



UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA ELÉTRICA  
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DETECÇÃO DE ESCORREGAMENTO EM TEMPO  
REAL PARA CONTROLE DE UMA GARRA  
ROBÓTICA, UTILIZANDO MACHINE LEARNING

Alexandre Henrique Pereira Tavares

Uberlândia-MG

2020

**ALEXANDRE HENRIQUE PEREIRA TAVARES**

**DETECÇÃO DE ESCORREGAMENTO EM TEMPO REAL PARA  
CONTROLE DE UMA GARRA ROBÓTICA, UTILIZANDO  
MACHINE LEARNING**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas de energia elétrica

Linha de pesquisa: Controle e automação

---

Prof. Dr. Aniel Silva de Moraes,

Orientador

Uberlândia - MG

2020

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

T231 Tavares, Alexandre Henrique Pereira, 1995-  
2020 Detecção de escorregamento em tempo real para controle de  
uma garra robótica, utilizando Machine Learning [recurso  
eletrônico] / Alexandre Henrique Pereira Tavares. - 2020.

Orientador: Aniel Silva de Morais.  
Dissertação (Mestrado) - Universidade Federal de Uberlândia,  
Pós-graduação em Engenharia Elétrica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2020.231>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia elétrica. I. Morais, Aniel Silva de, 1979-, (Orient.).  
II. Universidade Federal de Uberlândia. Pós-graduação em  
Engenharia Elétrica. III. Título.

CDU: 621.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:  
Gizele Cristine Nunes do Couto - CRB6/2091  
Nelson Marcos Ferreira - CRB6/3074

**ALEXANDRE HENRIQUE PEREIRA TAVARES**

**DETECÇÃO DE ESCORREGAMENTO EM TEMPO REAL PARA  
CONTROLE DE UMA GARRA ROBÓTICA, UTILIZANDO  
MACHINE LEARNING**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para obtenção do grau de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas de energia elétrica

Linha de pesquisa: Controle e automação

Uberlândia, 17 de fevereiro de 2020.

Banca examinadora:

Prof. Dr. Aniel Silva de Moraes - UFU, Orientador

Prof. Dr. Sérgio Ricardo de Jesus Oliveira - UFU

Prof. Dr. Josué Silva de Moraes - UFU

Prof. Dr. Kleber Lopes Fontoura - CEFET-MG



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA**  
 Coordenação do Programa de Pós-Graduação em Engenharia Elétrica  
 Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902  
 Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Dissertação de Mestrado Acadêmico, 725, PPGEELT				
Data:	Dezessete de fevereiro de dois mil e vinte	Hora de início:	08:00	Hora de encerramento:	10:30
Matrícula do Discente:	11812EEL012				
Nome do Discente:	Alexandre Henrique Pereira Tavares				
Título do Trabalho:	Detecção de escorregamento em tempo real para controle de uma garra robótica, utilizando Machine Learning				
Área de concentração:	Sistemas de energia elétrica				
Linha de pesquisa:	Controle e automação				
Projeto de Pesquisa de vinculação:	Título: Técnicas de identificação de sistemas visando aplicabilidade em processos industriais Agência Financiadora: UNIVERSIDADE FEDERAL DE UBERLÂNDIA - (Programa Institucional de Apoio a Pesquisa (apoio financeiro)) Início 02/01/2013 Término __/__/__ No. do Projeto na agência: __ Professor Coordenador: Marcio Jose da Cunha__				

Reuniu-se no Anfiteatro 1E, Campus Santa Mônica, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Sérgio Ricardo de Jesus Oliveira - FEELT/UFU; Josué Silva de Moraes - FEELT/UFU; Kleber Lopes Fontoura - CEFET-MG; Aniel Silva de Moraes - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Aniel Silva de Moraes, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de **Mestre**.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Josué Silva de Moraes, Professor(a) do Magistério Superior**, em 17/02/2020, às 10:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Aniel Silva de Moraes, Professor(a) do Magistério Superior**, em 17/02/2020, às 10:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Kleber Lopes Fontoura, Usuário Externo**, em 17/02/2020, às 11:14, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Sergio Ricardo de Jesus Oliveira, Membro de Comissão**, em 17/02/2020, às 12:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://www.sei.ufu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **1723417** e o código CRC **AE4EC229**.

# Agradecimentos

Agradeço primeiramente a Deus que me guiou em todos os meus projetos de minha vida e me proporcionou oportunidades para crescer em todos os sentidos. Também agradeço aos meus pais Marcílio e Silvana, ao meu irmão Guilherme, à minha namorada Bárbara e à toda minha família e amigos que me apoiaram nesta fase de minha vida. Um agradecimento especial à toda equipe do Biolab da Universidade Federal de Uberlândia, principalmente ao professor Sérgio e ao professor Alcimar que me guiaram e me orientaram na maior parte do trabalho; aos engenheiros Ronaldo, Andrei e Vinícius que me ajudaram tecnicamente no desenvolvimento de meus experimentos e processamento dos dados. Por fim, quero agradecer a todos os alunos e professores que me auxiliaram e ajudaram a desenvolver este projeto de alguma forma.

# Dedicatória

Decido este trabalho à minha família e a Deus.

# Resumo

Tavares, A.H.P. **Detecção de escorregamento em tempo real para controle de uma garra robótica, utilizando Machine Learning..** 2020. 75f. Dissertação de Mestrado, Universidade Federal de Uberlândia, Uberlândia, MG.

O manuseio e prensão de objetos de forma correta depende do controle preciso da força aplicada, juntamente com a detecção de escorregamento do objeto a ser segurado. A implementação de sensoriamento tátil para a detecção de escorregamento no controle da força de prensão pode reduzir os custos na manipulação de objetos na indústria e trazer mais segurança para aqueles que operam junto a estas máquinas. Assim, foi desenvolvido um sistema de prensão de objetos que atua em apenas uma direção, recebe os sinais de dois sensores de pressão e um sensor acústico, e tem como atuador um motor de passo, que controla a força de prensão exercida no objeto. O sistema desenvolvido teve seu princípio de funcionamento baseado na detecção, em tempo real, de escorregamento na superfície de contato do objeto, por meio da análise do sinal do sensor acústico, posicionado na superfície, além da detecção da força de prensão. Um algoritmo de treinamento supervisionado foi usado como classificador e desempenhou a função de detectar a presença de escorregamento na superfície do dispositivo. Assim, o sistema de controle da força de prensão sobre o objeto a ser segurado é baseado na resposta do classificador frente à presença de escorregamento. Sua resposta, caso positiva, implica um ganho incremental fixo da força exercida durante a prensão. Ao final, é analisada a performance do sistema online de controle da prensão para diferentes objetos e observa-se que o sistema é capaz de manter a prensão estável para objetos com maior massa e rigidez elevada.

**Palavras-chave:** Controle da força de prensão, detecção de escorregamento, aprendizado de máquina.

# Abstract

Tavares, A.H.P. **Real-time slip detection to control a robotic grasp, using Machine Learning..** 2020. 75f. MSc. Dissertation, Federal University of Uberlândia, Uberlândia, MG.

The correct handling and gripping of objects depend on the precise control of the applied force, together with the slip detection of the object to be held. The implementation of tactile sensing for slip detection in the control of the gripping force can reduce the costs of handling objects in the industry and bring more safety to those who operate with these machines. Thus, an object gripping system was developed that acts in only one direction, it receives signals from two pressure sensors and an acoustic sensor, and it has a stepper motor that controls the gripping force exerted on the object. The developed system has its operating principle based on the slip detection, in real-time, on the contact surface of the object, through the analysis of the signal from the acoustic sensor, positioned on the surface, in addition to the detection of the grip strength. A supervised learning algorithm was used as a classifier and performed the function of detecting the presence of slipping on the device's surface. Thus, the control system of the grip strength on the object to be held is based on the classifier's response to the presence of slipping. Its answer, if positive, implies a fixed incremental gain in the force exerted during the grip. In the end, the performance of the online grip control system is analyzed for different objects and it is observed that the system can maintain the grip stable for objects with greater mass and high rigidity.

**Keywords:** Grip force control, slip detection, machine learning.

# Sumário

<b>Agradecimentos</b>	<b>i</b>
<b>Dedicatória</b>	<b>ii</b>
<b>Resumo</b>	<b>1</b>
<b>Abstract</b>	<b>2</b>
<b>Lista de Figuras</b>	<b>5</b>
<b>1 Introdução</b>	<b>8</b>
1.1 Contextualização . . . . .	8
1.2 Objetivo . . . . .	10
1.3 Organização da Dissertação . . . . .	11
<b>2 Fundamentação Teórica</b>	<b>12</b>
2.1 Fenômeno de Escorregamento . . . . .	12
2.2 Sensores Biológicos . . . . .	13
2.3 Sensores Táteis . . . . .	16
2.3.1 Sensores de Deslocamento . . . . .	16
2.3.2 Sensores de Microvibrações . . . . .	17
2.3.3 Sensores de Força . . . . .	19
2.4 Hardware . . . . .	19
2.4.1 Comunicação de Dados . . . . .	19
2.4.2 Placa processadora . . . . .	20
2.4.3 Máquina de Controle Numérico Computadorizado (CNC) . . . . .	21
2.5 Machine Learning (Aprendizado de Máquina) . . . . .	22
2.5.1 Redes Neurais Artificiais . . . . .	24
2.5.2 Máquina de vetores de suporte . . . . .	26

<b>3</b>	<b>Metodologia</b>	<b>28</b>
3.1	Descrição do Hardware . . . . .	28
3.1.1	Sensoriamento . . . . .	28
3.1.2	Aquisição dos Dados . . . . .	31
3.1.3	Transmissão de Dados . . . . .	33
3.1.4	Controle da força de prensão . . . . .	35
3.2	Software Desenvolvido . . . . .	37
3.2.1	Placa processadora . . . . .	38
3.2.2	PC: Interface gráfica e controle do sistema . . . . .	39
3.2.3	Deteção de Escorregamento . . . . .	40
3.2.4	Pré-processamento, Extração e Seleção de Características . . . . .	42
3.2.5	Treinamento do Classificador . . . . .	43
3.2.6	Sistema de Controle da força de prensão . . . . .	44
3.3	Experimento para aquisição dos sinais com seus targets . . . . .	44
3.4	Análise do desempenho dos algoritmos classificadores . . . . .	47
3.5	Análise da primeira classificação correta do evento de escorregamento em sinais offline . . . . .	49
3.6	Análise da performance do sistema de controle da força de prensão, em tempo real . . . . .	50
3.7	Validação do algoritmo de classificação . . . . .	51
<b>4</b>	<b>Resultados</b>	<b>52</b>
4.1	Experimento para análise da sensibilidade de sensores para deteção de escorregamento . . . . .	52
4.2	Comparação de performance entre RNA e SVM . . . . .	53
4.2.1	Análise da melhor arquitetura da Rede Neural Artificial . . . . .	53
4.2.2	Análise do tamanho das amostras utilizadas como entrada aos classificadores . . . . .	55
4.2.3	Análise da influência da qualidade das amostras durante o treinamento . . . . .	57
4.2.4	Análise da primeira classificação correta do evento de escorregamento em sinais offline . . . . .	58
4.2.5	Análise da performance do sistema de controle em tempo real . . . . .	60

<b>5</b>	<b>Discussões</b>	<b>62</b>
5.1	Experimento para análise da sensibilidade de sensores para detecção de escorregamento . . . . .	62
5.2	Comparação de performance entre RNA e SVM . . . . .	63
5.2.1	Análise da melhor arquitetura da Rede Neural Artificial . . . . .	63
5.2.2	Análise da influência do tamanho das amostras na acurácia de classificação dos algoritmos . . . . .	63
5.2.3	Análise da primeira classificação correta do evento de escorregamento em sinais offline . . . . .	65
5.3	Análise da performance do sistema em tempo real . . . . .	67
<b>6</b>	<b>Conclusões</b>	<b>69</b>
	<b>Referências</b>	<b>70</b>

