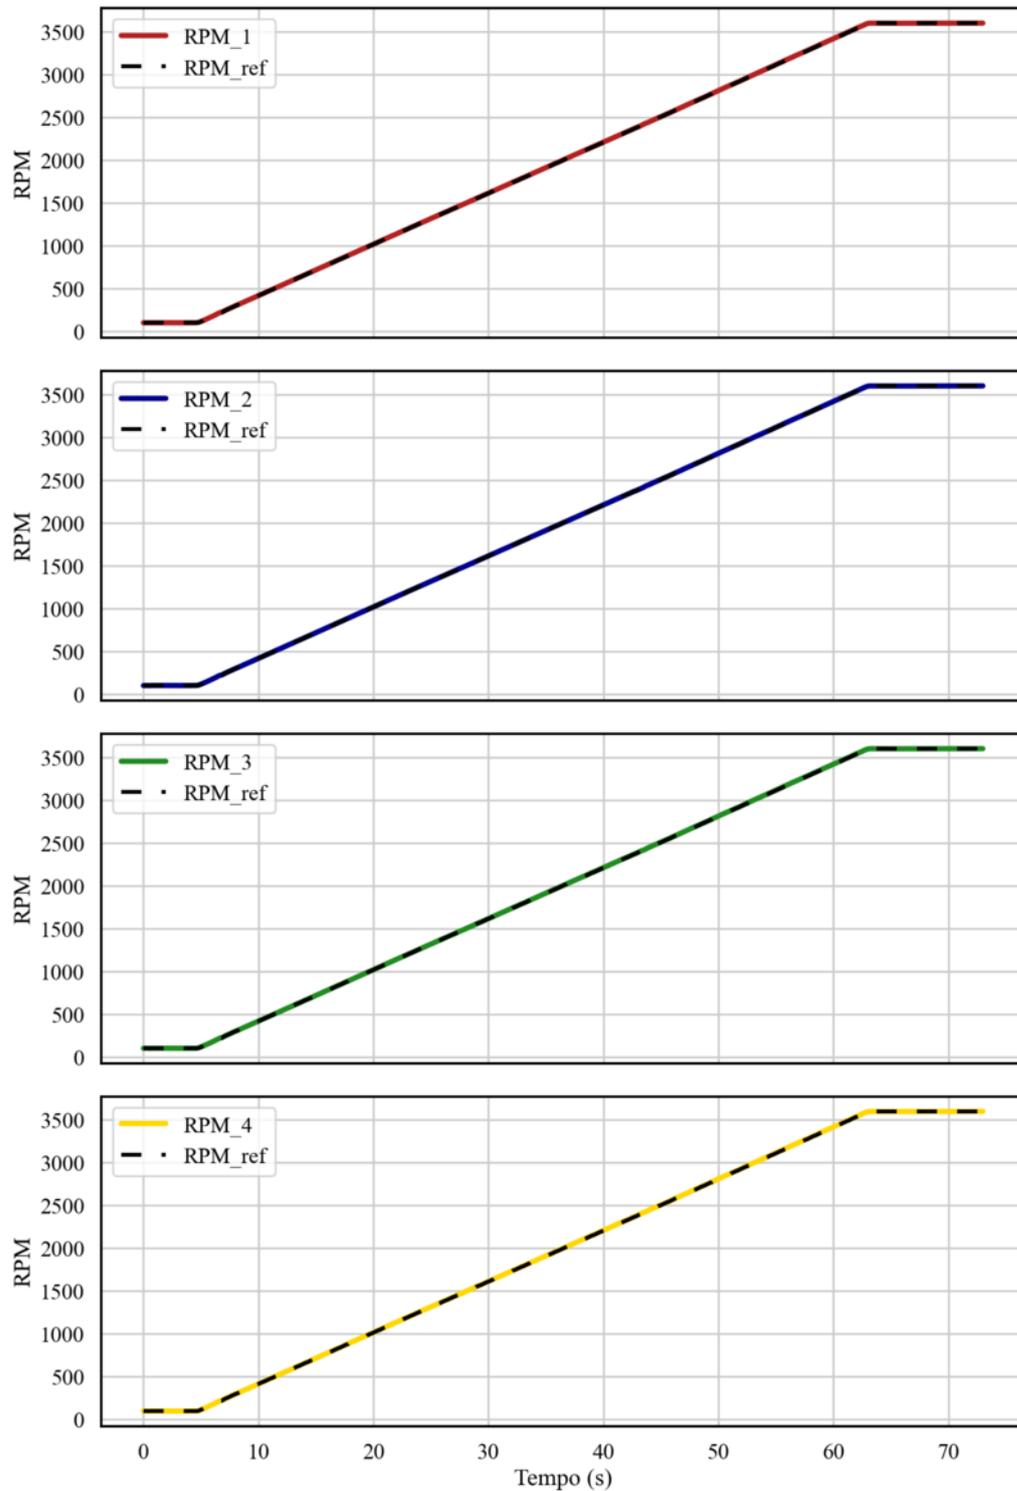


Figura 78 – Perfil de Velocidade - Configuração 2



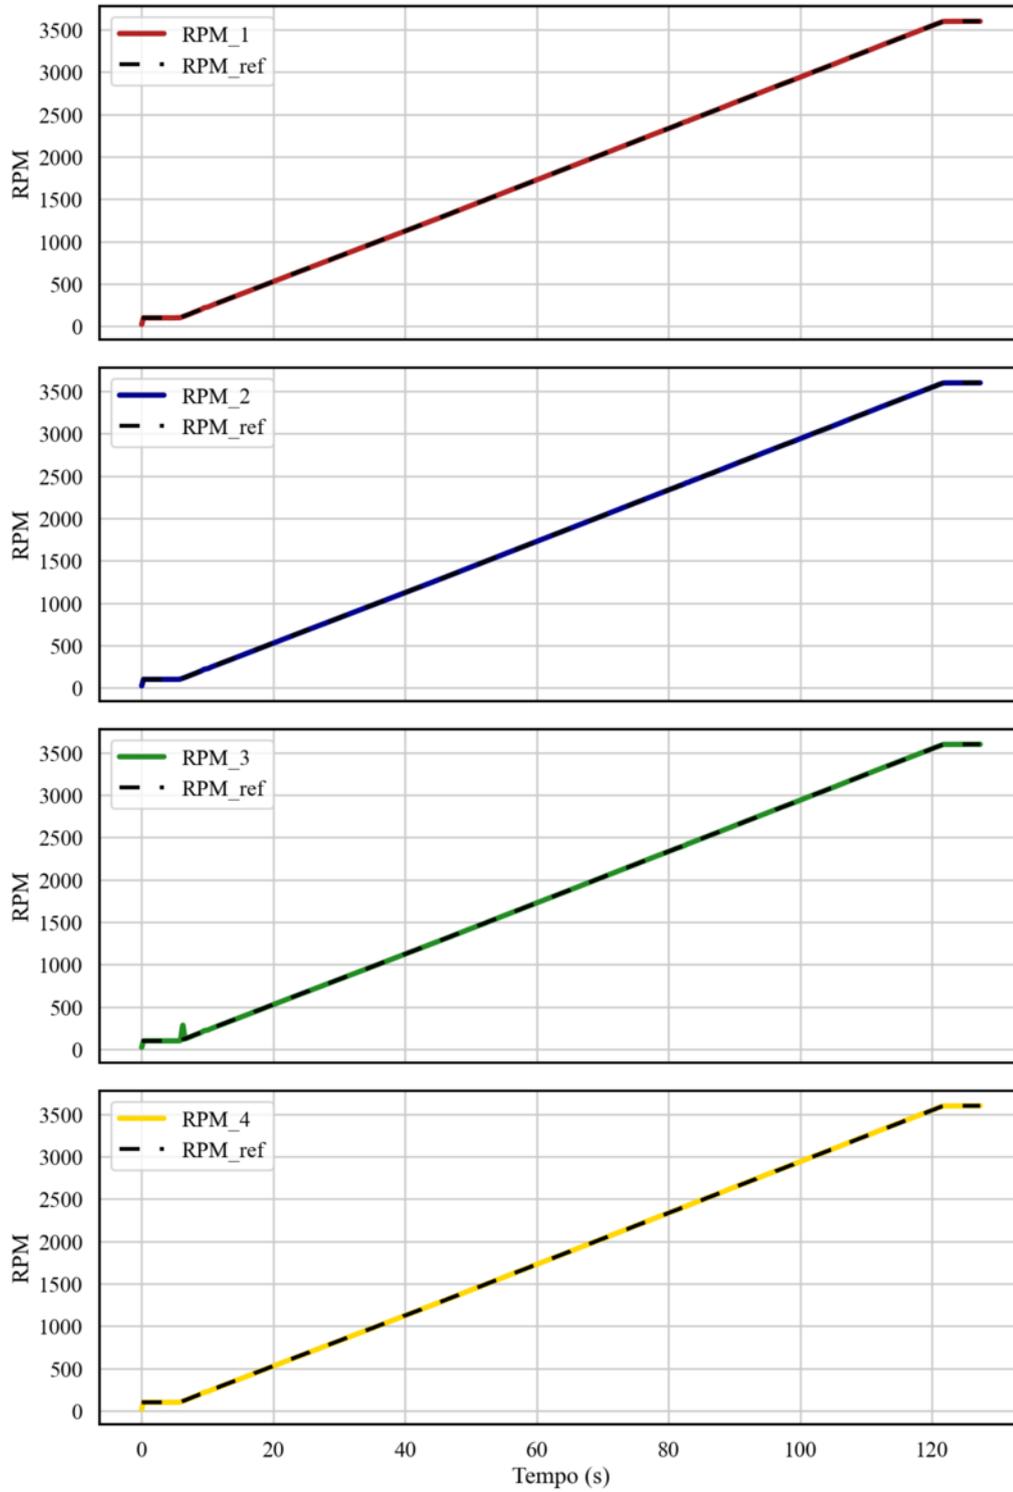
Fonte: Autor

Figura 79 – Perfil de Velocidade - Configuração 3



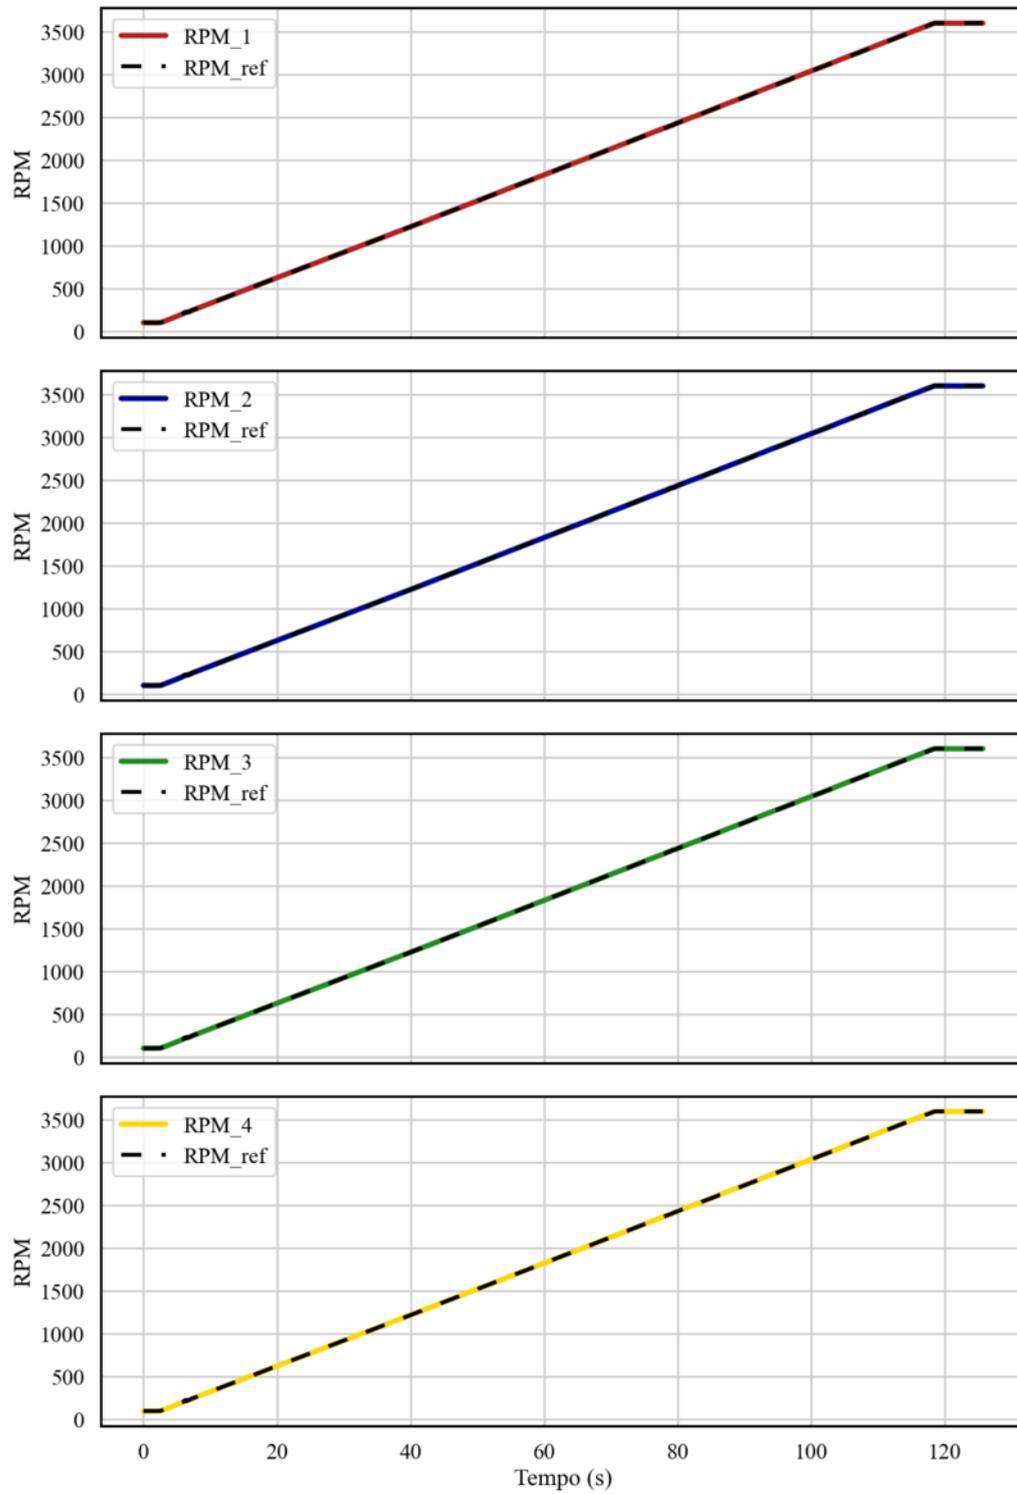
Fonte: Autor

Figura 80 – Perfil de Velocidade - Configuração 4



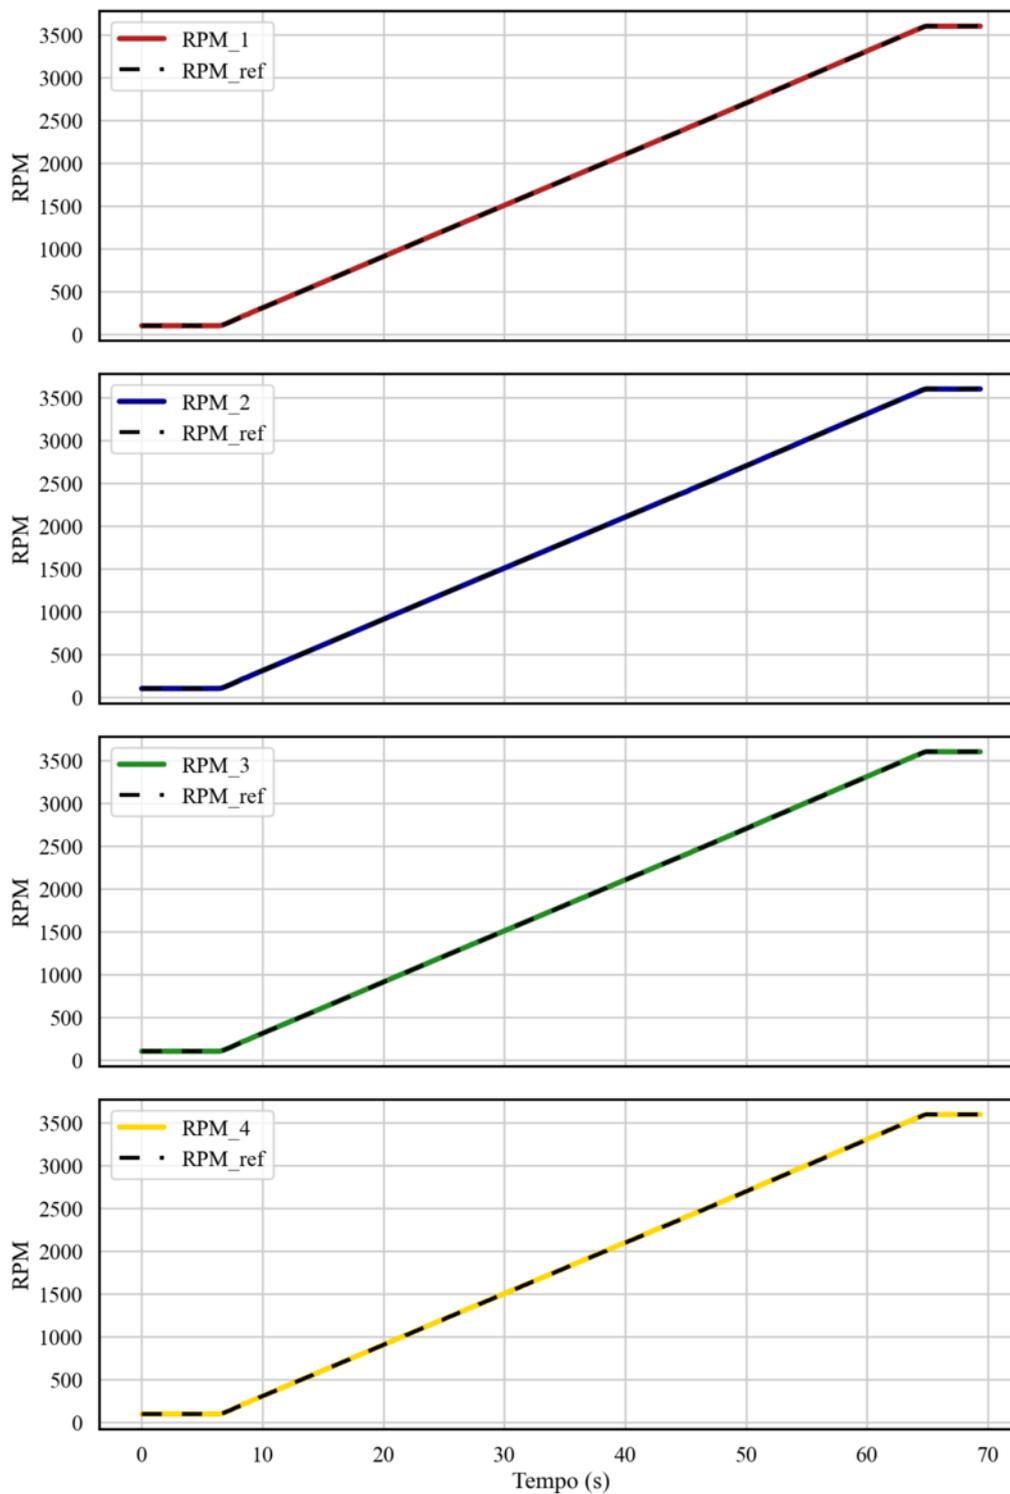
Fonte: Autor