# Lista de Figuras

2.1	Diagrama de forças durante a apreensão de um objeto. . . . .	13
2.2	Mecanorreceptores e suas respostas frente a estímulos externos . . . . .	15
2.3	Máquina CNC utilizada, com controle por motores de passo. . . . .	21
2.4	Estrutura básica de uma Rede Neural Artificial. . . . .	25
2.5	Princípio de funcionamento da separação de classes de uma Máquina de Vetores de Suporte para entradas com apenas duas dimensões. . . . .	26
3.1	Sistema desenvolvido de controle unidirecional da força de apreensão. . . . .	29
3.2	Diagrama de funcionamento do hardware. . . . .	30
3.3	Setup do experimento para verificação das resposta dos sensores de pressão e acústico, frente à presença de escorregamento. . . . .	30
3.4	Protótipo desenvolvido de sensor tátil. . . . .	32
3.5	Aquisição dos dados em 12 bits e convertidos para dois Bytes. . . . .	32
3.6	Protocolo UART de envio de um Byte pela comunicação serial. . . . .	34
3.7	Protocolo utilizado para agrupamento dos Bytes em pacotes. . . . .	34
3.8	Sistema de controle da força de apreensão sobre um objeto. . . . .	36
3.9	Diagrama dos softwares desenvolvidos, entre parênteses está a linguagem de programação de cada software. . . . .	38
3.10	Sinal de uma coleta experimental. As amostras rotuladas com presença de escorregamento são identificadas pela cor verde, enquanto as amostras rotuladas com ausência de escorregamento são identificadas pela cor vermelha. . . . .	42
3.11	Sinais dos sensores de uma amostra após o processo de rotulagem. . . . .	45
3.12	Objetos utilizados durante o experimento de coleta dos sinais de escorregamento. . . . .	46

3.13	Localização das amostras utilizadas no treinamento, em uma coleta, durante os testes 1 e 2. A cor verde representa a localização das amostras com <i>target</i> de presença de escorregamento e a cor vermelha representa as amostras com <i>target</i> de ausência de escorregamento. O sinal representado em azul não foi considerado no treinamento do classificador. . . . .	48
3.14	Sinal coletado pelo microfone de eletreto (A); <i>targets</i> de cada amostra de 40 ms, coletados a partir da variação do sinal digital do sensor óptico no experimento para aquisição dos sinais e <i>targets</i> (B); resposta do classificador para cada amostra (C). . . . .	50
4.1	Amostra do sinal do sensor de pressão durante o experimento para análise de sua sensibilidade frente à presença de escorregamento. . . . .	52
4.2	Amostra do sinal do sensor acústico durante o experimento para análise de sua sensibilidade frente à presença de escorregamento. . . . .	53
4.3	Acurácia de classificação da Rede Neural Artificial pelo número de camadas escondidas, a quantidade de neurônios por camada foi fixada em 20. O símbolo n.s. indica que não há diferença estatística entre dois resultados e o asterisco verde mostra média de cada distribuição. . . . .	54
4.4	Acurácia de classificação da Rede Neural Artificial pelo número de neurônios por camada escondida. O símbolo n.s. indica que não há diferença estatística entre dois resultados e o asterisco verde mostra média de cada distribuição. . . . .	55
4.5	Comparação da acurácia de classificação da RNA para diferentes tamanhos das janelas temporais dos dados. O símbolo n.s. indica que não há diferença estatística entre dois resultados e o asterisco verde mostra média de cada distribuição. . . . .	56
4.6	Comparação da acurácia de classificação da SVM para diferentes tamanhos das janelas temporais dos dados. O asterisco verde mostra média de cada distribuição. . . . .	57
4.7	Comparação da acurácia de classificação entre a RNA e a SVM, considerando o escorregamento total. O asterisco verde mostra média de cada distribuição. . . . .	58
4.8	Comparação da acurácia de classificação entre a RNA e a SVM, considerando apenas o escorregamento incipiente. O asterisco verde mostra média de cada distribuição. . . . .	59
4.9	Diferença entre o índice da primeira amostra classificada corretamente e a primeira amostra com <i>target</i> indicando a presença de escorregamento (Delta) para cada objeto. . . . .	60

# Capítulo 1

## Introdução

### 1.1 Contextualização

O *feedback* tátil é muito importante quando se trata da manipulação de objetos, pois permite ter conhecimento da força aplicada na preensão do objeto. Além disso, o *feedback* tátil permite identificar outras propriedades físicas do objeto a ser manipulado, como por exemplo sua forma e rigidez e fornece informações sobre as forças de interação entre o manipulador e o objeto (não apenas forças normais, mas também forças de cisalhamento, que caracterizam o escorregamento [12]).

No corpo humano, principalmente na ponta dos dedos, a detecção da sensação de escorregamento é feita pelos mecanorreceptores, que podem capturar informações como pressão e vibração. O primeiro receptor capaz de perceber o deslizamento é o Meissner Corpúsculo, caracterizado por uma adaptação rápida (FA-I). Ele é ativado por estímulos transitórios e é responsável para fornecer informações sobre vibração, textura e movimentos da pele. O segundo são as células de Merkel, que são classificadas como do tipo de adaptação lenta (aférentes SA-I) e são capazes de detectar informações relacionadas a estímulos estáticos, como pressão e estiramento da pele [26]. Através dessas informações, o ser humano consegue controlar a força de preensão de objetos e assim, evitar que eles caiam.

No entanto, replicar a sensação tátil, para o controle da força de preensão, em máquinas ainda é uma área em desenvolvimento. Com o avanço tecnológico das indústrias, cada vez mais manipuladores robóticos realizam tarefas que antes eram desempenhadas somente por mão humanas. Por isso, a implementação de *feedback* tátil sobre garras mecânicas robóticas é importante para aumentar a precisão do manuseio de objetos e, acima de tudo, garantir a segurança para as pessoas que trabalham com essas máquinas.

Até o momento, poucas aplicações reais utilizam a tecnologia de *feedback* tátil. Além dos atuadores robóticos usados na indústria, esta tecnologia é muito útil na indústria de próteses de membros superiores, pois trazem mais segurança para o usuário nas tarefas diárias e também tornam a sua interação interpessoal mais segura.

Um grande número de pesquisas está emergindo na área de identificação de escorregamento com aplicação no controle da força de preensão em objetos. Diferente tipos de sensores táteis podem ser encontrados na literatura, por exemplo: sensor óptico [33], [36]; piezoelétrico [42],[7], [45], [21],[22],[14], [11]; acústico [12],[28], [37], [13]; piezo resistivo [10],[9]; fotoelástico [11], [15]. Embora a ideia de embarcar sensores de escorregamento em próteses de mão remonte ao final dos anos 80 [4], sensores táteis artificiais ainda estão longe de se igualarem funcionalmente aos biológicos.

Em [33], é utilizado um sistema neuromórfico (baseado no funcionamento dos neurônios do sistema nervoso humano) em que são gerados pulsos à medida que o sensor detecta um deslocamento relativo entre ele e o objeto a ser segurado. Assim, um controlador PI (proporcional integral) foi desenvolvido para o controle da força de preensão e este é atuante apenas na direção de incrementar a força de preensão, caracterizando assim como um controle monotônico. Este autor desenvolveu um limiar adaptativo para a geração dos pulsos, cuja finalidade é a adaptação do sistema para se ter um bom funcionamento para materiais com reflectâncias diferentes. Assim, ele conseguiu contornar uma das limitações da utilização de sensores ópticos para a detecção de escorregamento, que é a baixa performance para materiais transparentes ou com alta reflectância. Em [36], também é utilizado um sensor óptico para a detecção do escorregamento e este autor controla a força de preensão visando minimizar o deslocamento relativo entre o manipulador e o objeto a ser segurado. Como limitações destes dois trabalhos pode-se levantar a diminuição da performance de detecção de escorregamento do sensor óptico em ambientes com muita iluminação externa e em ambientes com o ar muito carregado de macro partículas, que podem obstruir a passagem de luz no receptor deste sensor. Além disso, principalmente para o trabalho de [36], o sistema de controle de preensão não funciona muito bem para objetos transparentes ou com alta reflectância.

Em [45] e [2], é realizada a detecção de escorregamento pela intensidade da força tangencial medida na superfície do objeto a ser prensado. Em [45], é medida a diferença entre dois sensores *strain gauges* para a detecção da força tangencial e em [2], esta força é medida através de um sensor de força mais complexo. Estes trabalhos apresentam a limitação da baixa sensibilidade ao escorregamento e maior tempo de resposta, se comparado aos outros métodos de detecção de escorregamento para controle da força de preensão.

Em [7], é utilizado um sensor de microvibrações do tipo piezoelétrico para a detecção de escorregamento. O controle da força de preensão atua no sentido de minimizar a amplitude da onda de vibração vinda deste sensor. A principal limitação deste trabalho é sua alta sensibilidade a ruídos externos, sejam eles sonoros ou por vibrações.

Diante das limitações referentes ao sensoriamento e aos métodos de controle presentes no trabalhos apresentados acima, foi levantada a seguinte hipótese: A combinação de dois sensores (acústico e pressão) com controle derivado de um sistema de *Machine Learning* pode melhorar a performance de sistemas de preensão de objetos.

No presente trabalho, um conjunto de sensor acústico e sensores de pressão formam um sensor tátil, que desempenha o papel de captar informações táteis do objeto a ser segurado, para ser possível controlar a força ideal de preensão. Esta dissertação apresenta uma alternativa para a detecção de escorregamento usando um design de detecção tátil, com base no princípio da detecção de escorregamento por técnicas de *Machine Learning*.

## 1.2 Objetivo

O objetivo do trabalho é apresentar um sistema capaz de controlar a força ideal de preensão para diversos objetos, através da detecção de escorregamento, que possua um tempo de resposta baixo, pretendendo ser menor ou igual ao tempo médio de percepção de escorregamento em humanos [44], o que torna o sistema capaz de manter uma preensão estável, ou seja, sem deixar o objeto cair do manipulador.

Primeiramente foram avaliadas as melhores estratégias de sensoriamento para detecção do escorregamento. Depois, foi feita uma análise das melhores estratégias de escolha de algoritmo de aprendizado de máquina. Para classificar os eventos, quanto a presença ou ausência de escorregamento, foram comparadas a acurácia de dois algoritmos de *Machine Learning*, sendo eles Support Vector Machines (SVM) e Rede Neural Artificial do tipo Perceptron Multicamadas (MLP) e o melhor entre os dois foi utilizado.

O próximo objetivo consistiu em implementar um sistema para coleta dos dados e treinamento dos algoritmos de *Machine Learning*. Os *targets* utilizados para o treinamento supervisionado do algoritmo foram obtidos por um protocolo, que será detalhado na Seção 3.3. Posteriormente, a acurácia de classificação do sistema foi testada e validada utilizando o método de validação cruzada do tipo *k-fold*. Por fim, foi analisada a performance do sistema para a estabilização da preensão para diferentes objetos.

Por fim, objetivou-se validar o sistema de classificação para dados *offline* e depois

verificou-se a performance do sistema *online*. Os resultados de performance do sistema de controle *online* da força de prensão são comparados com os resultados obtidos de [43] e [5].

### 1.3 Organização da Dissertação

A dissertação está estruturada da seguinte forma: o capítulo 2 apresenta a base teórica que permite a compreensão dos assuntos abordados na dissertação; o capítulo 3 apresenta as procedimentos de detecção de escorregamento em detalhes, mostrando o *hardware* e especificações de *software*, bem como a configuração experimental, usada para a avaliação do método. O capítulo 4, os resultados referentes ao desempenho do sistema são apresentados e o capítulo 5 os discute. Finalmente, o capítulo 6 indica as conclusões e trabalhos futuros.

# Capítulo 2

## Fundamentação Teórica

A seguir serão apresentados conceitos, cujo entendimento é importante para a melhor compreensão do trabalho como um todo.

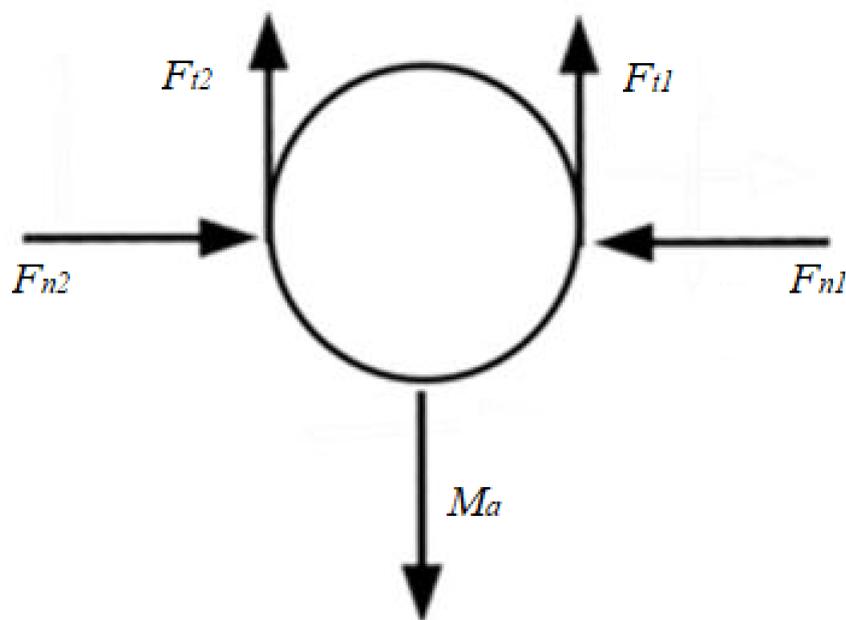
### 2.1 Fenômeno de Escorregamento

Quando se trata da manipulação de objetos mantendo a estabilização de sua preensão, é muito importante detectar o deslizamento, ou escorregamento, entre o manipulador e o objeto, pois esta informação representa um *feedback* para o sistema, dizendo se a força de preensão está correta ou não. Nesta seção será feita uma convenção de que a superfície de contato entre o objeto a ser manipulado e o sensor tátil será chamada de  $S$ . A Figura 2.1 mostra o diagrama de forças durante a preensão de um objeto qualquer, em que  $F_{n2}$  e  $F_{n1}$  representam as forças normais e  $F_{t1}$  e  $F_{t2}$  representam as forças de cisalhamento, ou tangenciais, exercidas entre a superfície de contato do manipulador e do objeto a ser manipulado, por fim  $M_a$  representa a força peso do objeto.