Figura 81 – Perfil de Velocidade - Configuração 5



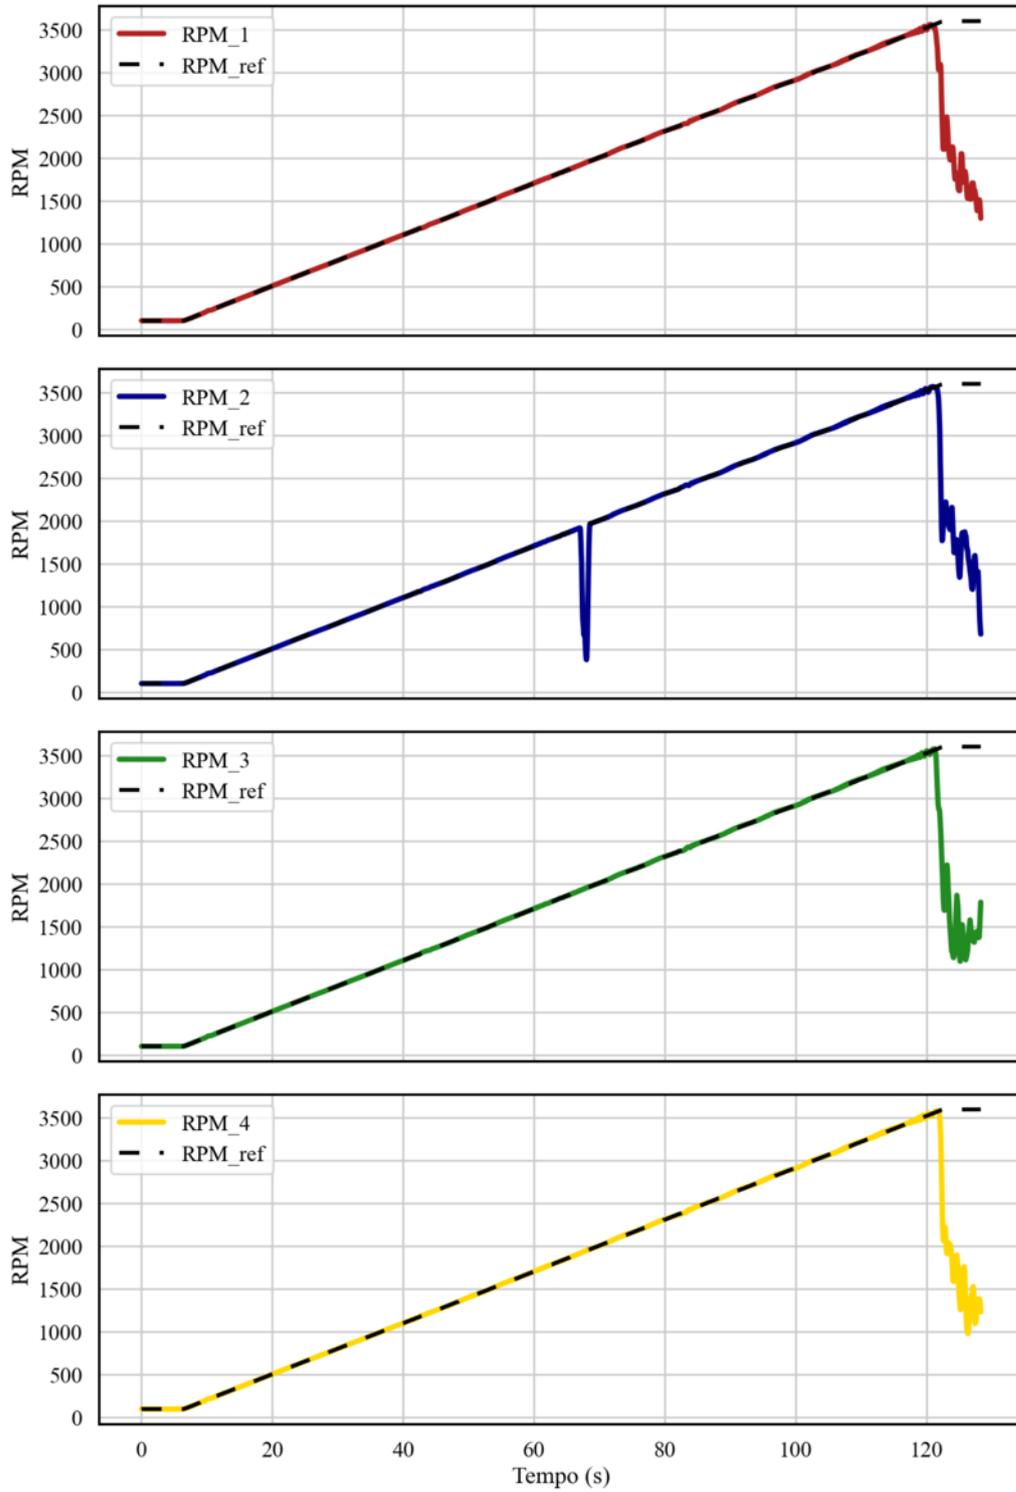
Fonte: Autor

Figura 82 – Perfil de Velocidade - Configuração 6



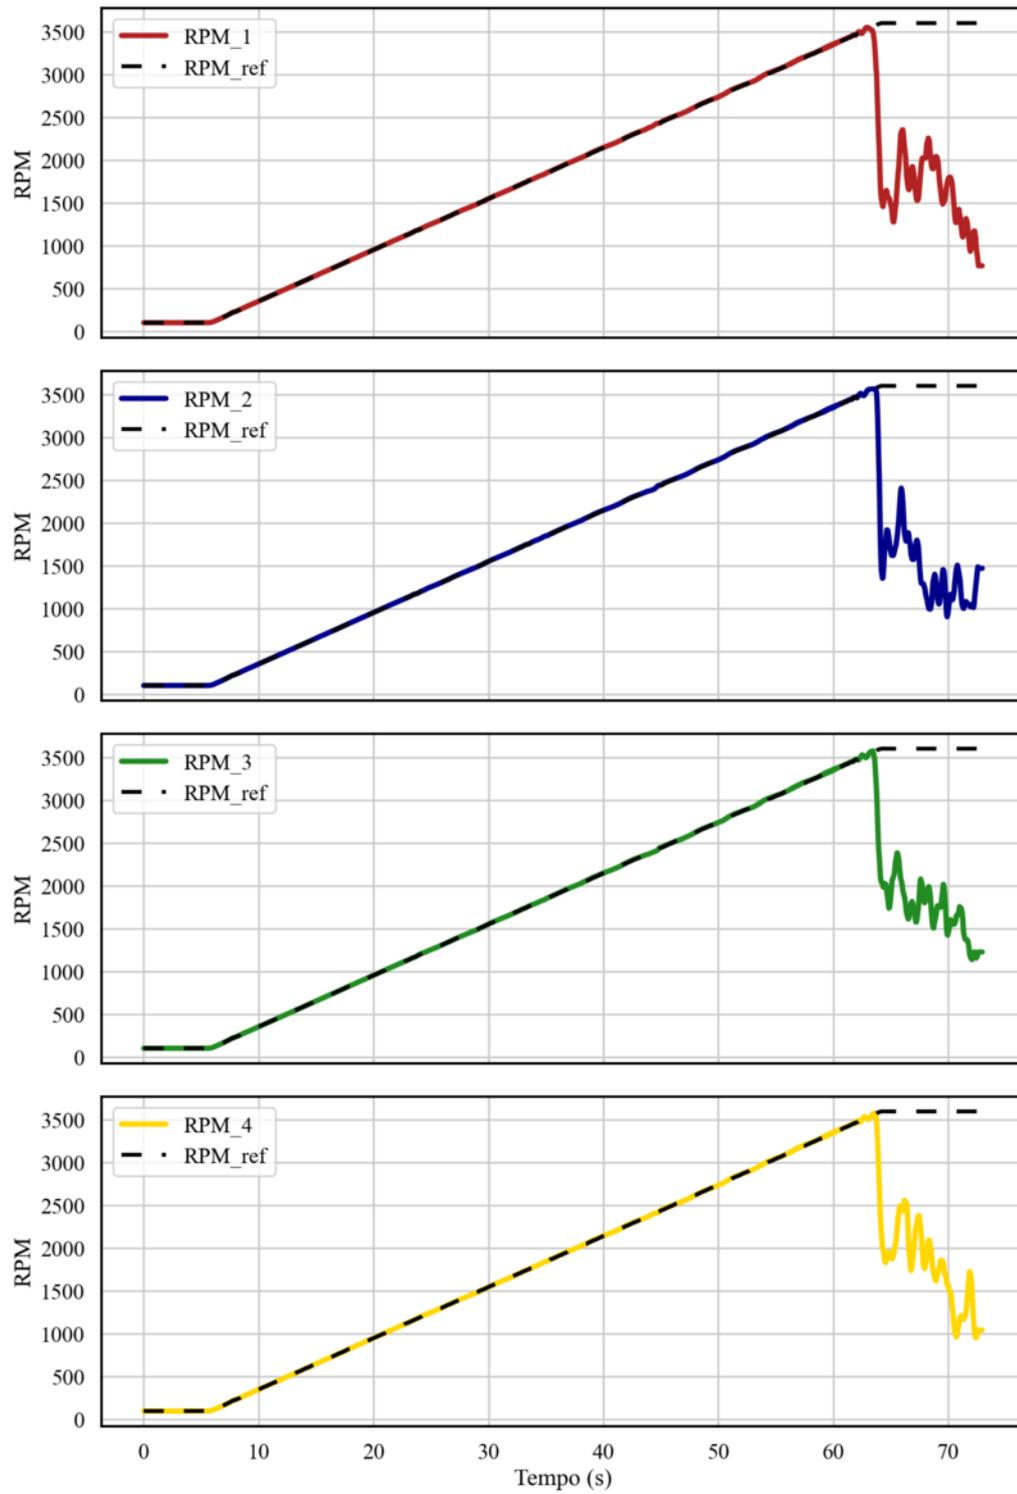
Fonte: Autor

Figura 83 – Perfil de Velocidade - Configuração 7



Fonte: Autor

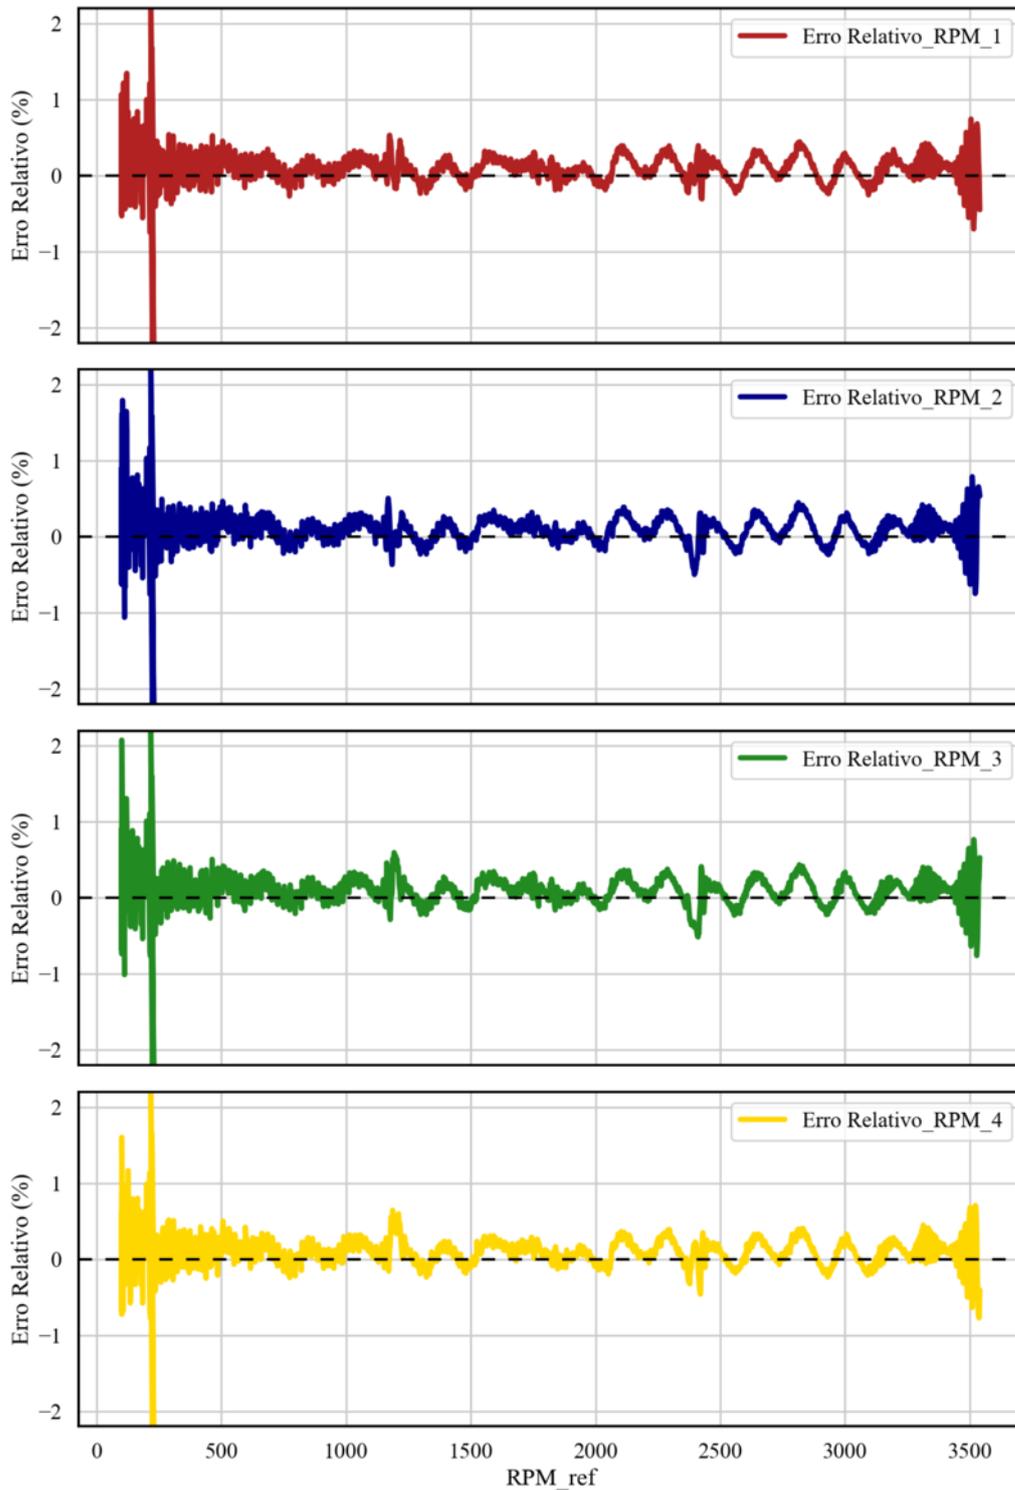
Figura 84 – Perfil de Velocidade - Configuração 8