O deslizamento iminente (também chamada do incipiente ou micro deslizamento) é um deslocamento relativo que ocorre em uma região estreita de  $S$ , enquanto o deslizamento total (ou macro) envolve um grande número de pontos de  $S$ . Essas definições implicam que deslizamentos iminentes e totais são fenômenos temporalmente contíguos, com o deslizamento iminente precedendo o deslizamento total [39].

Limitando a análise de forças resultantes à direção vertical, uma estabilidade de preensão (em que ocorre boa aderência entre o manipulador e o objeto, evitando assim o escorregamento) exige que as forças de compressão sejam reguladas para que  $F_{t1} + F_{t2} = M_a$ . A estratégia mais simples para evitar o escorregamento de objetos consiste em regular a componente normal da força de preensão  $F_n$ , para assim modificar a força de cisalhamento  $F_t$  e igualar

Figura 2.1: Diagrama de forças durante a prensão de um objeto.



Fonte: O autor (2020).

à força peso do objeto. De fato, eventos de escorregamento podem ocorrer se pelo menos uma das seguintes condições for verificada: i) a força de prensão normal é insuficiente, o que pode ocorrer durante sua aplicação gradual a partir de uma condição sem carga ou se as propriedades do objeto, por exemplo a massa, são estimadas incorretamente; ii) quando a força tangencial, que deve ser contrabalançada, é maior do que o esperado ou aumenta muito rapidamente (por exemplo, devido a uma perturbação inesperada, como uma colisão); ou iii) o coeficiente de atrito se torna muito baixo, como no caso de superfícies molhadas e escorregadias [12].

## 2.2 Sensores Biológicos

O corpo humano possui diversos sensores. Os proprioceptores são responsáveis pela detecção da posição e movimento dos membros do corpo, enquanto os mecanorreceptores, que estão ramificados em diferentes profundidades da pele, desempenham o papel de detectar estímulos externos, fornecendo informações sobre atrito e forças de interação [12].

Cada mecanorreceptor é responsável por detectar estímulos específicos. Eles recebem informações táteis (como pressão e força cisalhante) e convertem em *spikes*, ou seja, picos de tensão gerados quando é ultrapassado um certo *threshold*, ou limiar. Os sinais produzidos pelos mecanorreceptores são então transmitidos ao Sistema Nervoso Central (SNC) por meio de vias

aferentes paralelas. Eles são classificados em dois principais grupos: os de adaptação rápida (RA1 e RA2, ou do inglês *Rapidly Adapting*) e os de adaptação lenta (SA1 e SA2, ou do inglês *Slowly Adapting*).

Serão descritos os quatro mecanorreceptores presentes nas pontas dos dedos do corpo humano:

1 – Corpúsculo de Pacini: se localizam na parte mais profunda da derme e são capazes de detectar estímulos táteis e vibrações. São compostos por fibras nervosas, dispostas em camadas, que desempenham a função de células de sustentação. A camada disposta mais externamente é capaz de detectar a pressão exercida e este sinal é propagado às outras camadas e enviado ao centros nervosos correspondentes. Os corpúsculos de Pacini são os mecanorreceptores com adaptação mais rápida entre todos os quatro, assim, são classificados como do tipo FA2.

2 – Discos de Merkel: são capazes de adquirir sensibilidade tátil e de pressão. Eles são localizados na parte menos profunda da pele, têm a forma de um disco e são fixados às células da epiderme somente por suas extremidades, assim são capazes de detectar forças de pressão e cisalhamento (tração) sobre a pele. São receptores de resposta lenta, do tipo SA1, e são capazes de detectar a localização exata do estímulo e reconhecer a forma do objeto tocado.

3 – Corpúsculos de Meissner: são encontradas na região superior das impressões digitais dos dedos, logo abaixo do fim da epiderme. Sua forma se assemelha com espiras e eles possuem a capacidade de detectar estiramento da pele, movimentos leves e vibrações de baixa frequência. Por serem classificados no tipo FA1, só respondem à estímulos transientes, por isso, não são ativados com aplicação de pressão contínua.

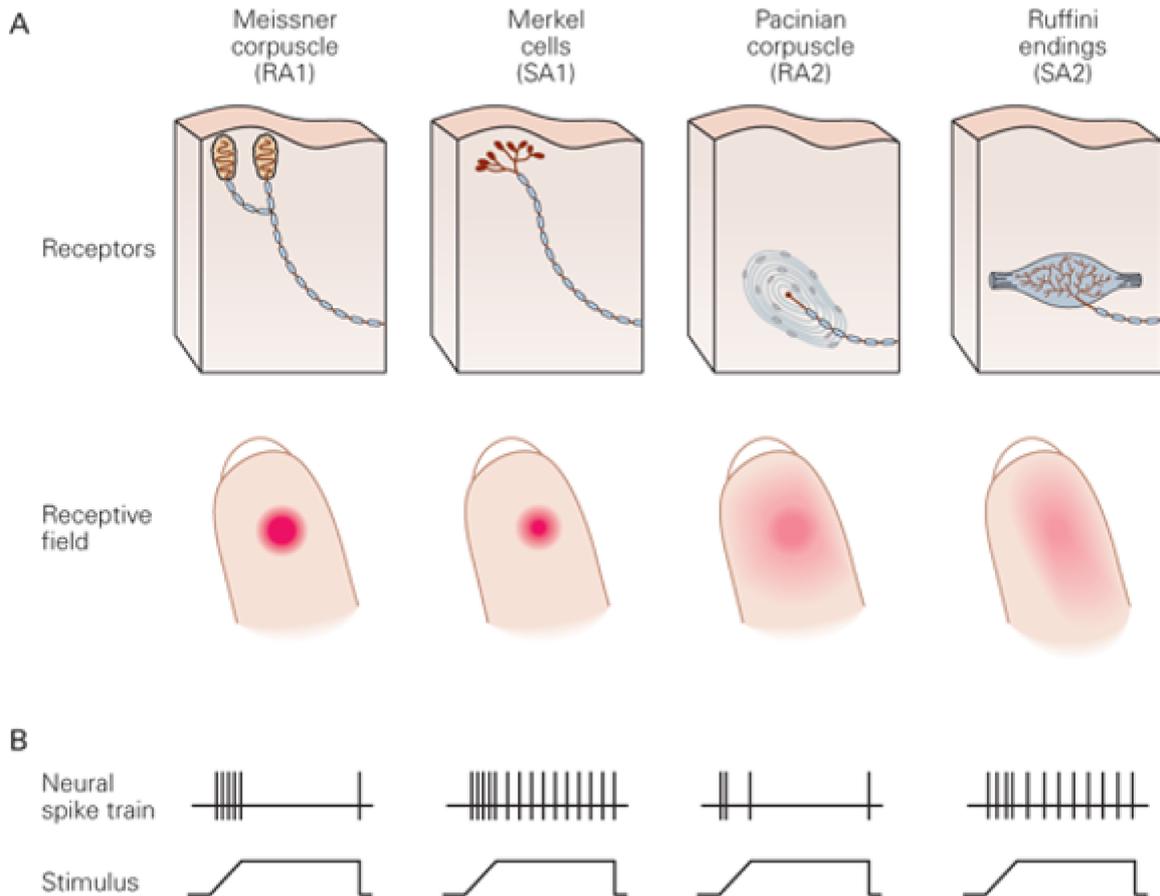
4 - Terminais de Ruffini: se localizam em camadas mais profundas da pele e são especialistas na detecção de pressão estática, sendo ativados em todas as direções de pressão aplicada. Por serem de resposta lenta, são classificados como mecanorreceptores do tipo SA2.

Estudos mostram que o deslizamento é detectado, principalmente, pelos receptores FA2, que são os mecanorreceptores mais sensíveis a vibrações (Tabela 2.1) [39]. Os receptores do tipo FA2 captam a intensidade da força de cisalhamento, enquanto que os receptores FA1, SA1 e SA2 captam informações sobre a direção do deslizamento [31].

A Figura 2.2 mostra a localização espacial de cada mecanorreceptor, ou seja, o quão profundo eles estão na pele humana e a região de percepção de cada tipo de receptor na ponta dos dedos. Por fim, é possível notar suas respostas frente a estímulos de pressão externa. Os mecanorreceptores de adaptação rápida (Corpúsculo de Meissner - RA1 e Corpúsculo de Pacini - RA2) são ativados quando há presença de estímulos transientes, ou seja, quando há

variação da pressão exercida ou presença de vibração na superfície de contato da pele. Já os mecanorreceptores de adaptação lenta (Células de Merkel - SA1 e Terminações de Ruffini - SA2) apresentam resposta frente a todo tipo de estímulo e são especializados em detecção de sinais estáticos ou com variação lenta.

Figura 2.2: Mecanorreceptores e suas respostas frente a estímulos externos



Fonte: [27].

Tabela 2.1: Mecanorreceptores e suas características [12].

Mecanorreceptores	Densidade Espacial na ponta dos dedos	Diâmetro de Percepção	Faixa de Frequência	Parâmetro de Detecção
Merkel (SA1)	750/cm <sup>2</sup>	3-4 mm	0-30 Hz	Compressão
Ruffini (SA2)	75/cm <sup>2</sup>	>10 mm	0-15 Hz	Direção de estiramento
Meisser (FA1)	1500/cm <sup>2</sup>	3-4 mm	10-60 Hz	Estiramento da pele
Pacini (FA2)	75/cm <sup>2</sup>	>20 mm	50-1000 Hz	Vibração

## 2.3 Sensores Táteis

O sensor de escorregamento básico é um dispositivo binário capaz de detectar a presença e ausência de escorregamento. Alguns sensores são capazes de detectar escorregamento em sua fase iminente, outros apenas o escorregamento total. Sensores mais complexos podem fornecer informações sobre a direção e a velocidade do escorregamento. Mesmo que a maioria dos sensores táteis seja bioinspirado [8], [41], a capacidade de percepção de escorregamento ainda é difícil de ser replicada, pois não existe um único receptor específico dedicado à detecção de escorregamentos a ser imitado, mas sim todo um conjunto de sensores que, juntos, detectam diversas sensações táteis.

A falta de um modelo biológico claro para se inspirar gerou uma grande variedade de abordagens, que diferem entre si em termos de: i) parâmetros a serem monitorados (por exemplo, deslocamento de objetos, microvibrações, forças normais e de cisalhamento, fluxos térmicos), ii) mecanismos de transdução (por exemplo, piezoresistivos, piezoelétricos, capacitivos, ópticos, magnéticos, térmicos) e iii) soluções tecnológicas (por exemplo, materiais macios ou flexíveis).

A seguir serão detalhadas algumas das tecnologias utilizadas no sensoriamento para a detecção do evento de escorregamento.

### 2.3.1 Sensores de Deslocamento

Os sensores de deslocamento são capazes de detectar o escorregamento a partir do movimento relativo entre o objeto a ser prensado e a superfície do sensor.

Este deslocamento pode ser mensurado através do movimento de peças mecânicas, como discos ou esferas, conectadas a transdutores magnéticos ou ópticos [46]. Como as partes mecânicas são propensas ao acúmulo de impurezas (causando assim maior atrito entre os componentes e prejudicando o funcionamento global do sistema), os sensores mais recentes não têm mecanismo externo de movimento e detectam o deslocamento relativo comparando uma sequência de imagens capturadas por um sensor a cada emissão de luz de um foto diodo (LED). O sensor de deslocamento tanto em sua configuração mecânica ou óptica é capaz de fornecer informações sobre a velocidade e a direção do escorregamento.