Fonte: Autor

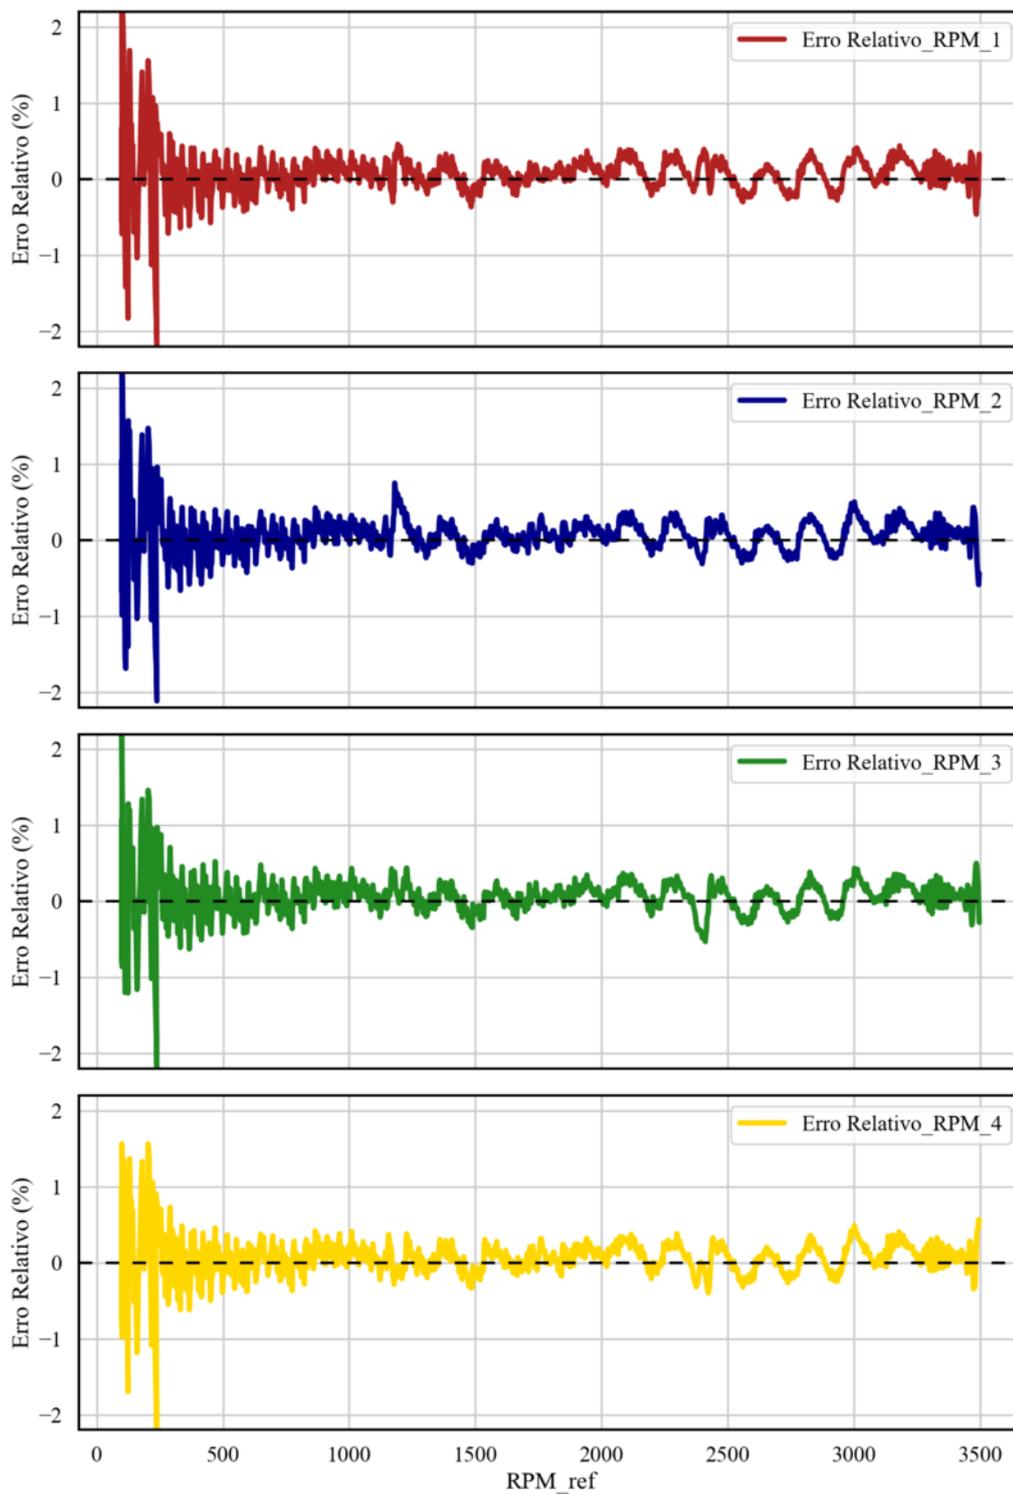
B.2 Gráficos de Erro Relativo

Figura 85 – Erro Relativo - Configuração 1



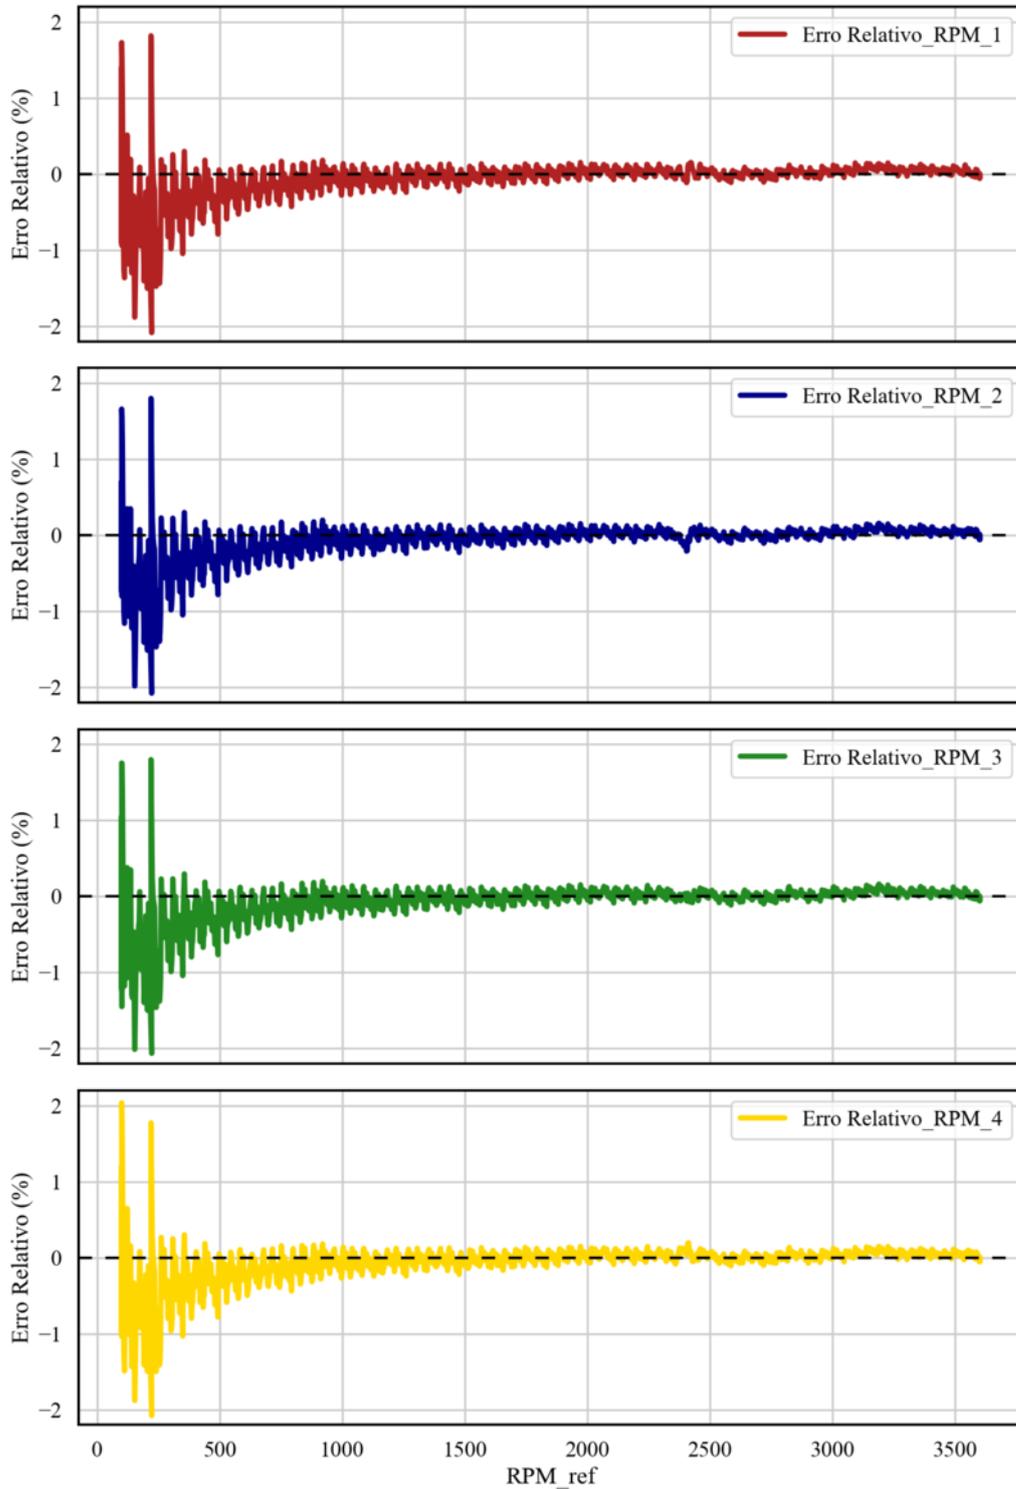
Fonte: Autor

Figura 86 – Erro Relativo - Configuração 2



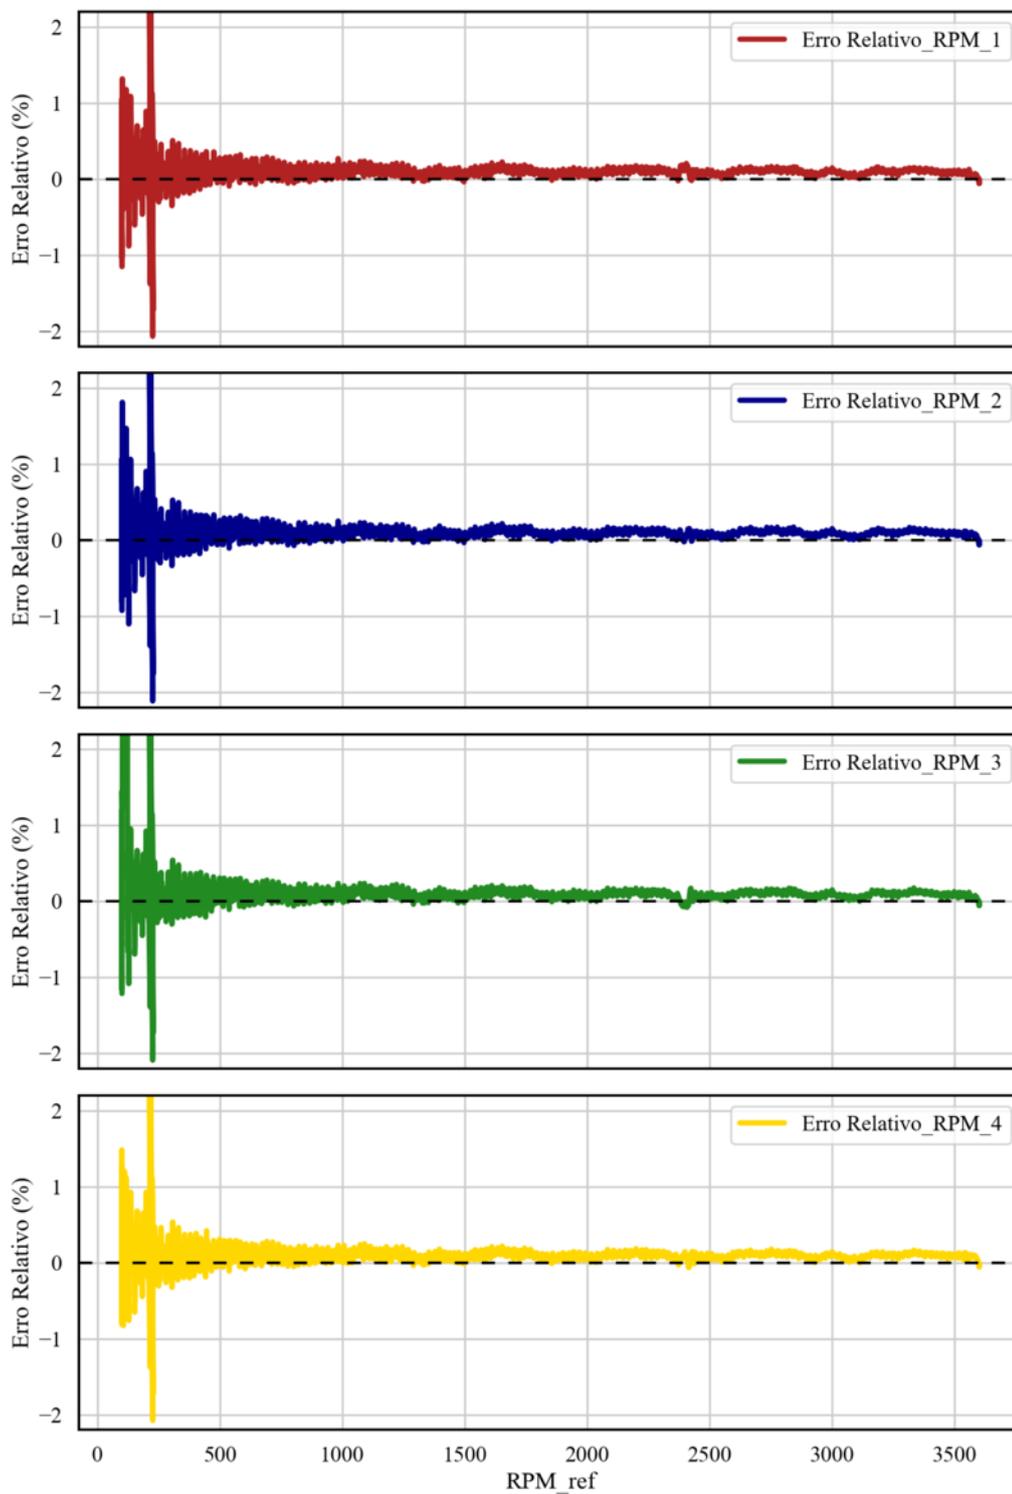
Fonte: Autor

Figura 87 – Erro Relativo - Configuração 3



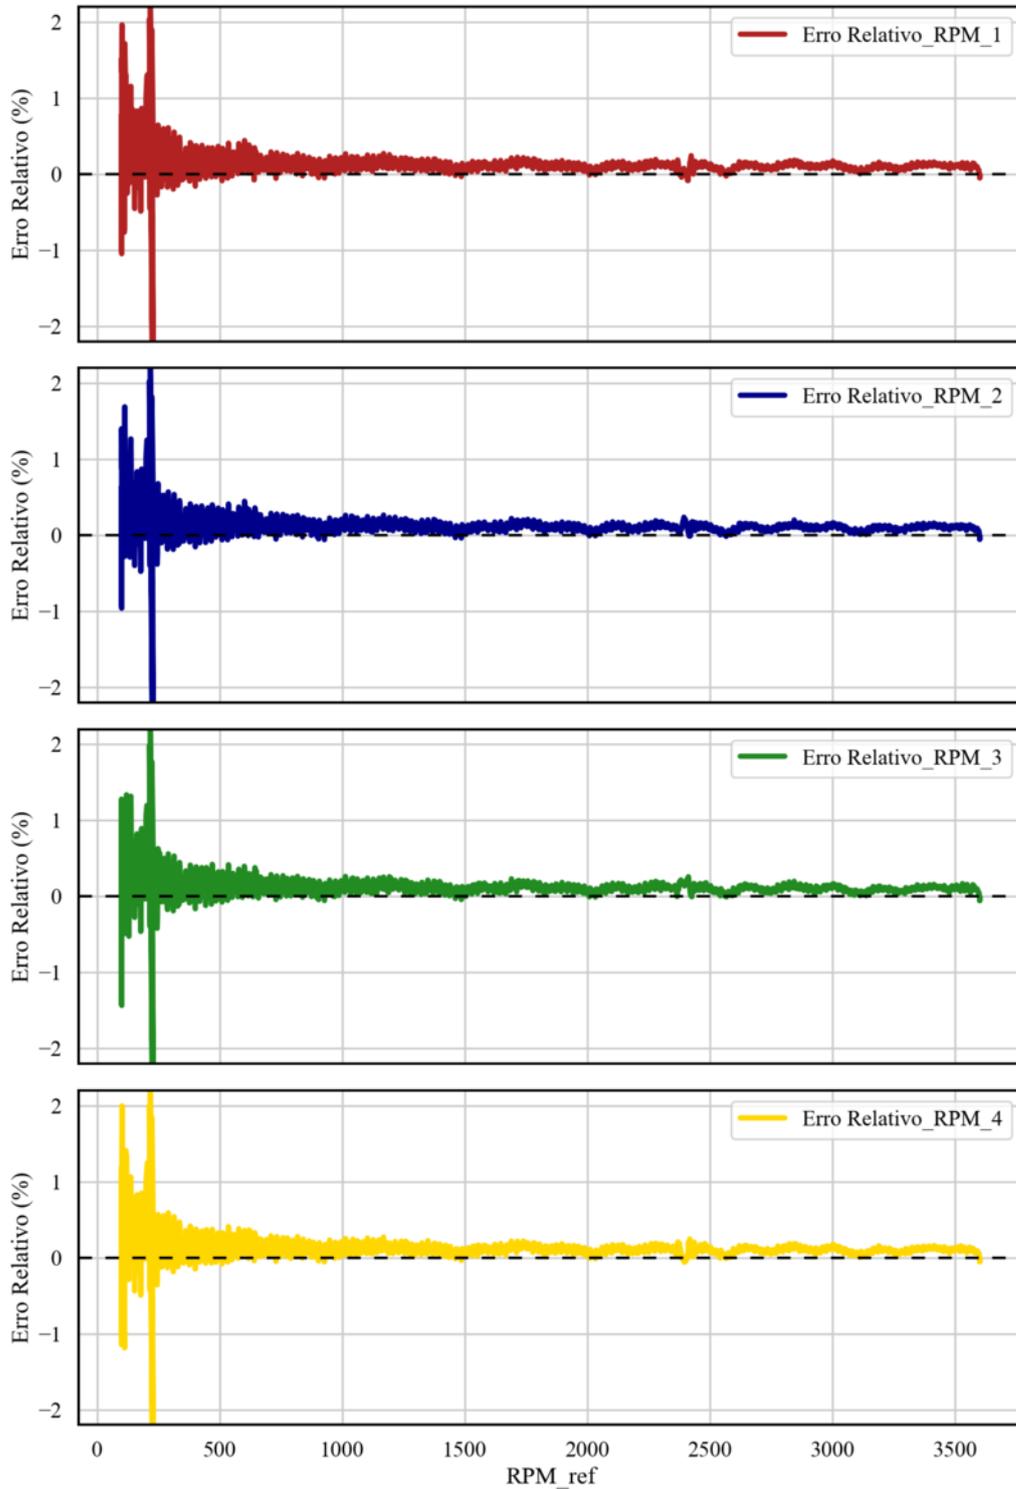
Fonte: Autor

Figura 88 – Erro Relativo - Configuração 4



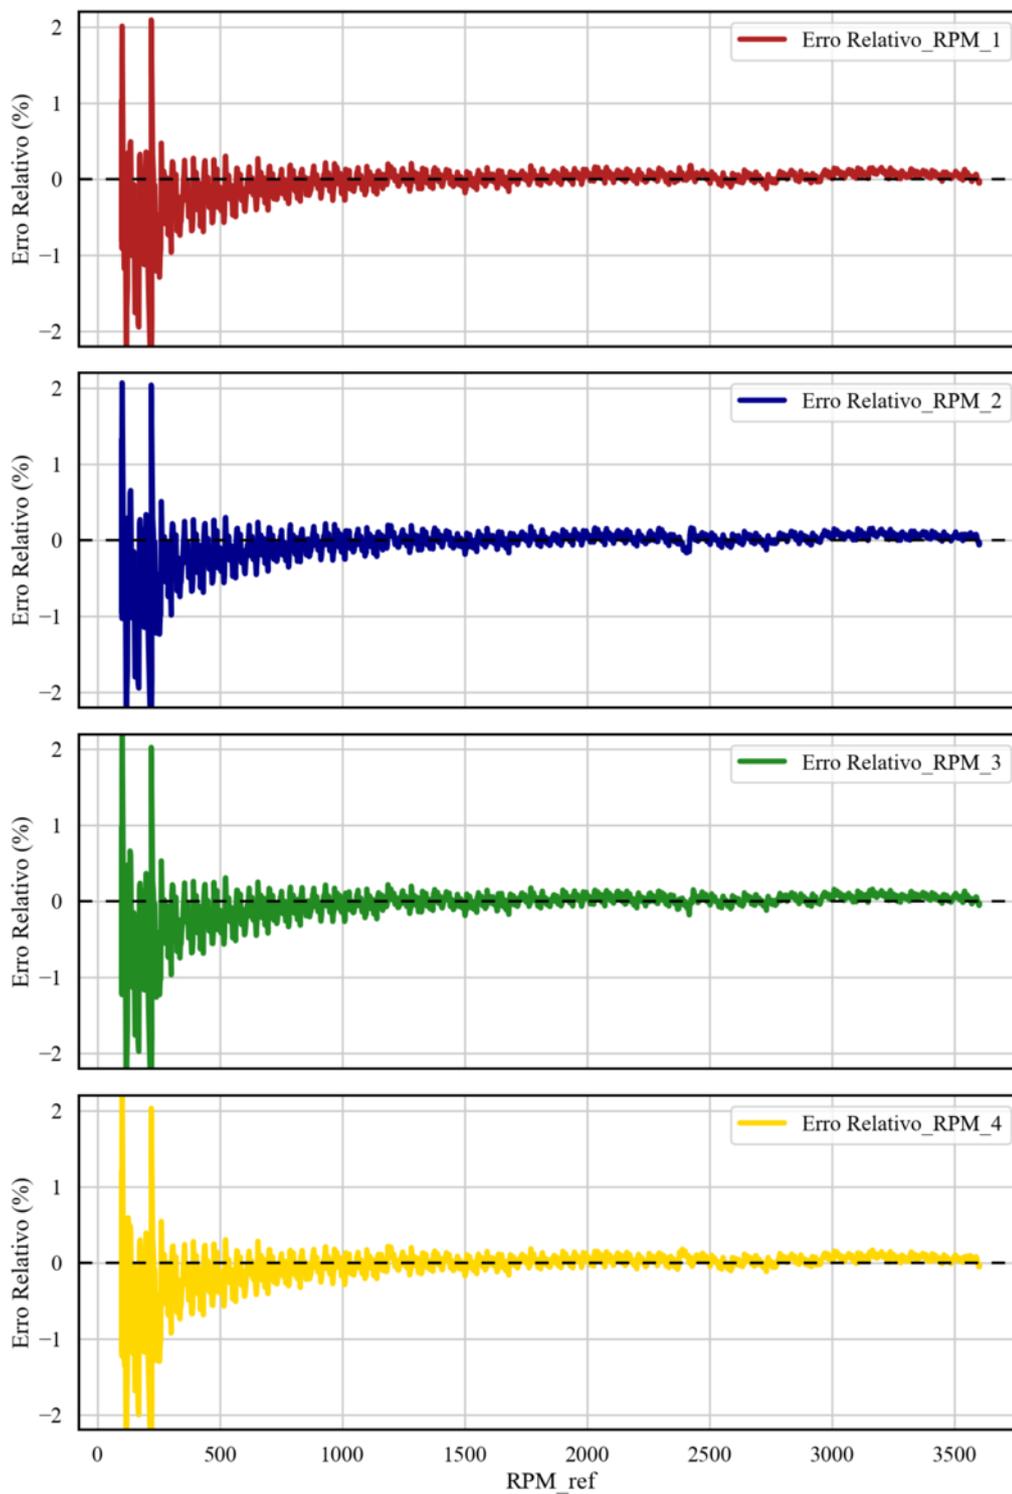
Fonte: Autor

Figura 89 – Erro Relativo - Configuração 5



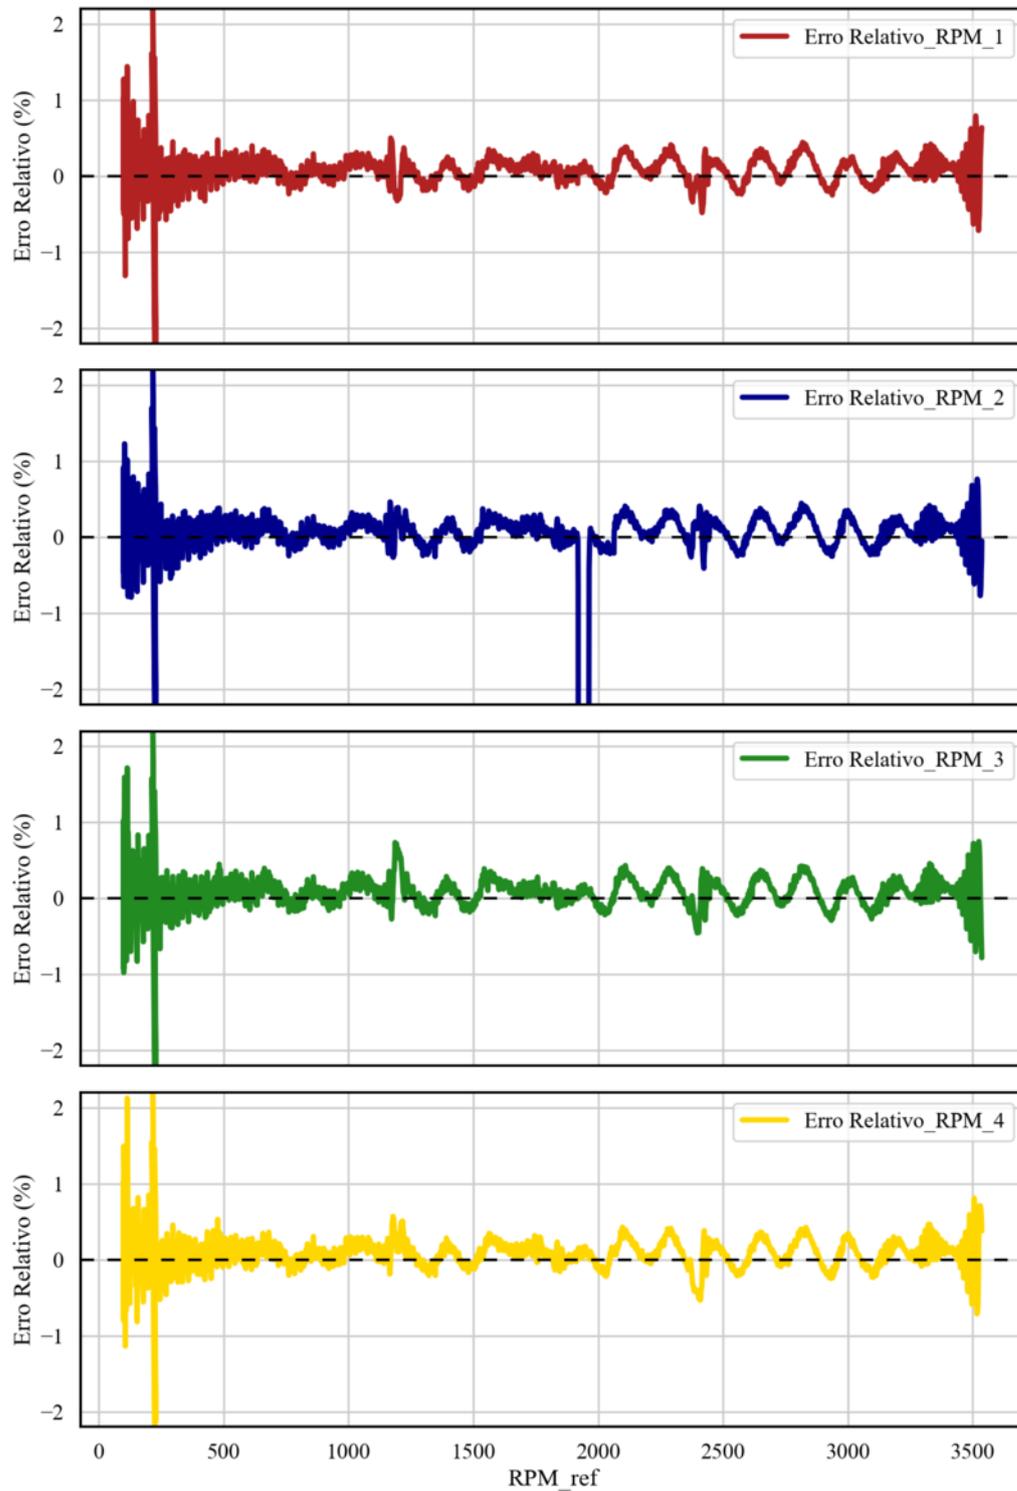
Fonte: Autor

Figura 90 – Erro Relativo - Configuração 6



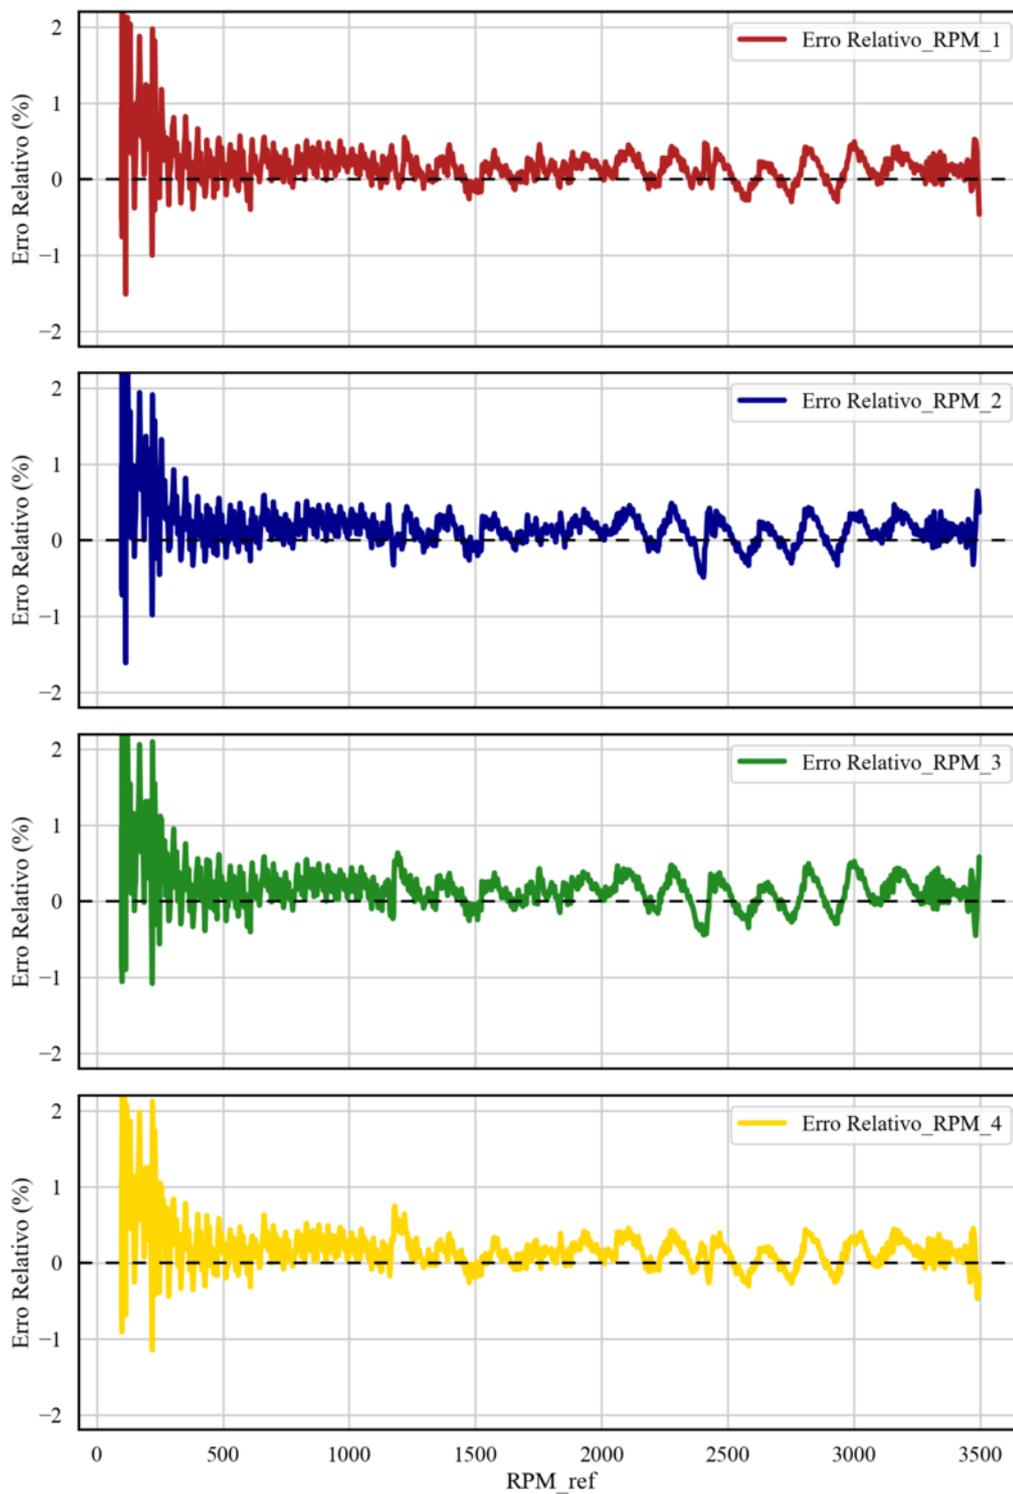
Fonte: Autor

Figura 91 – Erro Relativo - Configuração 7



Fonte: Autor

Figura 92 – Erro Relativo - Configuração 8

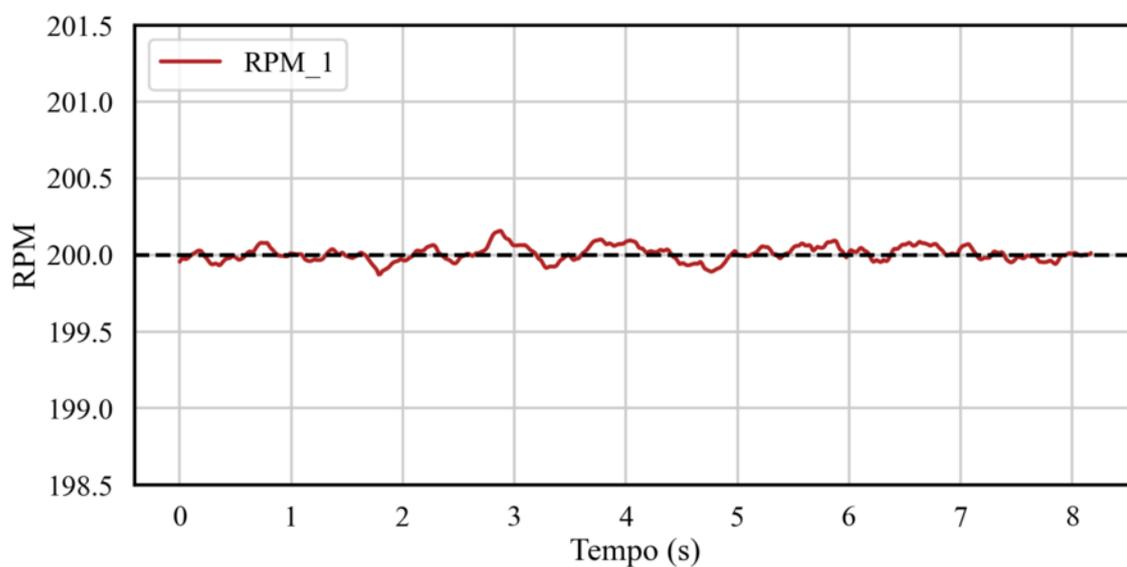


Fonte: Autor

APÊNDICE C

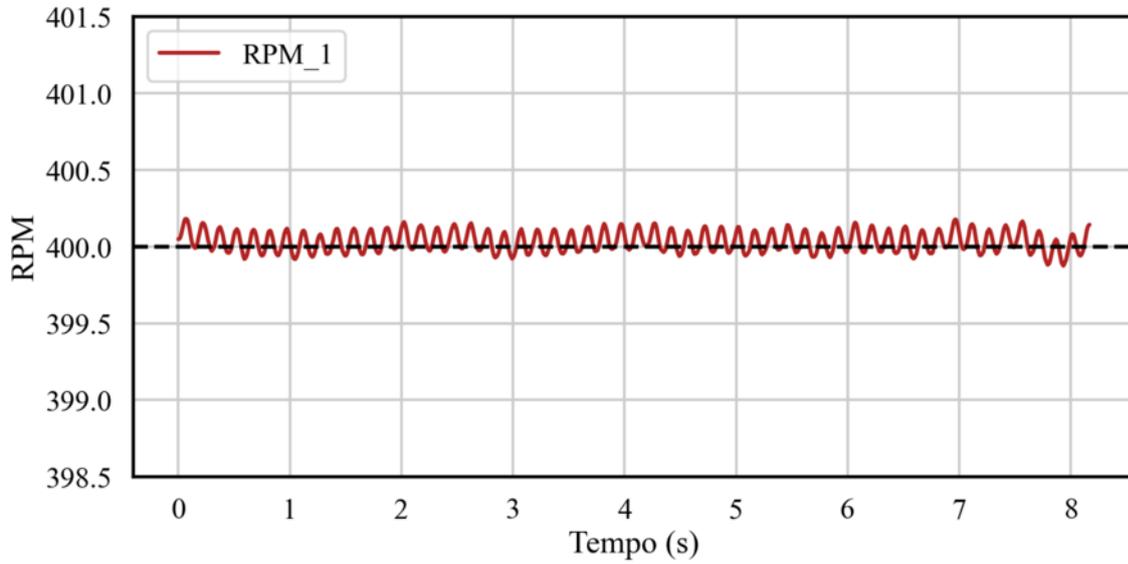
Gráficos - Experimento 3: Estabilidade

Figura 93 – Medidas de Velocidade em 200 RPM



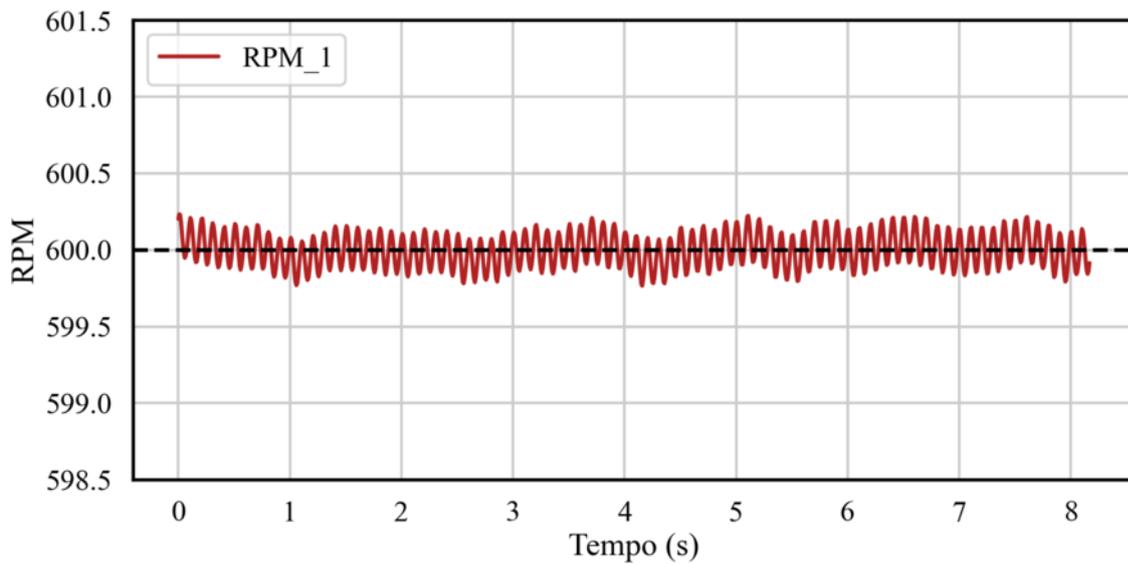
Fonte: Autor

Figura 94 – Medidas de Velocidade em 400 RPM



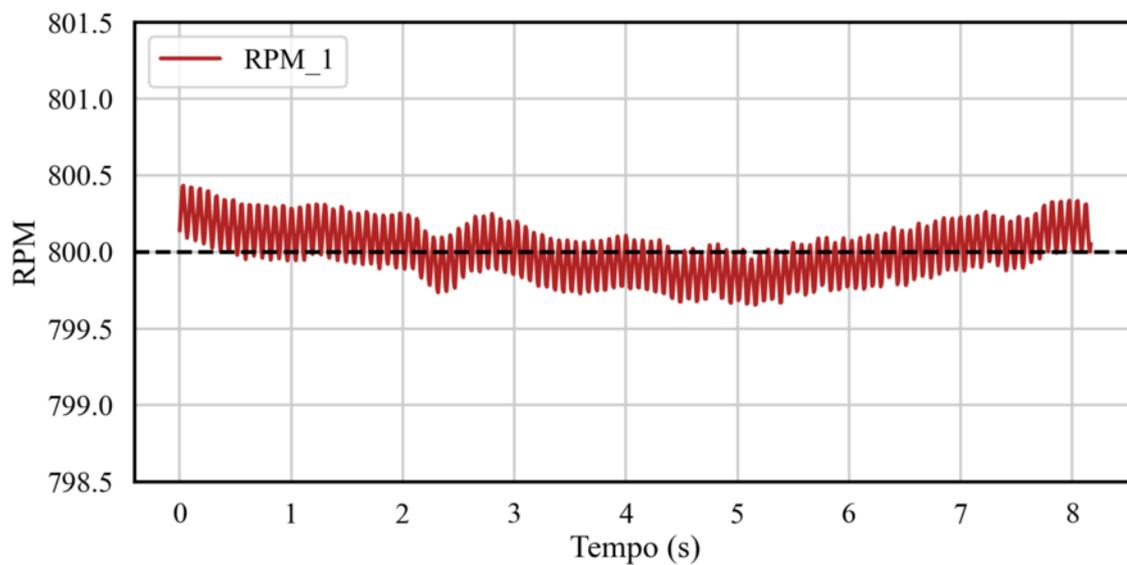
Fonte: Autor

Figura 95 – Medidas de Velocidade em 600 RPM



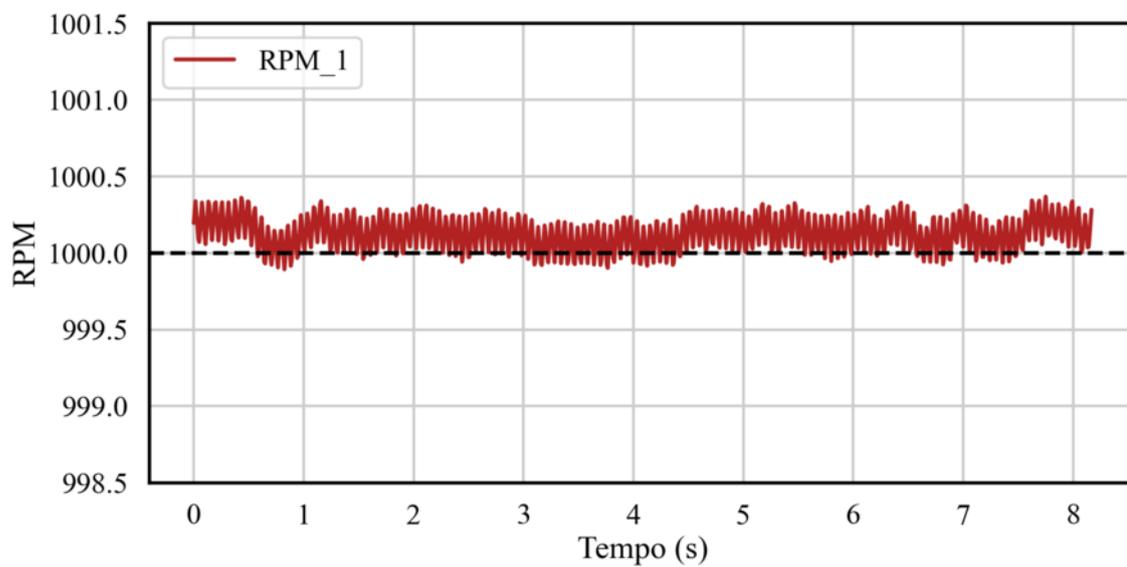
Fonte: Autor

Figura 96 – Medidas de Velocidade em 800 RPM



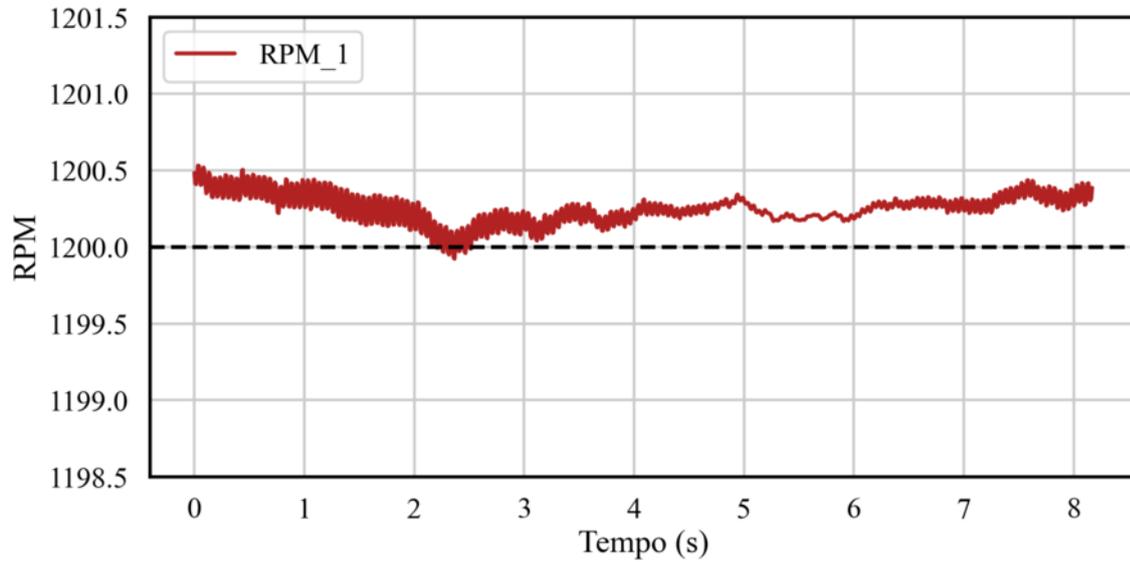
Fonte: Autor

Figura 97 – Medidas de Velocidade em 1000 RPM



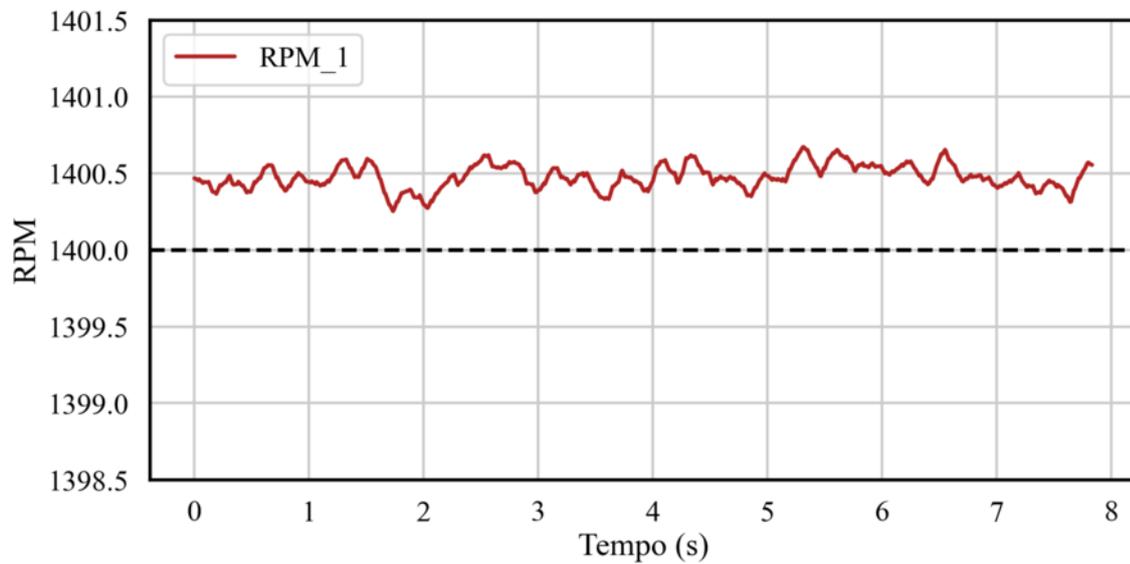
Fonte: Autor

Figura 98 – Medidas de Velocidade em 1200 RPM