A configuração mecânica do sensor em questão é utilizada principalmente nos efetores finais dos manipuladores industriais. Apesar do baixo custo e da baixa sensibilidade à rugosidade do objeto, sua aplicação nas próteses de mão é dificultada pela difícil integração em luvas cosméticas, ou seja, próteses que são mais semelhantes com a mão humana, pois o uso

destes sensores deixa a prótese com aspecto mais robótico do que humano. Além disso, as peças mecânicas em movimento, mediante o contato entre o manipulador e o objeto, podem afetar negativamente a estabilidade da preensão, dificultando assim o manuseio de objetos.

Algumas tentativas foram relatadas na literatura integrando sensores ópticos e de pressão [20], [23]. O algoritmo de controle do sistema de preensão dos objetos foi implementado baseando em sistemas bioinspirados.

É possível apresentar como vantagens dos sensores de deslocamento a sua baixa sensibilidade às vibrações externas do sistema (por exemplo, o acionamento de um motor) e à rugosidade do material, o que torna a sua performance semelhante para objetos ásperos, lisos ou até com presença de água ou óleo em sua superfície. Porém eles apresentam comportamento bastante distinto em superfícies com reflectâncias diferentes (por exemplo, borracha de cor escura e vidro branco). Outro detalhe importante a respeito de sensores de deslocamento é que a sensibilidade de deslocamento mínimo depende da resolução do sensor. Assim, o escorregamento iminente se torna difícil de ser detectado por sensores mais simples, o que prejudica o tempo de resposta do sistema ao utilizar estes sensores.

### 2.3.2 Sensores de Microvibrações

A fase inicial do escorregamento, ou escorregamento iminente, produz pequenas vibrações na superfície de contato entre o sensor e o objeto. Nos seres humanos, a percepção de escorregamento é baseada na detecção de vibrações que variam de 50 a 1000 Hz (receptores FA2), entretanto, de acordo com [10], as pontas dos dedos podem identificar o evento de escorregamento em sinais com uma frequência máxima de aproximadamente 300 Hz. Foram fornecidas evidências sobre a capacidade de detectar o deslizamento iminente por meio de microvibrações em [8], [41].

A vibração pode ser detectada diretamente (medindo a intensidade e a frequência da vibração) ou indiretamente (caracterizando a fonte de excitação, ou seja, as forças aplicadas ao sistema). Pode-se citar como exemplo de sensores de microvibrações os sensores acústicos, acelerômetros, sensores piezoelétricos.

#### **Sensores Acústicos**

Os transdutores de vibração direta são acelerômetros ou dispositivos acústicos. Transdutores indiretos geralmente são baseados em sensores de carga. Nos dois casos, devido à natureza do sinal, geralmente é realizada uma análise de Fourier com o objetivo de se analisar o

sinal no domínio da frequência. Diferentes algoritmos foram desenvolvidos para implementação e análise do sinal gerado pela Transformada Rápida de Fourier (FFT) [19]. Existem aplicações para detecção de escorregamento em que o sinal gerado pela FFT é comparado com um *threshold* definido de maneira *offline* [19] e outras em que este sinal é avaliado de maneira *online*, ou em tempo real, utilizando Redes Neurais Artificiais (RNA) [6].

A desvantagem apresentada por sensores acústicos, para a aplicação de detecção de escorregamento é a sua sensibilidade a ruídos sonoros externos, que podem ser gerados por sons próximos ao sistema, vibrações causadas pelo acionamento de motores ou atrito de partes móveis. Estes sinais ruidosos podem confundir o sensor acústico e fazê-lo identificar fenômenos erroneamente. Porém alguns fatores podem reduzir a presença de ruídos externos neste tipo de sensor, como, por exemplo, a estratégia de posicionamento do sensor no sistema, um revestimento acústico adequado (geralmente feito em espuma) na superfície de contato entre o sensor e o objeto e um circuito condicionador utilizando filtros adequados.

A sua grande vantagem, para a aplicação descrita, é exatamente a sua alta sensibilidade na captação de vibrações, sejam elas vindas de um meio gasoso (por exemplo, o ar) ou sólido. Este último é essencialmente importante para o sistema proposto, pois o escorregamento gera microvibrações que são propagadas em materiais sólidos e podem ser captadas por um sensor acústico. Assim, sua capacidade de detectar microvibrações com boa sensibilidade os fazem capazes de detectar o escorregamento incipiente, o que os tornam de grande utilidade para o controle de garras robóticas, pois conseguem ter uma resposta rápida e agir antes do escorregamento total.

## Microfone de Eletreto

Materiais da categoria eletreto são aqueles cuja concentração de cargas pode ser alterada quando sofrem influência de pressão ou deformação externa. Um microfone de eletreto é montado com um disco deste material acoplado a um diafragma. Em um lado do disco, um transistor de efeito de campo (FET) é inserido, quando as ondas sonoras atingem o diafragma do microfone, o acoplamento mecânico deforma o eletreto causando uma variação das cargas e, portanto, variando a tensão aplicada à porta do transistor. O resultado é que a corrente no transistor varia proporcionalmente à forma de onda do som incidente [40].

A vantagem de se usar um FET é que o transistor já atua como um amplificador de sinal. Suas principais características são o tamanho pequeno, cerca de 10 mm de diâmetro e 4,5 mm de espessura, alta relação de sinal-ruído e também o fato de ser unidirecional, o que

significa uma boa captação de sons emitidos em direção ao sensor, mas a detecção de som em direções transversais tem amplitude menor. Sua faixa de frequência captável é de 100 Hz a 12.000 Hz.

### 2.3.3 Sensores de Força

Um dos métodos mais simples de controle para evitar eventos de escorregamento utilizando um sensor de força é estimar em tempo real a força de prensão normal necessária para equilibrar a força tangencial (Figura 2.1). Esse cálculo pode ser realizado diretamente se o coeficiente de atrito é conhecido e pode levar em conta as propriedades mecânicas da superfície de contato do sensor através de um modelo de contato [32].

Os sensores de força podem possuir até três eixos de mensuração e os exemplares mais completos são mais utilizados na detecção de escorregamento, pois permitem detectar simultaneamente forças normais e de cisalhamento [18].

Seu princípio de funcionamento é baseado na modificação do seu padrão de impedância, de acordo com a magnitude e a direção da força aplicada sobre ele, a localização do ponto de contato e a forma do objeto. Alguns exemplos de sensores de força são células de carga, *strain gauges* e materiais piezoresistivos.

Estes sensores apresentam a vantagem de serem robustos e terem boa acurácia de detecção de escorregamento para diversos tipos de materiais diferentes, independente da rugosidade, rigidez ou reflectância. Porém não apresentam sensibilidade equiparável aos sensores acústicos para a captação de pequenas vibrações, por isso não têm bons resultados para identificar o escorregamento iminente, o que pode prejudicar no tempo de resposta do sistema de controle online da prensão de objetos.

Diante deste sensores apresentados, foi utilizado no protótipo desenvolvido um sensor acústico para detecção de escorregamento, juntamente com sensores de força. A seguir serão apresentados conceitos importante para entendimento dos métodos de utilizados para conexão e aquisição destes sensores para que o sistema de controle funcione corretamente.

## 2.4 Hardware

### 2.4.1 Comunicação de Dados

Uma comunicação de dados segura e completa exige que todos os dados sejam enviados em sua sequência correta. De nada adianta enviar todos os dados de uma série temporal, sem

que a sequência deles seja correta, pois neste caso, a informação sobre o sinal seria completamente distorcida.

Para que esta comunicação de dados funcione da melhor forma, foram desenvolvidos os protocolos de comunicação, que são convenções que controlam e possibilitam a conexão, comunicação e transferência dos dados entre dois, ou mais, sistemas computacionais. Estes protocolos gerenciam a sintaxe, semântica e sincronização da comunicação e podem ser implementados via *hardware*, *software* ou pela combinação dos dois [16].

A sintaxe representa o formato dos dados e a ordem a que estes dados são apresentados. A semântica refere-se ao significado de cada conjunto sintático que dá sentido à mensagem enviada. Por fim, a sincronização define a velocidade de envio e recebimento dos dados.

Em grande parte dos computadores domésticos e em algumas máquina industriais, a comunicação de dados inter máquinas é realizada pela comunicação Serial seguindo o protocolo USB ( Universal Serial Bus, ou em português, porta serial). Este é um padrão que estabelece especificações para os cabos de transmissão, conectores e protocolos de comunicação, conexão e provimento de energia entre computadores e seus dispositivos periféricos.

A comunicação serial foi utilizada no trabalho para envio dos dados dos sensores entre os dois dispositivos, o computador e a placa processadora. A seguir são detalhadas as características da placa processadora e a máquina CNC utilizada para a alteração da força de prensão dos objetos.

## 2.4.2 Placa processadora

Uma placa processadora é uma plataforma de prototipagem eletrônica que permite o desenvolvimento de projetos de controle de sistema interativos. A plataforma é comandada por meio de instruções de código escritas no microprocessador do sistema. Ao enviar o código, ele ficará armazenado no chip microcontrolador (*firmware*), por isso não há necessidade de sistemas operacionais ou a realização de *boot* ao ligar a plataforma. Isso faz com que o sistema esteja em funcionamento, assim que ele for alimentado.

A placa utilizada no trabalho tem como software de programação, um compilador gcc (C e C++) baseado em *Wiring*, em que possui um interface gráfica construída em Java. Apesar de sua interface de desenvolvimento ser bastante intuitiva e repleta de bibliotecas contendo funções prontas para diversas aplicações, é possível programar seu microcontrolador em linguagem de baixo nível, sendo possível a manipulação digital dos registradores diretamente do chip, para que se obtenha a maior performance possível, com menor tempo de reposta entre os comandos

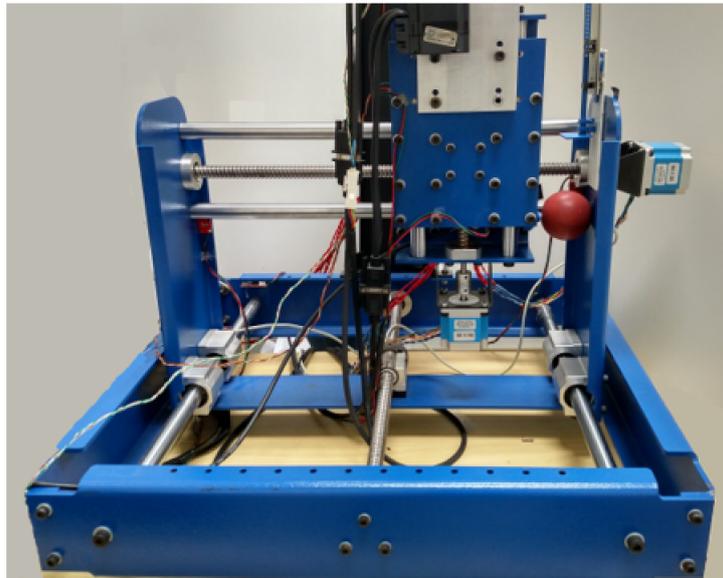
programados.

Seu hardware é composto de um regulador de tensão DC para 5V ou 3.3V (a depender do modelo da placa) para alimentação da placa por fonte externa; um conector USB para transmissão de dados entre a placa e um PC, e para o carregamento do *software* no microcontrolador; pinos de entrada e saída digitais e analógicas para leitura de sensores e envio de sinais para controle de atuadores; conversores analógico-digitais (DAC) para leitura de sinais analógicos vindos de sensores externos. Além desses componentes, a placa dispõe de um microcontrolador, com *clock* definido, que varia entre modelos diferentes. Seu tempo de uma instrução de máquina é igual ao intervalo entre dois pulsos de seu *clock* interno. Assim, em modelos mais avançados é possível atingir um intervalo de instruções de máquina de cerca de 12 ns.

### 2.4.3 Máquina de Controle Numérico Computadorizado (CNC)

Um controle numérico computadorizado (CNC, do inglês Computer Numeric Control) é uma máquina que permite o controle da posição de um manipulador em diferentes eixos. Geralmente, um motor é responsável pelo movimento do manipulador de cada eixo, totalizando 3 motores, que atuam assincronamente para movimentá-lo em todo o espaço de operação. A Figura 2.3 mostra a máquina CNC utilizada, sendo ela controlada por motores de passo.

Figura 2.3: Máquina CNC utilizada, com controle por motores de passo.