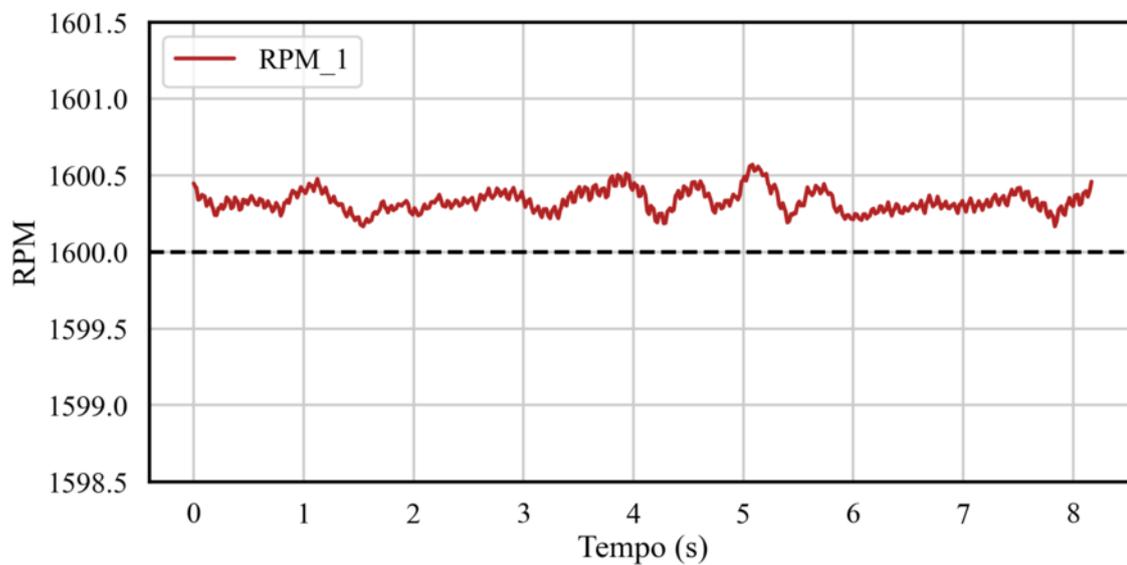
Fonte: Autor

Figura 99 – Medidas de Velocidade em 1400 RPM



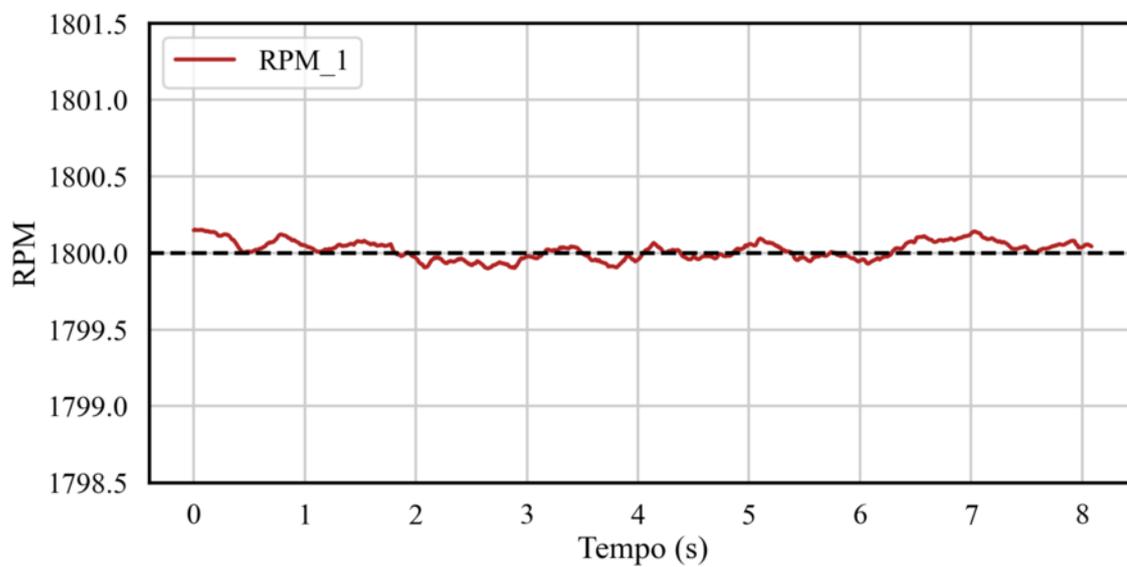
Fonte: Autor

Figura 100 – Medidas de Velocidade em 1600 RPM



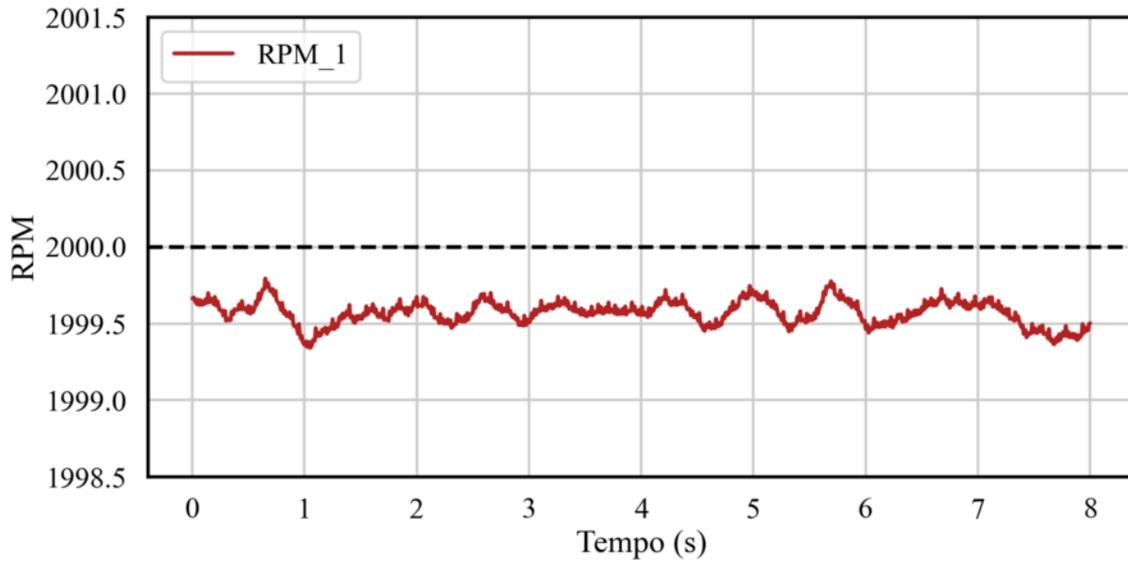
Fonte: Autor

Figura 101 – Medidas de Velocidade em 1800 RPM



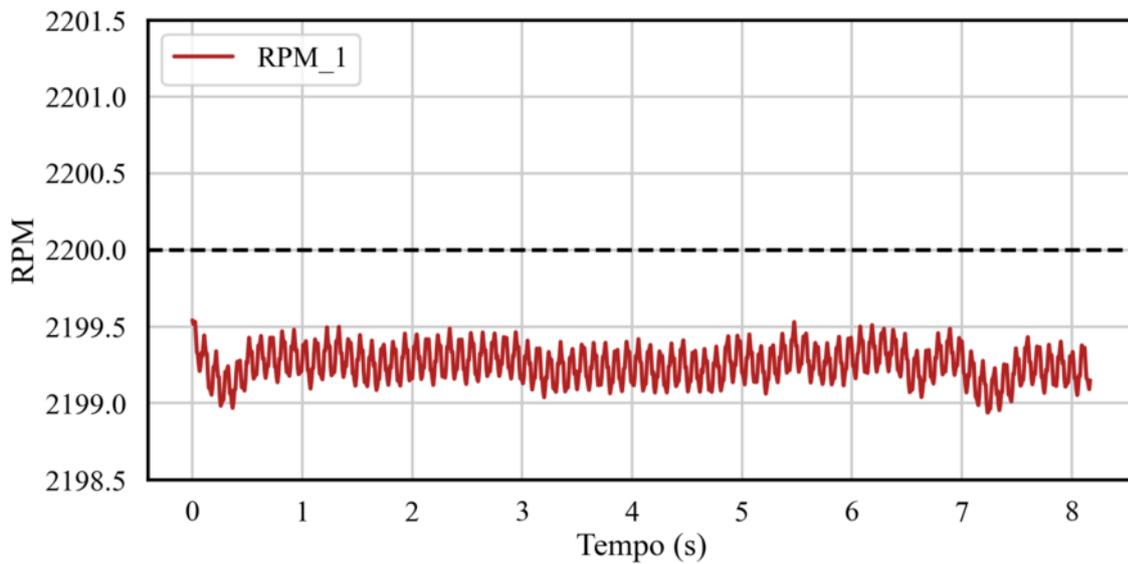
Fonte: Autor

Figura 102 – Medidas de Velocidade em 2000 RPM



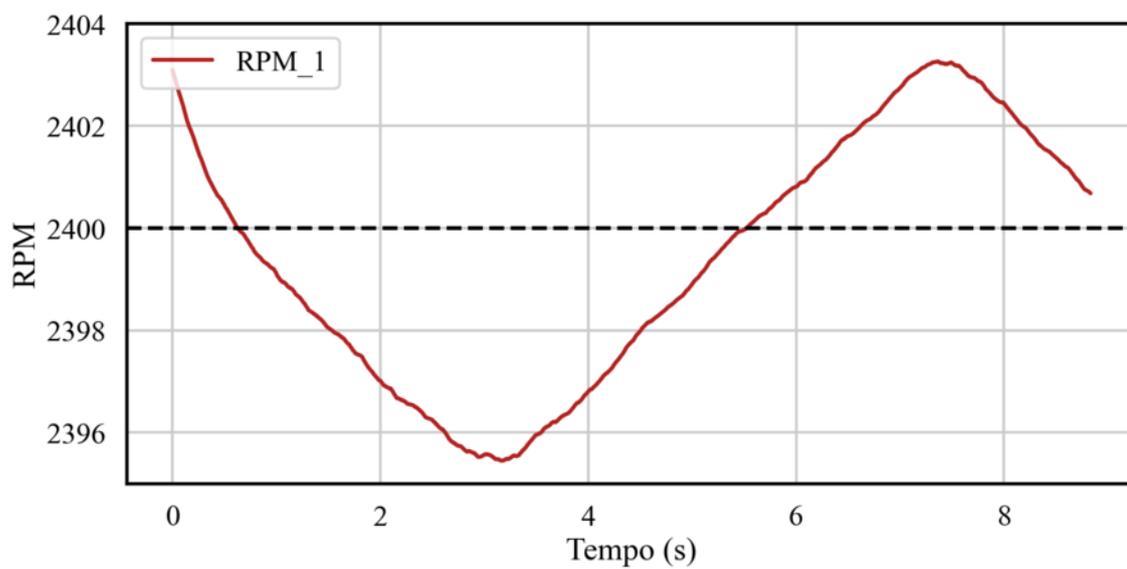
Fonte: Autor

Figura 103 – Medidas de Velocidade em 2200 RPM



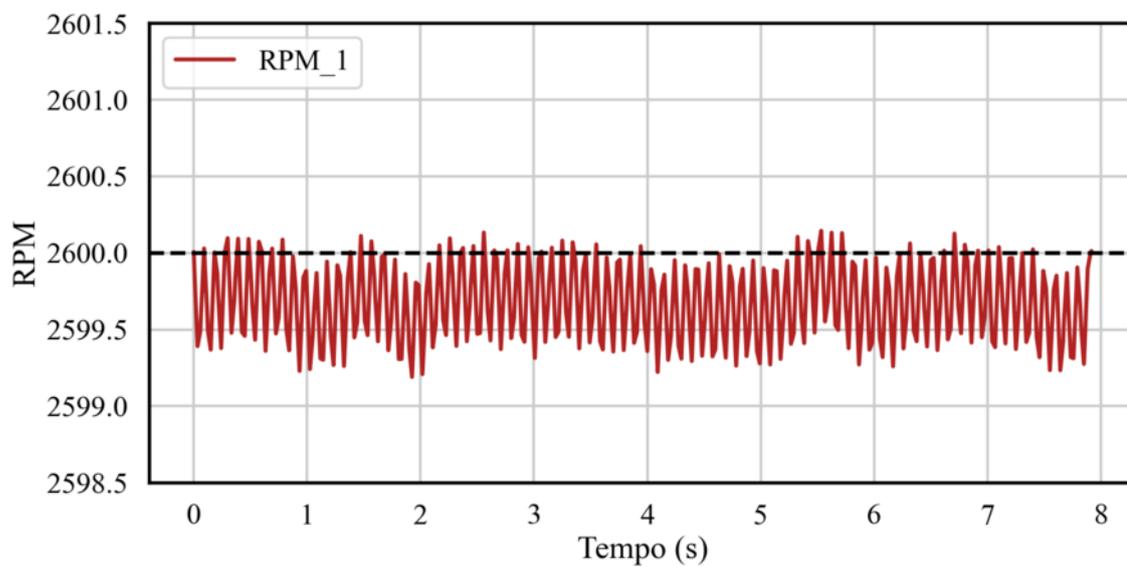
Fonte: Autor

Figura 104 – Medidas de Velocidade em 2400 RPM



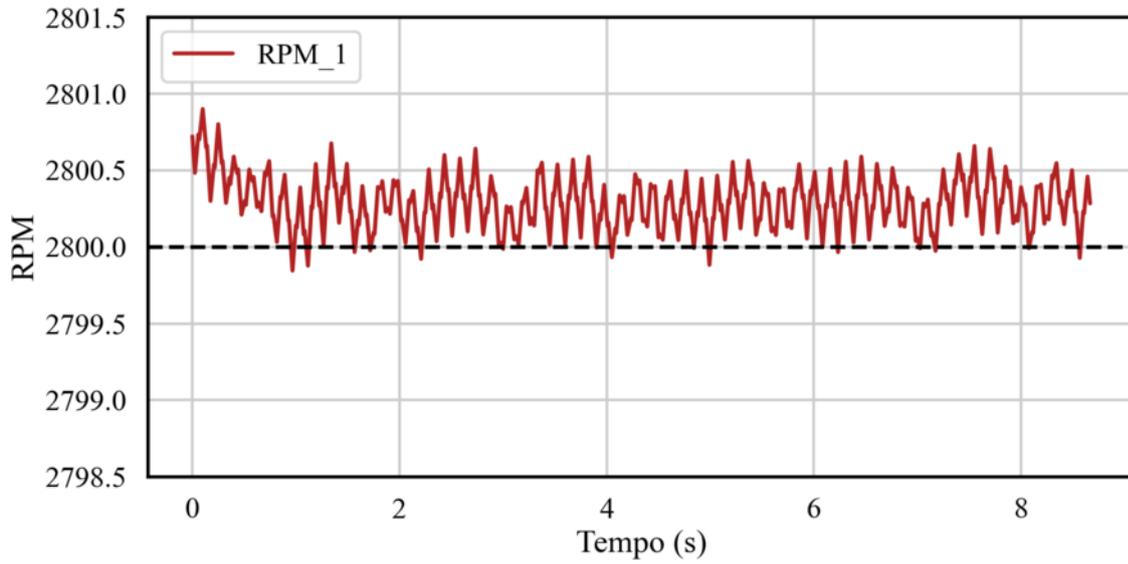
Fonte: Autor

Figura 105 – Medidas de Velocidade em 2600 RPM



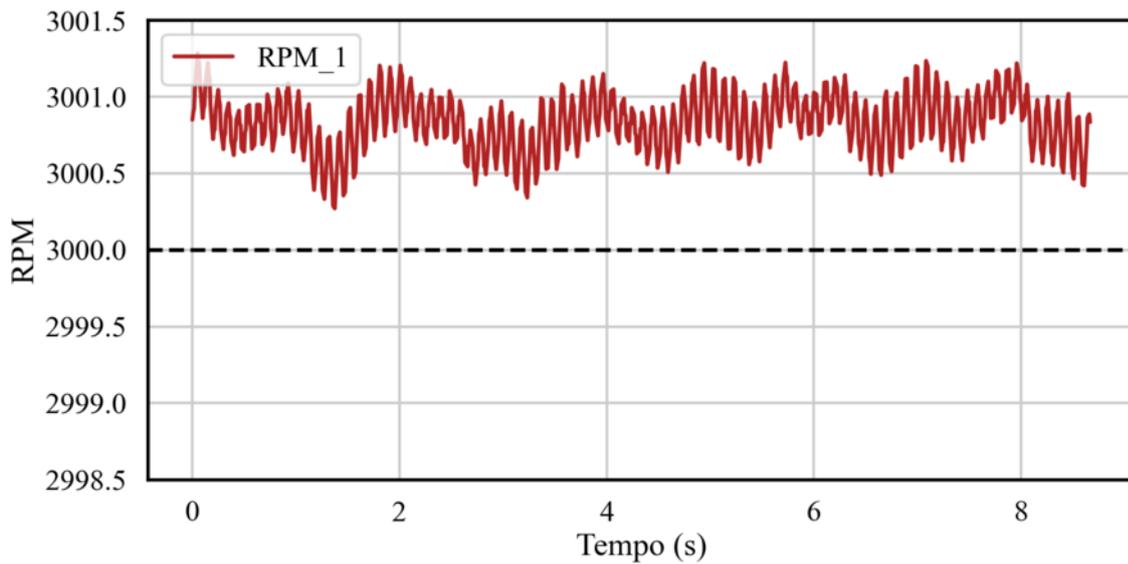
Fonte: Autor

Figura 106 – Medidas de Velocidade em 2800 RPM



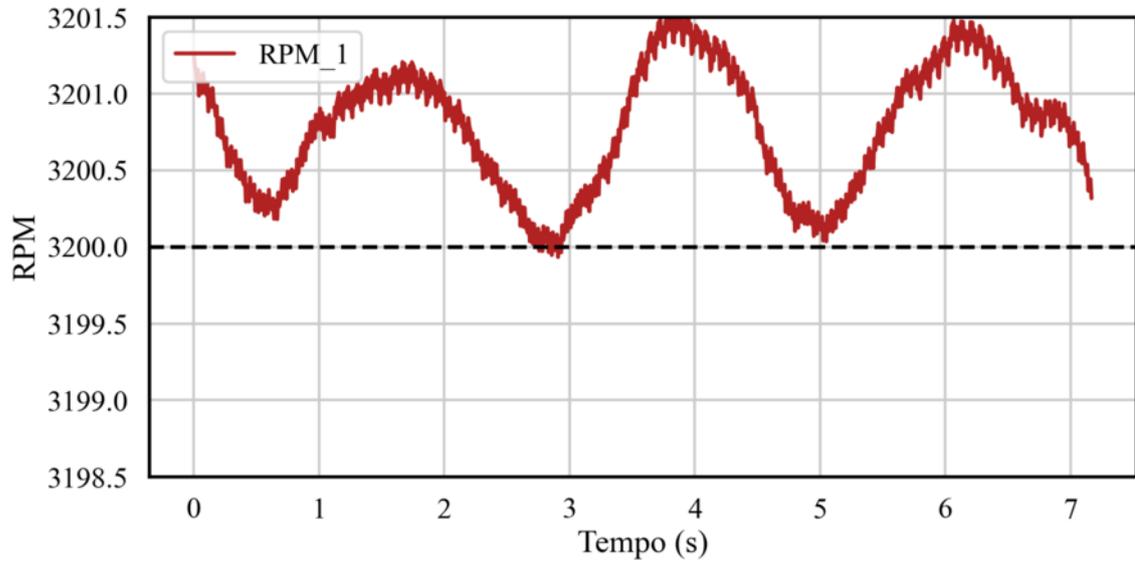
Fonte: Autor

Figura 107 – Medidas de Velocidade em 3000 RPM



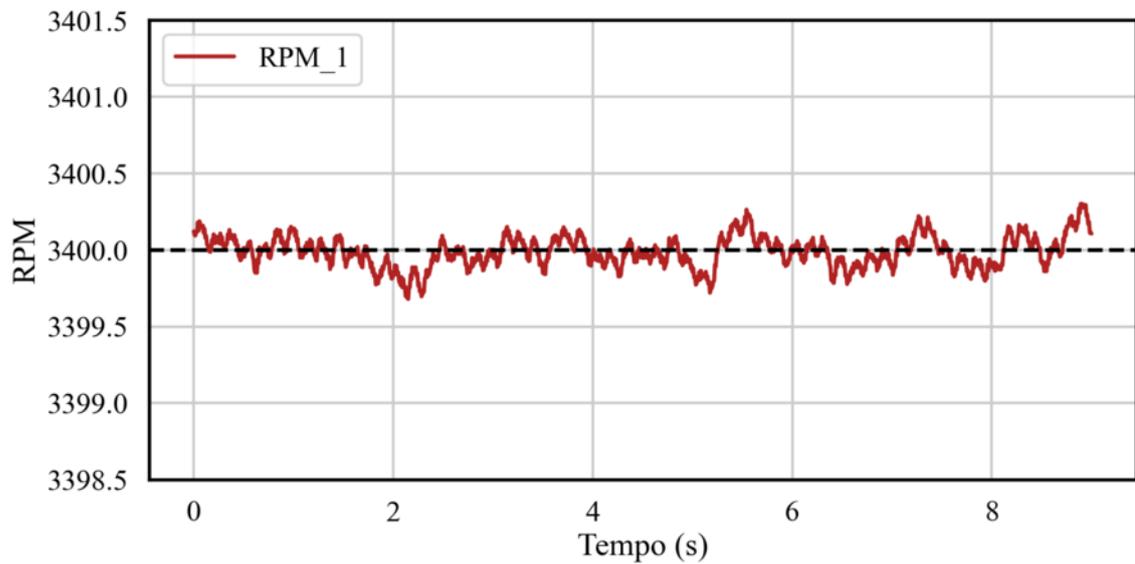
Fonte: Autor

Figura 108 – Medidas de Velocidade em 3200 RPM



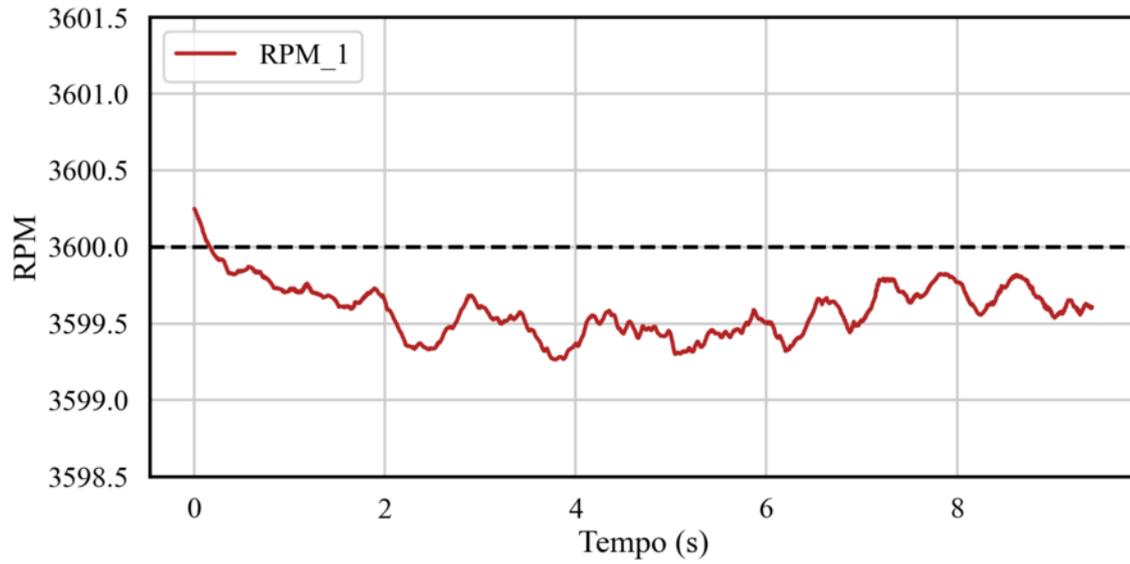
Fonte: Autor

Figura 109 – Medidas de Velocidade em 3400 RPM



Fonte: Autor

Figura 110 – Medidas de Velocidade em 3600 RPM



Fonte: Autor

APÊNDICE D

Plano e Coleta de Dados

Tabela 6 – Dados Coletados - Configurações

Arquivo	Massa Balanceada [Kg]	Massa Desbalanceada [Kg]	Altura da Massa Desbalanceada [mm]	Replica
1	0	0	0	1
2	0	0	0	2
3	0	0	0	3
4	0	0.5	0	1
5	0	0.5	0	2