Fonte: O autor (2020).

O controle simultâneo da movimentação em vários eixos é possível através de comandos escritos em um código em linguagem específica, chamada de código G (ou *G-code*, em inglês).

As máquinas CNC permitem movimentos mais rápidos e precisos, se comparado às

capacidades humanas, e assim, são capazes de confeccionar peças complexas (especialmente quando usada em conjunto com os atuais programas CAD/CAM) e também realizar a movimentação de peças por meio de caminhos precisos, definidos previamente, via *G-code*.

Em [43] e [5], a alteração da força de prensão é realizada por meio da movimentação unilateral dos sensores em apenas uma direção. Assim, decidiu-se seguir o mesmo procedimento de alteração da força de prensão e para isto, foi utilizada a máquina CNC.

A placa processadora e a máquina CNC foram utilizadas com o intuito de adquirir os dados dos sensores e controlar a força de prensão sobre o objeto, respectivamente. Assim, para que seja possível fechar a malha de controle para detecção de escorregamento e atuação sobre a força de prensão, foi utilizado um algoritmo de aprendizado de máquina (ou *Machine Learning*, em inglês) para detecção do escorregamento, a partir da análise dos sinais dos sensores.

## 2.5 Machine Learning (Aprendizado de Máquina)

O termo aprendizado de máquina muitas vezes se confunde com inteligência artificial, mas não são exatamente a mesma coisa. O aprendizado de máquina consiste em construir um modelo a partir de dados de entrada, para que seja possível realizar previsões e decisões de acordo com os dados inseridos durante o seu treinamento. Quando se fala de inteligência artificial, é englobado todo o conceito de adaptação de um algoritmo para realizar tarefas que ele não esteja programado anteriormente. Por isso, o conceito de aprendizado de máquina se encaixa dentro do grande conceito de inteligência artificial [38].

O aprendizado de máquina consiste no desenvolvimento de algoritmos que são capazes de aprender através de seus erros e até realizar previsão de dados. Estes algoritmos nada mais são que modelos matemáticos em que seus coeficientes são ajustados a partir do erro de reposta entre a saída prevista e a saída obtida, para um conjunto de dados amostrais apresentados em sua entrada. As técnicas utilizadas para o ajuste desses coeficiente se baseiam na teoria da estatística [24].

O aprendizado de máquina consiste em uma análise heurística do conjunto de dados de uma população e vem substituindo os algoritmos determinísticos, em que é feita a busca completa em todas as amostras possíveis da população, o que muitas vezes se torna uma tarefa impraticável computacionalmente. É possível citar como aplicações de algoritmos de aprendizado de máquina o reconhecimento de rostos por imagem, diagnósticos médicos, reconhecimento de fala, visão computacional e locomoção de robôs autonomamente.

Pode-se dividir os algoritmos de aprendizado de máquina em três principais grupos

em relação à forma de treinamento, sendo eles: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço [35].

No aprendizado supervisionado, as amostras inseridas durante o treinamento são rotuladas, ou seja, o algoritmo já tem as respostas ideais para cada amostra de entrada, por isso o ajuste de seu modelo interno se baseia na minimização do erro entre a saída calculada e a saída ideal, também chamada de *target* (alvo ou resposta esperada de cada amostra de entrada).

No aprendizado não supervisionado, não há rotulagem das amostras inseridas durante o treinamento, por isso não há como calcular o erro de classificação entre a saída obtida e esperada. Assim, o treinamento consiste em separar as amostras em um número pré-definido de grupos. Esta separação é feita por semelhança entre grupos, cada grupo será formado por amostras que compartilham uma característica em comum. Este tipo de separação de dados pode ser utilizada para encontrar novos padrões em uma população de amostras de dados.

Por fim, no aprendizado por reforço, o algoritmo deve atingir determinado objetivo, assim o seu modelo é ajustado com base em recompensas e punições quanto ao score alcançado para tal objetivo.

Outra categorização dos algoritmos de aprendizado de máquina é feita em relação à forma como a saída é apresentada e qual o seu propósito. Primeiramente, tem-se a classificação de dados, em que o conjunto de amostras de entradas é dividido em duas ou mais classes. Através do treinamento supervisionado, o algoritmo aprende que o grupo de amostras que apresentam certas características devem ser classificadas em uma classe e outro grupo, que apresentam características distintas, deve ser classificado como presente à outra classe [35].

Outra categoria é a regressão de dados. Nesta categoria são apresentadas amostras com saídas rotuladas (*targets*) contínuos, ao invés de discretas no caso da classificação. O objetivo deste tipo de algoritmo é fazer a interpolação ou extrapolação de um série temporal, por exemplo, para se prever dados futuros ou reconstruir dados dentro da distribuição de amostras utilizadas durante o treinamento.

Um outra possível categoria de algoritmos de aprendizado de máquina é a redução dimensional, em que é feita a compactação dos dados de entrada ao mapeá-los para um espaço de menor dimensão [35].

A partir de agora, focaremos na classificação de dados, utilizando treinamento supervisionado, por isso será utilizado, diversas vezes, o termo classificador para se referir ao algoritmo de aprendizado de máquina. Segundo [25] e [17], o treinamento supervisionado é mais indicado para os casos em que são conhecidas as classes em que se deseja separar os dados de entrada e quando é possível rotular os dados de entrada. Diante disso, foi feita a escolha do treinamento

supervisionado.

Existem algumas técnicas utilizadas para a otimização da acurácia de classificação do algoritmo classificador, dentre elas pode-se exemplificar o pré-processamento dos dados antes de serem inseridos na entrada do algoritmo.

O pré-processamento consiste em refinar os dados para que estes possam exprimir melhor as características mais marcantes de cada classe e assim facilitar a classificação entre as duas populações de amostras e aumentar a acurácia. Outra causa do pré-processamento dos dados é a retirada da redundância de informações entre as amostras.

As técnicas de pré-processamento estão divididas em dois grandes grupos, a seleção de características e a extração de característica. Na primeira, são selecionados apenas os mais relevantes atributos (ou características) das amostras, sem que nenhuma informação seja transformada, apenas selecionada entre tantos dados disponíveis.

Um exemplo de seleção de características para sinais temporais é selecionar apenas as regiões da amostra que contêm picos (cristas e vales) e descartar todos os outros pontos fora destes intervalos.

Na segunda categoria de pré-processamento, a extração de características consiste em calcular novos parâmetros, que possuem natureza diferentes daqueles dados originais das amostras. Um exemplo de extração de características para um sinal temporal é calcular a média, variância e valor de pico a pico de uma amostra de uma forma de onda e substituir toda a amostra de dados por apenas estas informações, que representam as amostras de uma maneira diferente.

A seguir serão apresentados dois exemplos de algoritmos classificadores, que são utilizados na literatura para a classificação de sinais temporais [3].

### 2.5.1 Redes Neurais Artificiais

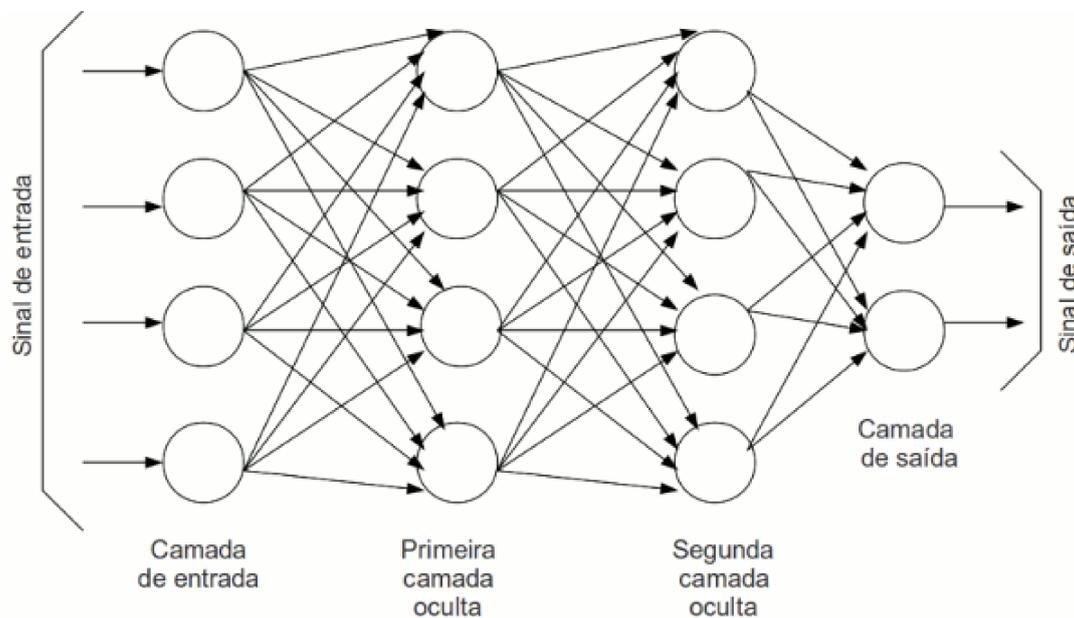
A rede neural artificial (RNA) é um algoritmo baseado nas redes neurais biológicas, mais especificamente no funcionamento dos neurônios do corpo humano. Cada neurônio do corpo humano é interligado com diversos outros e a sua ativação depende do conjunto dos sinais vindos de todos os outros neurônios conectados a ele. Assim também ocorre com a rede neural artificial, cuja estrutura é formada por uma rede de neurônios e a saída depende dos sinais de todos os outros neurônios conectados a ele [3].

O sinal de saída de cada neurônio é calculado pelo somatório de todos os neurônios da camada anterior multiplicados pelos seus respectivos pesos (valor da conexão de dois neurônios)

e ao final adicionado a um viés (ou *bias*). Após calculado este somatório, o valor é inserido em uma função de ativação (mais comumente a função sigmoide binária ou bipolar, mas há diversas outras) e a resposta final do neurônio é o valor de  $f(x)$  desta função de ativação. A única diferença ocorre nos neurônios da camada de saída da rede neural artificial, em que a função de ativação é uma função linear, que não mais está compreendida no intervalo de 0 a 1, ou -1 a 1, mas sim pode resultar em outros valores fora deste intervalo, ou seja, permite valores na faixa de saturação da função sigmoide.

O ajuste dos pesos da rede neural artificial é realizado por um algoritmo de *backpropagation* (ou retropropagação do erro) durante a fase de treinamento, que visa minimizar o erro de resposta dos neurônios da camada de saída. A medida que as amostras são mostradas para a RNA com seus respectivos *targets*, é calculado o erro (geralmente utilizado o erro quadrático médio) entre a saída obtida e o *target* e então este erro é propagado para as camadas intermediárias (ou escondidas), do sentido da saída para a entrada, e o ajuste dos pesos de cada camada é ajustado seguindo uma formulação específica [29]. A Figura 2.4 mostra a estrutura básica de uma rede neural artificial.

Figura 2.4: Estrutura básica de uma Rede Neural Artificial.



Fonte: [1]

Cada neurônio representa um coeficiente de seu modelo matemático. Assim, quanto maior o número de neurônios e camadas escondidas presentes na arquitetura da RNA, mais informações serão extraídas do conjunto de amostras apresentadas durante seu treinamento.

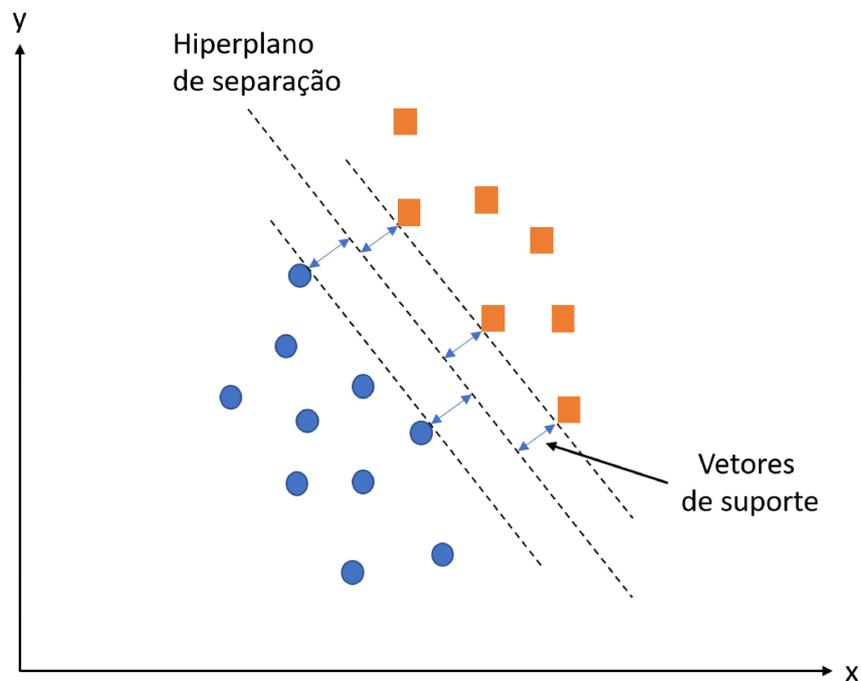
## 2.5.2 Máquina de vetores de suporte

A Máquina de Vetores de Suporte (SVM) é um algoritmo de classificação binária, ou seja, diferentemente da RNA, a SVM é capaz de separar somente duas classes distintas.