6	0	0.5	0	3
7	0	1	0	1
8	0	1	0	2
9	0	1	0	3
10	0	1.5	0	1
11	0	1.5	0	2
12	0	1.5	0	3
13	0	2	0	1
14	0	2	0	2
15	0	2	0	3
16	0	2.5	0	1
17	0	2.5	0	2
18	0	2.5	0	3

Tabela 6 - Continuação

Arquivo	Massa Balanceada [Kg]	Massa Desbalanceada [Kg]	Altura da Massa Desbalanceada [mm]	Replica
19	2.5	0	0	3
20	2.5	0	0	1
21	2.5	0	0	2
22	2.5	0.5	0	1
23	2.5	0.5	0	2
24	2.5	0.5	0	3
25	2.5	1	0	1
26	2.5	1	0	2
27	2.5	1	0	3
28	2.5	1.5	0	1
29	2.5	1.5	0	2
30	2.5	1.5	0	3
31	2.5	2	0	1
32	2.5	2	0	2
33	2.5	2	0	3
34	2.5	2	0	4
35	2.5	2.5	0	1
36	2.5	2.5	0	2
37	2.5	2.5	0	3
38	2.5	2.5	0	4
39	5.3	0	0	2
40	5.3	0	0	3
41	5.3	0	0	1
42	5.3	0.5	0	2
43	5.3	0.5	0	3
44	5.3	0.5	0	1
45	5.3	1	0	3
46	5.3	1	0	1
47	5.3	1	0	2
48	5.3	1.5	0	2
49	5.3	1.5	0	3
50	5.3	1.5	0	1
51	5.3	2	0	1
52	5.3	2	0	2