Este algoritmo também se encaixa na categoria de aprendizado supervisionado, então é necessário fornecer os *targets* de cada amostra, ao serem apresentadas na fase de treinamento. O ajuste de modelo consiste em traçar um hiperplano que irá separar as amostras em duas regiões diferentes no espaço de  $n$  dimensões (em que  $n$  é o tamanho da amostra de entrada) e assim, irá maximizar a distância das amostras mais próximas a este hiperplano, para as duas classes distintas [43].

Somente as amostras mais próximas ao hiperplano (para ambos os lados) são consideradas, pois o restante não influencia na posição desta região de separação. Esta distância entre as amostras mais próximas e o hiperplano de separação é chamada de vetor de suporte. O algoritmo tem o objetivo de encontrar a região ideal para inserir o hiperplano de separação para que os vetores de suporte sejam maximizados de ambas as classes [34]. A Figura 2.5 mostra o princípio de funcionamento da separação de classes de uma Máquina de Vetores de Suporte para entradas com apenas duas dimensões.

Figura 2.5: Princípio de funcionamento da separação de classes de uma Máquina de Vetores de Suporte para entradas com apenas duas dimensões.



Fonte: O autor (2020).

As duas técnicas de aprendizado de máquina aqui apresentadas são muito importantes

para o funcionamento do sistema de controle, pois elas permitem a detecção do evento do escorregamento a partir da análise dos sinais dos sensores. Em [43] e [5], são utilizadas técnicas de *Machine Learning* para a detecção de escorregamento através da entrada dos sinais dos sensores.

# Capítulo 3

## Metodologia

### 3.1 Descrição do Hardware

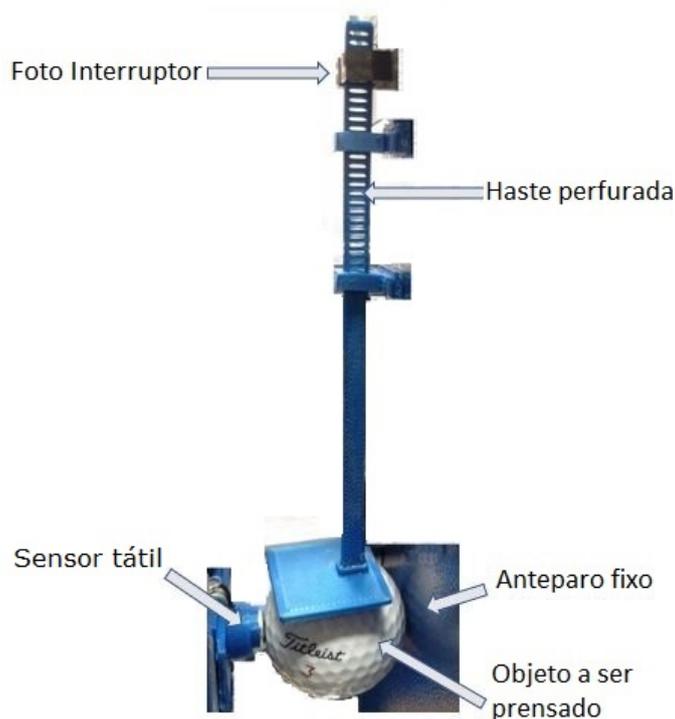
Para a validação do trabalho, foi desenvolvido um sistema capaz de executar a prensão de objetos em apenas uma direção. Uma máquina do tipo CNC foi utilizada e apenas um de seus eixos foi alterado. Desta maneira, o movimento do manipulador (em que foi acoplado o sensor tátil) foi controlado por um motor elétrico, do tipo motor de passo, sendo possível o controle da força de prensão de objetos contra um anteparo fixo. A Figura 3.1 mostra o protótipo desenvolvido.

O sistema consiste em sensores (formando um sensor tátil), que são conectados a um microcontrolador. É feita a comunicação dos dados dos sensores, via USB, com um PC, cuja finalidade é o processamento dos dados e detecção do evento de escorregamento. Caso o escorregamento seja detectado, o PC envia um comando ao microcontrolador, que em seguida define o movimento do manipulador para controlar a força de prensão do objeto. A Figura 3.2 mostra a montagem do hardware.

#### 3.1.1 Sensoriamento

Antes do desenvolvimento do sensor tátil proposto, foi analisado qual sensor seria a melhor escolha para ser utilizado na detecção de escorregamento. Assim, foram feitos testes com dois sensores, para verificar se o comportamento de seu sinal seguia um mesmo padrão se o sensor fosse deslizado sobre superfícies com diferentes rugosidades, ou diferentes coeficientes de atrito. O sensor escolhido foi aquele que conseguiu diferenciar melhor o sinal referente ao escorregamento, dentre o sinal estático.

Figura 3.1: Sistema desenvolvido de controle unidirecional da força de prensão.



Fonte: O autor (2020).

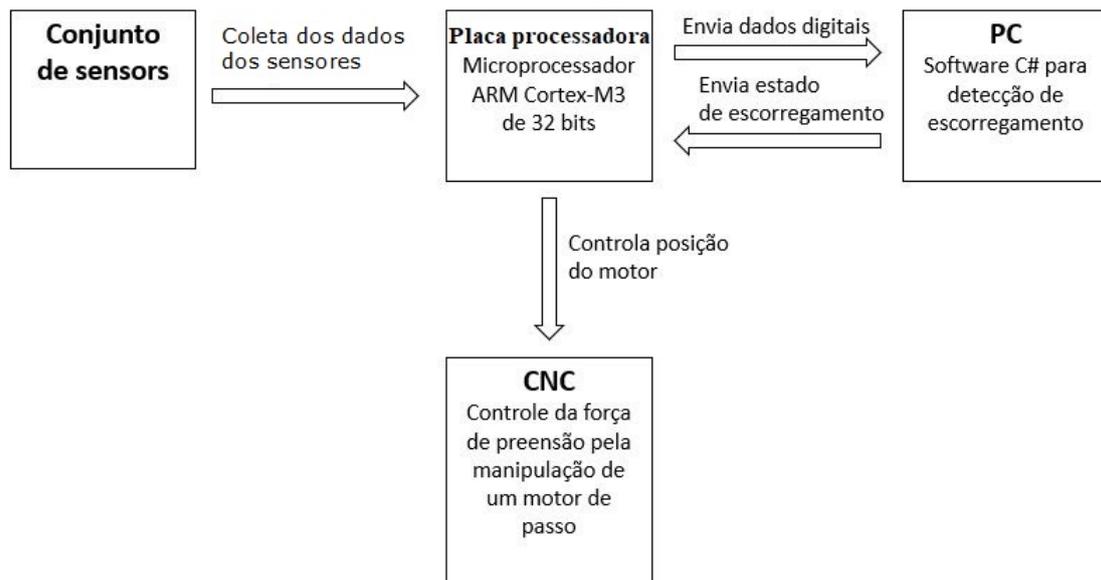
### Experimento para análise da sensibilidade de sensores para detecção de escorregamento

Primeiramente, foi utilizado um sensor de pressão do tipo FSR400 (*Force Sensing Resistor*) com o intuito de detectar o evento de escorregamento.

O sensor FSR400 é um resistor cuja resposta se caracteriza pelo decremento de sua resistência ao passo que há um aumento da força aplicada em sua superfície. Ele possui uma forma circular com dimensões de 0.35 mm de espessura e 7.62 mm de diâmetro, considerando-se apenas a região ativa e ignorando fios de transmissão. Sua faixa de detecção de força aplicada é de 0.1 N até 100 N e sua resolução é contínua, ou seja, consegue captar todas as forças possíveis dentro dessa faixa.

Foi montado um protocolo em que o sensor foi deslizado sobre diferentes superfícies (com rugosidades diferentes) e sua pressão foi mantida sempre constante durante todo o deslizamento. Isto foi possível com o uso de uma máquina CNC que foi programada, via *G-code*, para os seguintes procedimentos: i) pressionar o sensor contra a superfície, até que ele chegasse a um valor de pressão pré-estipulado; ii) deslizar o sensor sobre a superfície por 15 cm; iii) suspender o sensor, até que ele perdesse o contato com a superfície; iv) voltar para a posição inicial. Este experimento de coleta dos dados do sensor de pressão é ilustrado na Figura 3.3.

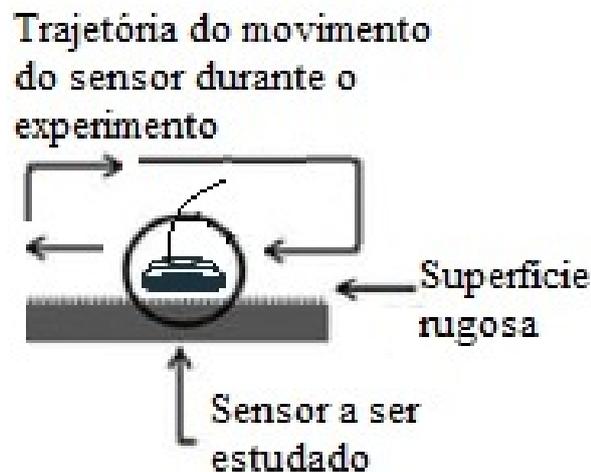
Figura 3.2: Diagrama de funcionamento do hardware.



Fonte: O autor (2020).

O processo foi repetido 10 vezes para 4 superfícies diferentes.

Figura 3.3: Setup do experimento para verificação das resposta dos sensores de pressão e acústico, frente à presença de escorregamento.



Fonte: O autor (2020).

Depois de feitas as 40 coletas dos sinais, o próximo passo do experimento foi alterar a pressão exercida entre o sensor e a superfície de contato. Assim, foram feitos 3 conjuntos de testes, o primeiro com pressão de 0.5 N, o segundo com pressão de 1 N e o terceiro com pressão de 5 N. O teste da variação da pressão exercida no sensor foi realizado com o intuito de verificar a sensibilidade do sinal do sensor frente à pressão exercida, ou seja, se ele consegue detectar o evento de escorregamento na prensão de objetos com força elevada e com baixa força.

Após o teste com o sensor de pressão, foi repetido o mesmo experimento com o sensor acústico, do tipo microfone de eletreto. Assim, por meio da máquina CNC, este sensor foi deslizado sobre 4 superfícies diferentes por 15 cm e cada teste foi repetido 10 vezes. Os resultados destes experimentos são mostrados na seção 4.1.

De acordo com a análise do sinal coletado dos sensores, foi escolhida a utilização do sensor acústico para o desenvolvimento do sistema proposto. A discussão dos resultados deste teste e o porquê desta escolha são mostrados na seção 5.1.

## Sensor Tátil desenvolvido

Após a escolha do melhor sensor para detectar o evento de escorregamento, foi desenvolvido o *hardware* de sensoriamento usando peças impressas em uma impressora 3D, de modo que elas se encaixassem perfeitamente na parte móvel da máquina CNC. Foram usados dois sensores de pressão do tipo FSR400 e um sensor acústico, do tipo microfone de eletreto (vide seção 2.3.2).