Tabela 6 - Continuação

Arquivo	Massa Balanceada [Kg]	Massa Desbalanceada [Kg]	Altura da Massa Desbalanceada [mm]	Replica
53	5.3	2	0	3
54	5.3	2.5	0	1
55	5.3	2.5	0	2
56	5.3	2.5	0	3
57	7.43	0	0	1
58	7.43	0	0	2
59	7.43	0	0	3
60	7.43	0.5	0	1
61	7.43	0.5	0	2
62	7.43	0.5	0	3
63	7.43	1	0	1
64	7.43	1	0	2
65	7.43	1	0	3
66	7.43	1	150	1
67	7.43	1	150	2
68	7.43	1	150	3
69	7.43	1.5	0	1
70	7.43	1.5	0	2
71	7.43	1.5	0	3
72	7.43	1.5	0	4
73	7.43	1.5	150	1
74	7.43	1.5	150	2
75	7.43	1.5	150	3
76	7.43	2	0	1
77	7.43	2	0	2
78	7.43	2	0	3
79	7.43	2	150	1
80	7.43	2	150	2
81	7.43	2	150	3
82	7.43	2.5	0	1
83	7.43	2.5	0	2
84	7.43	2.5	0	3
85	7.43	2.5	150	1
86	7.43	2.5	150	2

Tabela 6 - Continuação

Arquivo	Massa Balanceada [Kg]	Massa Desbalanceada [Kg]	Altura da Massa Desbalanceada [mm]	Replica
87	7.43	2.5	150	3
88	8.93	0	0	1
89	8.93	0	0	2
90	8.93	0	0	3
91	8.93	0.5	300	1
92	8.93	0.5	300	2
93	8.93	0.5	300	3
94	8.93	0.5	0	1
95	8.93	0.5	0	2
96	8.93	0.5	0	3
97	8.93	0.5	150	1
98	8.93	0.5	150	2
99	8.93	0.5	150	3
100	8.93	1	300	1
101	8.93	1	300	2
102	8.93	1	300	3
103	8.93	1	0	1
104	8.93	1	0	2
105	8.93	1	0	3
106	8.93	1	150	1
107	8.93	1	150	2
108	8.93	1	150	3
109	8.93	1.5	0	1
110	8.93	1.5	0	2
111	8.93	1.5	0	3
112	8.93	1.5	150	1
113	8.93	1.5	150	2
114	8.93	1.5	150	3
115	8.93	2	0	1
116	8.93	2	0	2
117	8.93	2	0	3
118	8.93	2	150	1
119	8.93	2	150	2
120	8.93	2	150	3

Tabela 6 - Continuação

Arquivo	Massa Balanceada [Kg]	Massa Desbalanceada [Kg]	Altura da Massa Desbalanceada [mm]	Replica
121	8.93	2.5	0	1
122	8.93	2.5	0	2
123	8.93	2.5	0	3
124	8.93	2.5	150	1
125	8.93	2.5	150	2
126	8.93	2.5	150	3
127	11.76	0	0	1
128	11.76	0	0	2
129	11.76	0	0	3
130	11.76	0.5	0	1
131	11.76	0.5	0	2
132	11.76	0.5	0	3
133	11.76	0.5	150	1
134	11.76	0.5	150	2
135	11.76	0.5	150	3
136	11.76	0.5	300	1
137	11.76	0.5	300	2
138	11.76	0.5	300	3
139	11.76	1	0	1
140	11.76	1	0	2
141	11.76	1	0	3
142	11.76	1	150	1
143	11.76	1	150	2
144	11.76	1	150	3
145	11.76	1	300	1
146	11.76	1	300	2
147	11.76	1	300	3
148	11.76	1.5	0	1
149	11.76	1.5	0	2
150	11.76	1.5	0	3
151	11.76	1.5	150	1
152	11.76	1.5	150	2
153	11.76	1.5	150	3
154	11.76	2	0	1

Tabela 6 - Continuação

Arquivo	Massa Balanceada [Kg]	Massa Desbalanceada [Kg]	Altura da Massa Desbalanceada [mm]	Replica
155	11.76	2	0	2
156	11.76	2	0	3
157	11.76	2	150	1
158	11.76	2	150	2
159	11.76	2	150	3
160	11.76	2.5	0	1
161	11.76	2.5	0	2
162	11.76	2.5	0	3
163	11.76	2.5	150	1
164	11.76	2.5	150	2
165	11.76	2.5	150	3
166	11.76	3	150	1
167	11.76	3	150	2
168	11.76	3	150	3

Tabela 7 – Dados Coletados - Valores de Entrada Extraídos

Arquivo	X1- Tempo [s]	X2- Deslocamento Abs. [mm]	X3- Máxima Órbita [mm]	X4- Integral Órbita [mm]	X5- Desvio Padrão Órbita [mm]
1	3.3501	0	5.5465	1206.3472	1.1474
2	3.1168	0	7.7381	1214.9500	1.5738
3	5.1835	0	6.3857	1063.9416	1.5448
4	5.4669	0	19.7349	3469.9224	5.5113
5	3.3251	0	19.5120	3594.6524	4.7088
6	3.3001	0	20.2542	3366.1450	4.9993
7	3.9418	0	29.2120	6862.1935	7.0194
8	5.8669	1	30.4761	6482.0124	8.4522
9	3.8002	0	32.3798	6632.2079	7.4703
10	6.5086	3	39.9419	9716.9591	11.0715
11	4.5752	4	39.7912	10659.9034	9.6396
12	4.5085	5	39.8705	10034.0384	9.7120
13	5.8669	11	44.0756	14713.4182	10.6070
14	5.6836	17	47.1400	14826.3262	10.3878
15	5.5502	20	49.0642	14496.9615	10.5214
16	17.9091	157	59.8217	49410.4170	12.7406
17	16.3259	185	60.0162	51578.7021	14.6651
18	12.6175	150	59.4042	39207.2230	14.0788
19	4.3168	0	8.1205	1568.0806	1.7035
20	4.3002	0	8.4392	1611.9864	1.7655
21	4.3001	0	9.5983	1810.2907	1.9485
22	4.5835	0	14.9351	3209.5728	3.4545
23	4.5252	1	14.5955	3038.2413	3.1731
24	5.0419	1	15.9199	3339.2039	3.4431
25	5.2585	1	26.0803	7539.5826	6.1857
26	5.1085	0	26.8931	7452.3578	6.3992
27	5.0085	1	25.2110	6516.4401	6.1497
28	5.7335	1	36.9510	10014.1095	9.5562
29	5.5919	1	36.1482	9196.4945	8.7722
30	5.5835	1	36.1978	9273.1984	8.9800
31	6.5003	3	42.6481	15430.7752	10.6206
32	6.2169	5	44.1039	13851.4708	10.5758
33	6.3919	3	43.6890	14961.4271	10.1824

Tabela 7 - Continuação

Arquivo	X1- Tempo [s]	X2- Deslocamento Abs. [mm]	X3- Máxima Órbita [mm]	X4- Integral Órbita [mm]	X5- Desvio Padrão Órbita [mm]
34	6.4669	3	43.8400	13042.5629	10.9413
35	8.5586	47	55.7512	23503.3563	13.0279
36	9.0588	36	49.4258	23451.9331	11.1232
37	9.6504	30	47.9629	24714.0082	11.4181
38	9.5004	49	54.0166	25586.9190	11.8260
39	6.1586	0	9.9148	2653.4454	1.9635
40	5.7919	0	9.4279	2508.8128	1.8677
41	5.4752	0	10.4674	2408.5258	2.2436
42	5.9335	0	21.6885	5444.0438	5.4675
43	5.8752	0	26.2145	5497.6501	6.1118
44	5.6669	0	24.2353	5094.3850	5.7351
45	6.2919	14	34.1901	8489.7676	8.1412
46	6.0835	1	34.9006	9090.3981	6.8888
47	5.9918	0	35.0116	8599.2726	8.7527
48	7.5919	1	43.7987	13401.4601	11.0408
49	7.1169	1	41.7243	12975.7076	10.4337
50	6.8419	1	41.7732	12223.9803	10.4778
51	8.0253	5	48.5713	18749.9577	12.5016
52	8.0503	4	48.2718	18900.6396	12.2776
53	7.7920	4	48.3248	18022.2238	12.6615
54	11.1670	44	54.3548	31723.7128	13.4726
55	10.6920	61	52.6328	30084.8010	12.7007
56	10.3087	58	53.3456	27721.5389	13.0401
57	7.1502	0	8.7562	2681.8923	1.8622
58	6.6919	0	8.5976	2648.4094	1.9261
59	6.6086	0	8.5340	2636.0990	1.8083
60	6.8586	0	19.2238	5460.3766	4.0533
61	6.5919	0	20.8669	5780.1725	4.3103
62	6.7252	0	21.5628	6133.8871	4.7124
63	7.1169	0	33.8538	10491.8988	8.1261
64	7.1002	0	35.9385	10332.5431	8.3816
65	7.0086	0	32.4142	9429.8900	7.4537
66	8.0086	1	34.0393	12900.2191	8.4807

Tabela 7 - Continuação

Arquivo	X1- Tempo [s]	X2- Deslocamento Abs. [mm]	X3- Máxima Órbita [mm]	X4- Integral Órbita [mm]	X5- Desvio Padrão Órbita [mm]
67	7.4919	1	36.1022	12122.9204	8.6275
68	7.3585	1	34.6156	11256.2527	8.3005
69	8.7169	3	41.7583	17417.3604	9.8880
70	8.3503	3	42.7499	17604.1963	10.1049
71	8.0503	2	42.3356	17388.7044	9.8107
72	8.0003	2	43.3220	15438.1865	10.5606
73	7.9836	2	42.8866	17141.0185	10.8374
74	7.7336	3	44.6687	17883.6690	11.0689
75	7.7253	3	43.1430	17828.1752	10.6798
76	10.6754	12	47.7186	22922.7121	11.3177
77	9.7337	14	48.7001	22425.9770	11.2692
78	9.4170	16	47.6545	21275.6049	11.2493
79	7.8336	6	49.6108	20043.8848	12.1329
80	7.8586	7	49.8404	20979.0781	12.3818
81	8.8836	11	48.7977	22967.9329	12.1316
82	14.5005	62	55.2783	41990.0235	12.8631
83	14.3920	31	53.3325	39341.6375	13.6390
84	13.8088	33	54.7771	38766.1066	12.9855
85	11.2087	69	57.6316	34582.6740	14.2823
86	11.0754	73	55.7041	34611.1291	13.9697
87	10.3587	42	54.1557	31588.2087	13.6910
88	7.6336	0	5.6319	2373.5486	1.2389
89	7.5753	0	6.0505	2533.9531	1.3368
90	7.4586	0	6.7266	2427.5924	1.4087
91	7.9586	0	19.4685	6263.0948	4.5548
92	8.1753	0	21.1026	6593.6182	4.7561
93	8.0170	0	20.8474	6637.0201	4.8814
94	7.9002	0	17.7152	5051.9619	4.1414
95	7.7003	0	18.9927	5039.0646	4.4020
96	8.2253	0	18.8382	5443.7856	4.6878
97	8.2836	0	19.3226	5424.6476	4.2372
98	8.1503	0	18.3138	5798.8209	4.7189
99	8.1836	0	19.0121	5393.6373	4.3511

Tabela 7 - Continuação

Arquivo	X1- Tempo [s]	X2- Deslocamento Abs. [mm]	X3- Máxima Órbita [mm]	X4- Integral Órbita [mm]	X5- Desvio Padrão Órbita [mm]
100	9.0837	1	34.1360	13453.5354	7.1491
101	8.6252	0	35.5764	11398.6405	7.2949
102	8.5253	0	36.3620	11456.4274	7.1918
103	8.8418	0	27.3568	9497.8615	6.7232
104	8.7251	0	27.9078	10262.2953	7.1000
105	9.4503	0	31.9866	10742.0674	7.6168
106	8.5503	1	33.3117	10976.7964	7.6645
107	8.4169	1	33.0797	10601.0060	7.6584
108	8.8003	0	35.8846	12030.4458	8.1497
109	9.6253	1	37.7714	14966.2046	9.3581
110	9.1837	1	38.4180	14983.7176	9.5895
111	9.0670	1	38.6749	14853.4457	9.7801
112	9.1003	2	41.2109	18234.0179	10.5409
113	8.7920	1	39.6353	17370.4256	10.0060
114	9.4503	1	42.3457	18557.6306	10.5416
115	11.6920	3	44.2075	22950.8536	10.5666
116	10.8420	2	44.8665	22775.0865	10.4842
117	10.5918	3	44.8045	21764.2892	10.7293
118	9.6669	4	46.8908	20671.8691	11.7955
119	10.5920	5	46.1225	23455.9305	11.6371
120	10.0002	3	46.9839	22553.7418	11.5780
121	12.1921	12	49.9848	29339.9853	11.6196
122	11.9836	17	50.6695	29741.4186	11.5092
123	14.1755	19	49.5018	36338.1664	11.6480
124	11.8587	30	52.3326	34443.3652	12.7468
125	12.0087	28	53.5458	34386.9235	13.1201
126	11.6086	41	51.8027	33496.9499	13.2315
127	9.9087	0	9.2685	3407.8564	2.1025
128	9.9920	0	9.2072	3509.7537	1.9802
129	9.5085	0	9.5397	3354.5698	2.0276
130	10.3670	0	18.8573	6362.0637	4.4683
131	9.9670	0	20.0820	6194.0574	4.6650
132	9.6920	0	19.1597	5692.0192	4.4398

Tabela 7 - Continuação

Arquivo	X1- Tempo [s]	X2- Deslocamento Abs. [mm]	X3- Máxima Órbita [mm]	X4- Integral Órbita [mm]	X5- Desvio Padrão Órbita [mm]
133	9.7003	0	19.4140	5785.4977	4.1893
134	9.4003	0	20.3103	5837.8830	4.4007
135	9.2253	0	19.7747	6275.0085	4.5043
136	9.1503	0	22.0338	6782.2949	4.6718
137	8.8503	0	21.9367	6255.7133	4.4526
138	8.8003	0	20.1752	6668.8746	4.5550
139	9.9920	1	34.6200	11876.8680	7.6371
140	10.5420	1	33.3007	12515.6108	7.3515
141	9.8003	1	33.6016	11396.9650	7.4092
142	9.8752	0	31.3548	11287.6635	7.2793
143	9.7837	1	35.2235	12502.8418	7.9192
144	9.4586	0	34.5158	11606.6452	7.5461
145	9.3587	0	34.9394	11922.4081	7.1482
146	9.3003	1	33.1160	12920.4142	7.1725
147	9.3170	0	32.4037	11904.0381	7.0285
148	10.9087	1	39.0857	17711.1121	9.2956
149	10.3920	1	39.0851	17914.8112	9.3349
150	10.1503	1	38.2249	16653.5779	9.1387
151	9.9920	1	39.7546	17717.5416	9.9085
152	9.8920	1	38.8829	17141.7832	9.6256
153	9.8253	1	39.1534	16925.6722	9.7169
154	11.5254	3	44.3717	22847.3253	10.4743
155	10.9587	2	45.7386	21677.6122	10.3225
156	10.9587	3	47.0248	23191.7237	10.7726
157	11.2254	3	47.1713	24590.8310	11.6224
158	10.1170	2	45.0233	21326.7611	10.8381
159	9.9503	2	44.9225	20595.8710	10.9507
160	15.6422	22	49.6806	44106.8015	10.9609
161	17.4527	14	49.3284	45241.5275	9.4934
162	16.7089	15	49.4715	44772.0558	10.9747
163	11.5587	23	48.8530	32167.8502	11.8945
164	11.3587	34	49.8889	31802.8114	12.0721
165	11.6087	23	49.3827	32236.3480	12.3330

Tabela 7 - Continuação

Arquivo	X1- Tempo [s]	X2- Deslocamento Abs. [mm]	X3- Máxima Órbita [mm]	X4- Integral Órbita [mm]	X5- Desvio Padrão Órbita [mm]
166	14.0838	39	52.9388	41584.6859	12.8822
167	13.7005	47	54.5550	41718.3213	12.8902
168	13.4254	59	53.1603	40377.7980	12.7995