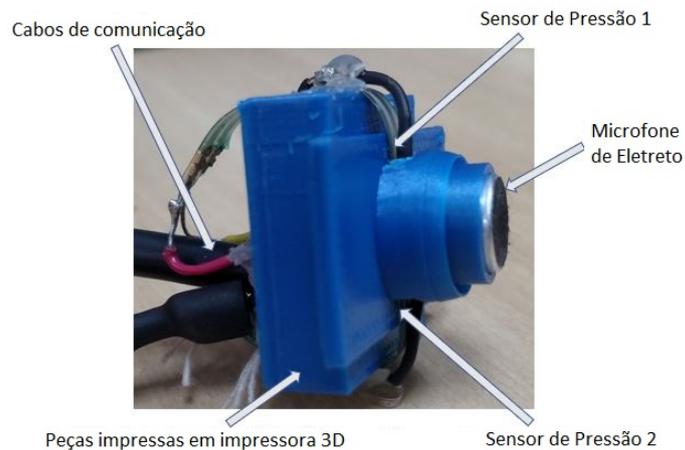
No sensor tátil desenvolvido, os sensores de pressão foram usados para a captação de resposta estática, enquanto o sensor acústico foi responsável por detectar resposta dinâmica. Assim, os sensores de pressão desempenham o papel de medir a força exercida entre o sensor tátil e o objeto a ser prensado. Complementarmente, o sensor acústico tem o papel de detectar, exclusivamente, se está ocorrendo ou não o evento de escorregamento. Pode-se fazer a analogia de que os sensores de pressão são equivalentes aos mecanorreceptores do tipo SA (vide seção 2.2) e o sensor acústico equivale aos mecanorreceptores do tipo RA2.

Como indicado na Figura 3.4, os dois sensores de pressão foram montados logo abaixo do microfone, estando próximos um ao outro, de modo que, se uma mínima rotação do microfone ocorresse no eixo horizontal, os sensores seriam capazes de capturar essa rotação pela diferença no valor da pressão entre eles. Foi inserida a captação desta informação adicional, pois a rotação do microfone de eletreto pode indicar que o objeto está começando a escorregar.

### 3.1.2 Aquisição dos Dados

A aquisição de dados vindos dos sensores foi feita por uma placa processadora, que possui o microcontrolador embarcado de 32 bits *Atmel SAM3X8E ARM Cortex-M3*, cujo *clock* é de 84 MHz. Esta placa possui um conversor analógico digital (ADC) interno que opera em até 12 bits, o que confere uma resolução de até 4096 valores diferentes dentro da faixa de operação do sensor. Sua taxa de envio de bits por segundo (bps ou baud rate) pela porta serial atinge o

Figura 3.4: Protótipo desenvolvido de sensor tátil.



Fonte: O autor (2020).

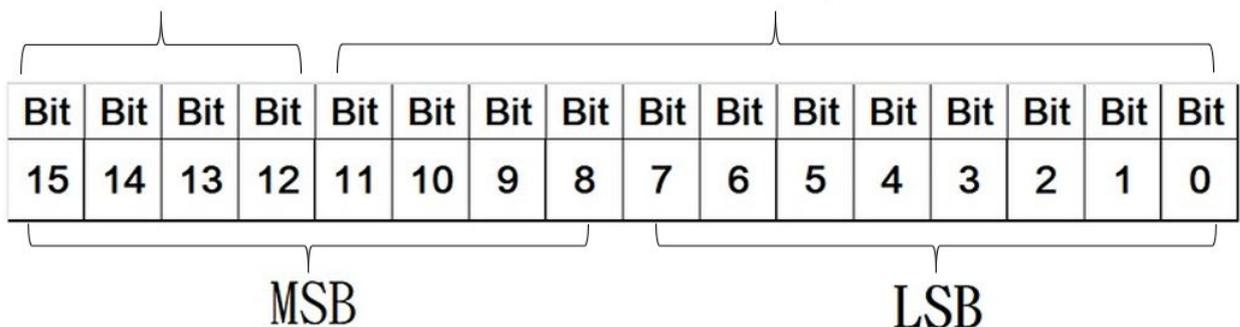
valor máximo de 20 Mbps (utilizando a porta USB nativa).

Visto que o dado medido de cada sensor pelo conversor ADC tem o valor de 12 bits e que as informações são enviadas pela comunicação serial por meio de Bytes (que são conjuntos de oito bits), o valor de tensão de cada sensor em uma aquisição precisou ser dividido em dois Bytes, o primeiro Byte contendo os oito primeiros bits (chamados de menos significativos ou no inglês LSB - *Least Significant Bit*) e o segundo contendo os outros quatro bits (bits mais significativos ou no inglês MSB - *Most Significant Bit*), sendo que os valores restantes para completar o Byte foram preenchidos com zeros. A Figura 3.5 mostra esta organização dos dados dos sensores em Bytes.

Figura 3.5: Aquisição dos dados em 12 bits e convertidos para dois Bytes.

Preenchimento do restante dos bits com zeros

Dado coletado do sensor pelo DAC de 12 bits



Fonte: O autor (2020).

Deste modo, os sinais dos sensores foram adquiridos à uma taxa de 1 KHz, o que

representa um tempo entre a aquisição de dois dados igual a 1 ms. Especificamente ao sensor acústico, foi acoplado um amplificador com ganho de 20 db e um filtro analógico passa-baixo *Butterworth* de quarta ordem com frequência de corte de 500 Hz, para limitar o sinal relacionado à alta frequência e assim reduzir o ruído, para que não ocorra um fenômeno indesejado, chamado de *Aliasing*. O *Aliasing* gera uma distorção no sinal acrescentando componentes harmônicas que antes eram inexistentes. Ele é causado quando não é respeitado o teorema de Shannon Nyquist [30] que diz que a frequência de aquisição do sinal deve ser maior que o dobro de sua maior frequência.

### 3.1.3 Transmissão de Dados

Ao final de cada aquisição, os dados de todos os sensores, representados em Bytes, eram organizados em um pacote definido, ou protocolo, e este era enviado ao computador por meio da comunicação serial, para que pudesse ser feito o processamento dos dados. Um software na linguagem C# foi desenvolvido, com uma interface gráfica, para gravação de dados e detecção em tempo real do evento de escorregamento. Além disso, o software em C# permite o controle manual da posição do sensor tátil, pela manipulação do motor de passo da máquina CNC.

A organização dos dados em um pacote antes do envio é importante para que haja a garantia de que todos os Bytes sejam enviados na ordem correta. Ao mesmo tempo, o receptor dos dados verifica o pacote e, somente se os dados estiverem organizados da maneira correta, ele irá guardá-los. Caso contrário, ele irá descartá-los, pois entende-se que os Bytes foram corrompidos ou adquiridos na ordem incorreta.

Esta organização dos Bytes em pacotes foi baseada na forma como o protocolo UART organiza o envio de cada Byte, mostrado na Figura 3.6. O protocolo UART tem o objetivo de coordenar o envio de cada Byte individualmente, de forma correta, sem que haja perdas de dados. Neste trabalho, o protocolo usado foi focado no envio de um conjunto de Bytes, formando assim um pacote.

Figura 3.6: Protocolo UART de envio de um Byte pela comunicação serial.

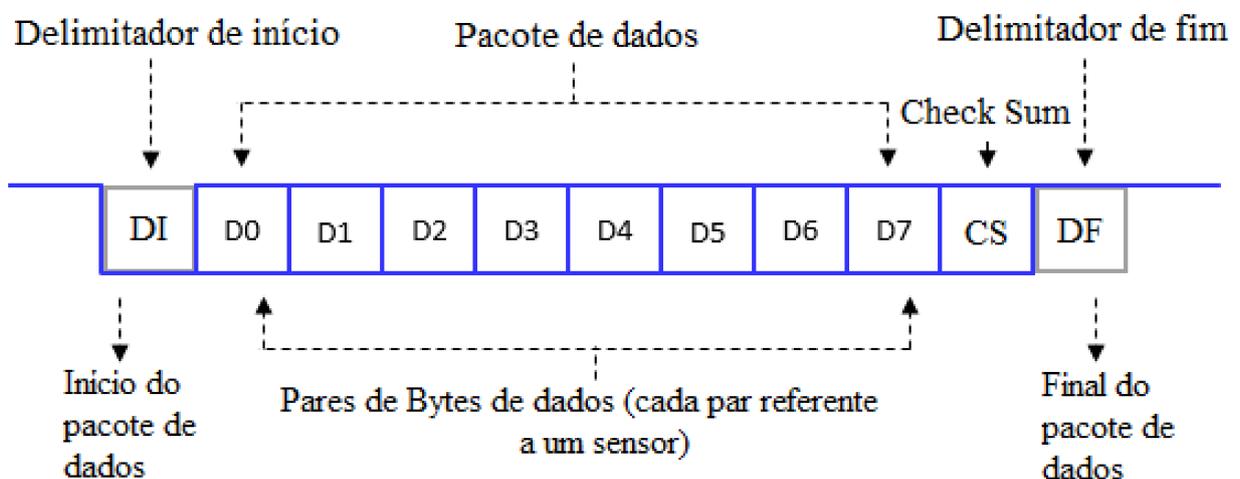


Fonte: O autor (2020).

O primeiro Byte enviado foi sempre constante e representa o início do pacote, este Byte é chamado de DI (delimitador de início) e teve seu valor fixado em 0x7E em representação hexadecimal, ou 126 em decimal. Outro Byte com valor imutável é o último do pacote, chamado de DF (delimitador de fim), e teve seu valor definido em 0x81 em representação hexadecimal, ou 129 em decimal.

Como o recebimento dos Bytes vindos pela porta serial não é feita de maneira sincronizada ao envio de dados, podem ser acumulados vários Bytes em sequência no *buffer* interno da serial entre uma aquisição e outra, o que torna difícil a identificação de qual Byte é representativo a cada sensor. Assim, os Bytes DI e DF foram inseridos para que o software de recebimento saiba o começo e o fim de cada pacote de dados em uma aquisição e assim, saiba identificar qual Byte representa cada dado específico. A Figura 3.7 mostra como foi feito o agrupamento dos Bytes em um pacote.

Figura 3.7: Protocolo utilizado para agrupamento dos Bytes em pacotes.



Fonte: O autor (2020).

Além dos Bytes especiais no início e fim de cada pacote, foi inserido outro Byte de verificação dentro do pacote, ele é chamado de *Check Sum* e se localiza logo antes do delimitador de fim. Diferentemente do DI e DF, que delimitam o início e fim do pacote de dados, o *Check Sum* desempenha o papel de confirmar a integridade dos dados dentro do pacote, checando se todos os dados estão presentes e se estão na ordem correta. Esta verificação é feita com a soma do último Byte de cada valor de tensão dos sensores, representando os bits menos significativos de cada dado dos sensores.

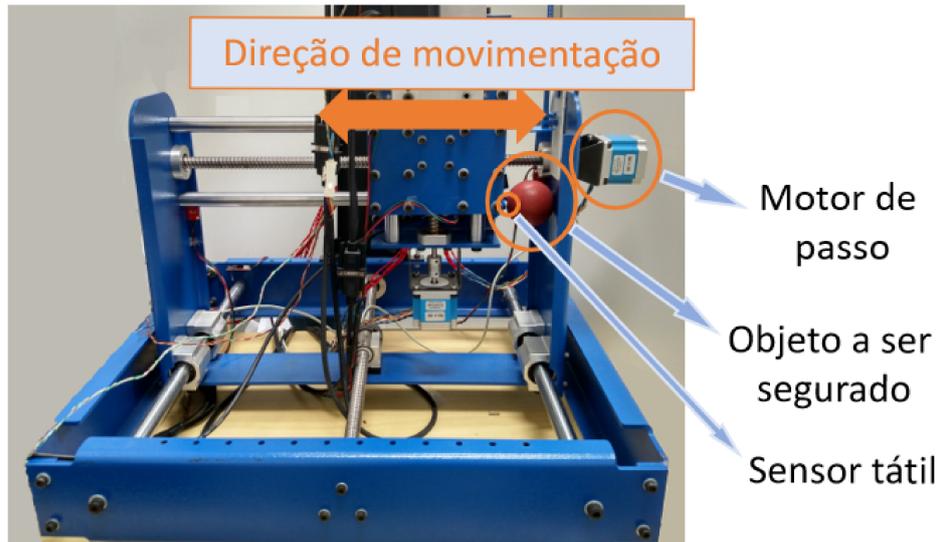
Após o pacote de dados ser enviado ao PC, ele é colocado em uma fila do tipo FIFO (*first in first out*). Então, é feita uma varredura de Byte a Byte a procura do DI. Caso o delimitador de início seja encontrado na fila, é verificado se o DF se encontra na posição correta, ao dar um passo do tamanho do pacote de dados. Se as duas primeiras fases de verificação forem concluídas com êxito, é então feita a última verificação antes de armazenar o pacote completo de dados, esta consiste em calcular a soma dos LSBs do valor de tensão de cada sensor. Somente se o valor desta soma for igual ao valor do Byte de verificação *Check Sum*, o pacote completo é salvo. Este processo de três verificações garante maior segurança no envio e recebimento dos dados, sem que nada se perca neste caminho.

Como dito anteriormente, os dados dos sensores foram adquiridos por uma placa processadora e então enviados a um computador, pela interface serial, para que fosse realizado o processamento e classificação dos sinais. A resposta do classificador era enviada de volta ao microcontrolador, para que pudesse manipular o atuador (motor de passo) e assim, controlar a força de prensão. O motivo do envio dos dados de um microcontrolador a um computador e depois novamente ao microcontrolador é a velocidade de processamento e a capacidade de processamento paralelo da CPU do computador. Por se tratar de um processador *multi-cores* e por ter frequência de operação superior à encontrada no chip da placa processadora, o computador consegue realizar muito mais cálculos por segundo, se comparado ao microcontrolador.

### 3.1.4 Controle da força de prensão

O controle da força de prensão entre o sensor tátil e o anteparo fixo foi realizado, exclusivamente, pela manipulação de um motor de passo. Pela sua montagem na máquina CNC, o motor é capaz de controlar a posição do sensor tátil, que por consequência, é capaz de controlar a força de prensão exercida bilateralmente no objeto a ser prensado. A Figura 3.8 mostra o sistema de controle da força de prensão sobre um objeto específico.

Figura 3.8: Sistema de controle da força de prensão sobre um objeto.



Fonte: O autor (2020).

O motor de passo presente na máquinas CNC foi ligado ao driver TB6600. Este driver permite o controle da velocidade de rotação do rotor (pelo ajuste da quantidade de passos por revolução), também permite o controle da direção de rotação e é capaz de desativar ou ativar o travamento do rotor (pela injeção ou não de corrente em suas bobinas). O driver TB6600 foi definido em sua configuração de 3200 passos por revolução, que junto à sua configuração de acoplamento mecânico à máquina CNC, permitiram um deslocamento horizontal do sensor tátil de  $3.126 \mu\text{m}$  por passo do motor.

Assim, o motor era controlado por meio da injeção de sinais digitais em três entradas do driver de controle do motor, TB6600. A primeira entrada digital é responsável por executar o movimento do rotor em um passo. Este movimento é executado ao fim de um pulso completo, ou seja, é preciso que o estado digital desta entrada seja alterado de *Low* para *High* e depois novamente de *High* para *Low* para, após este processo, ser executado um passo. Foram realizados testes de estabilidade no motor de passo e atingiu-se uma estabilidade satisfatória (sem que houvesse muita vibração durante o seu movimento) com a largura de pulso com valores superiores a  $50 \mu\text{s}$ .

A segunda entrada digital do driver permite o controle do sentido de rotação. Quando injetado um sinal com tensão definida (*High*), o motor é configurado para rotações no sentido de aumentar a força de prensão do objeto, e quando não havia sinal injetado na entrada digital (caracterizando um sinal digital do tipo *Low*), o motor é configurado para realizar rotações no sentido de diminuir a força de prensão.

Por fim, a terceira entrada digital é responsável por ativar e desativar o motor, ou seja,

deixar as suas bobinas carregadas e manter o rotor com certa carga à rotação externa, ou cortar a corrente nas bobinas e deixar o rotor livre para a rotação por forças externas. Esta última situação é importante para o caso de emergência, em que se deseja desativar o motor e permitir a sua rotação livre. Quando é injetado um sinal digital *High* na entrada do driver, o motor é desativado, ao passo que um sinal *Low* em sua entrada reativa o motor.

Assim, todos os comandos de movimento, ativação e direção de rotação do motor foram comandados pela placa processadora, que é capaz de enviar sinais digitais para as entradas do driver. A velocidade de rotação do rotor foi ajustada pelo tempo entre as interrupções de um *Timer*, implementadas na placa. O *Timer* responsável pela mudança do sinal digital injetado na entrada do Driver TB6600 foi implementado com tempo de  $500 \mu\text{s}$ , ou seja, o tempo total para a ocorrência de um pulso completo foi de 1 ms. Assim, esta velocidade permite que um passo do motor seja executado em 1 ms, o que representa um velocidade de rotação de 3.2 segundos por rotação, ou 18.75 rotações por minuto (rpm).

## 3.2 Software Desenvolvido

Para o funcionamento global do sistema, diversos softwares foram desenvolvidos e todos se comunicam de alguma forma. Na primeira etapa de construção do sistema, foram desenvolvidos os *softwares* que possibilitaram a aquisição e salvamento dos dados dos sensores com seus *targets*, segundo o experimento descrito na seção 3.3.

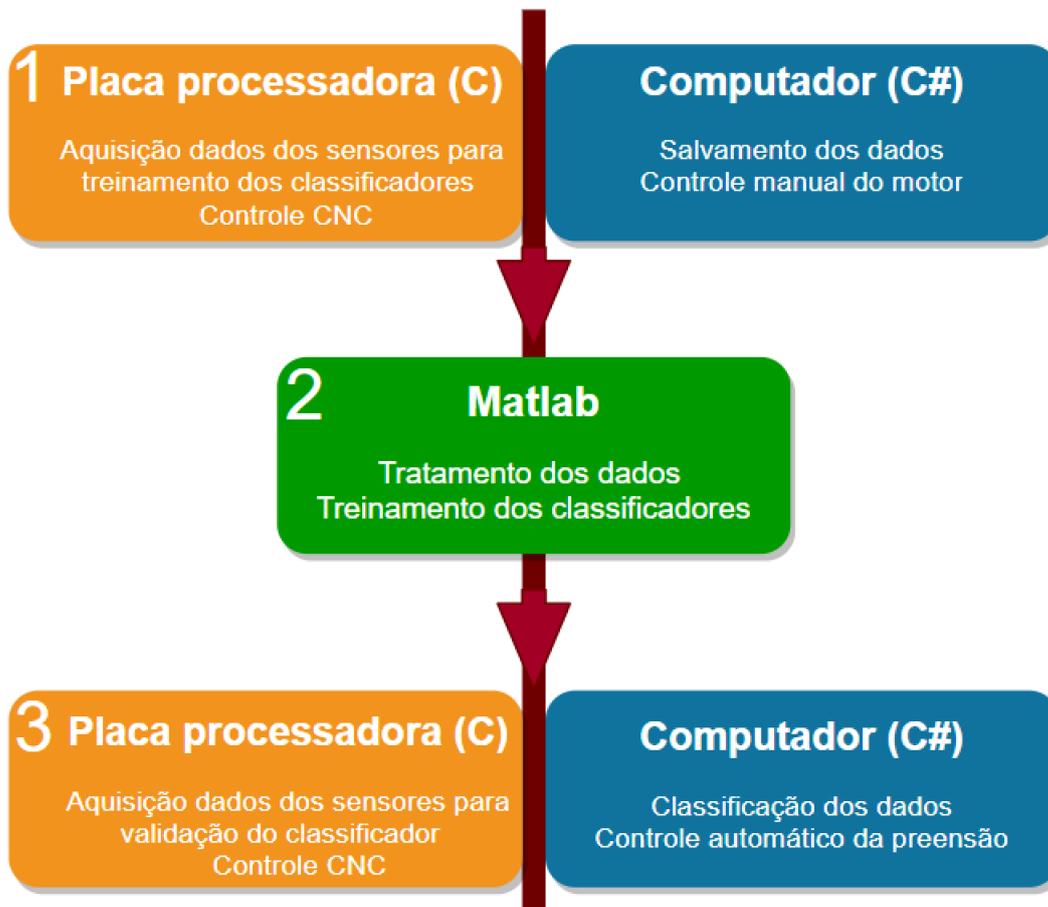
Na segunda etapa do sistema, os dados dos sinais dos sensores foram apresentados ao algoritmo classificador, para que ele pudesse aprender os padrões sobre os sinais e ser capaz de diferenciar os sinais relacionados à presença e ausência de escorregamento. Por fim, na terceira etapa o algoritmo classificador já treinado foi inserido no sistema para que ele pudesse identificar, em tempo real, se estava ocorrendo escorregamento entre o sensor e o objeto prensado e assim, ser capaz de controlar a força normal e manter a estabilização da preensão.

Assim, nas etapas 1 e 3, o *software* da placa processadora (linguagem C) e do computador (linguagem C#) foram os responsáveis por executar as tarefas. Um *software* desenvolvido em Matlab<sup>®</sup> (versão 2016b) foi o responsável por executar a etapa 2.

A Figura 3.9 mostra um diagrama que ilustra o papel de cada *software* no funcionamento global do sistema desenvolvido. As setas indicam o caminho das três etapas, de cima para baixo.

A seguir serão detalhados os softwares desenvolvidos em cada uma das etapas.

Figura 3.9: Diagrama dos softwares desenvolvidos, entre parênteses está a linguagem de programação de cada software.



Fonte: O autor (2020).

### 3.2.1 Placa processadora

Primeiramente, a placa processadora precisou ser programada, para que ela pudesse coletar os dados dos sensores de forma correta e enviá-los ao computador, pela porta serial. Além disso, a placa foi programada para enviar comandos específicos à máquina CNC, que permitem o controle preciso da posição do motor de passo, possibilitando assim controlar a força de prensão. O microcontrolador da placa foi programado em linguagem C.

Cada função desempenhada pelo microcontrolador foi implementada em uma interrupção, sendo acionada a cada intervalo de tempo fixo (caracterizando um *Timer*) ou por meio de um comando externo (caracterizando uma interrupção externa). A função de aquisição era disparada a cada 1 ms e esta foi configurada para manter ativada enquanto a placa estivesse energizada.

As interrupções externas foram responsáveis pelo controle do motor de passo da má-

quina CNC. Assim, quando um Byte era recebido em sua porta serial, era disparada a interrupção para verificação de qual comando foi enviado e logo em seguida, este comando era executado.

A interrupção para controle do motor tinha prioridade sobre as interrupções do timer de envio de dados. Este cuidado foi tomado, pois o controle do motor e, conseqüentemente, da força de prensão do objeto, é mais importante do que o envio dos dados dos sensores.

Todas as tarefas de escrita ou leitura digital das portas I/O da placa processadora foram implementadas com a manipulação dos registradores, com o intuito de gastar menos instruções de máquina e reduzir o tempo de processamento.

### 3.2.2 PC: Interface gráfica e controle do sistema

O algoritmo capaz de informar ao usuário todas as informações referentes aos sensores foi desenvolvido em linguagem C#. Neste software, além de possuir a interface gráfica que informa alguns dados ao usuário, ele permite a detecção em tempo real do evento de escorregamento e também permite o controle manual da posição do manipular, que exerce pressão ao objeto a ser prensado. Foi utilizada a abordagem de programação paralela, com o uso de *threads*. As principais *threads* do algoritmo são responsáveis: i) pela aquisição de dados dos sensores, que estavam armazenados no *buffer* da porta serial do computador; ii) pelo salvamento dos dados na memória interna do computador (para serem analisados posteriormente); iii) pela classificação dos dados quanto à presença ou ausência de escorregamento; iv) pelo envio de comandos ao microcontrolador, para que ele possa manipular o motor de passo da máquina CNC e controlar a força de prensão.

Além do *buffer* existente para armazenamento dos dados vindos para a porta serial do computador, foi criado outro *buffer* de armazenamento dos dados, para que fosse possível a leitura, em tempo real, dos dados gravados na porta serial e a inserção deles no algoritmo classificador, para análise do seu comportamento. Esta estratégia de criar um segundo *buffer* foi necessária, pois não é possível garantir que a *thread* de leitura dos dados seja sincronizada à *thread* de classificação. Isto, pois cada *thread* possui um número de comandos diferentes e ainda por cima, outros aplicativos rodam em segundo plano no computador, ao mesmo tempo em que este software é executado. Assim, com a criação deste *buffer* secundário, é possível que a velocidade de aquisição dos dados seja mais rápida que a sua análise pelo classificador, e mesmo assim, os dados não serão perdidos. Foi analisado o tamanho ideal deste *buffer* para que não ocorresse *overflow* (estouro do *buffer* e perda dos dados) e ao mesmo tempo não ocupasse

muita memória, e o resultado obtido foi um tamanho de 100 posições para o armazenamento temporário dos dados.

Na interface gráfica presente no *software* é possível: i) controlar o início e fim da execução do sistema; ii) acionar um parada emergencial do motor da máquina CNC; iii) controlar manualmente a posição do sensor tátil, liberando ou exercendo mais pressão sobre o objeto a ser segurado pelo sistema. Todos estes comandos de controle do atuador do sistema (que é o motor de passo) são feitos através do envio de um Byte à placa processadora. Cada Byte enviado representa um comando específico. Assim, caso a placa processadora receba qualquer um dos Bytes específicos pela comunicação serial, uma interrupção será gerada e o comando será executado imediatamente. Isto garante que o tempo de resposta entre o acionamento de um botão na interface gráfica (referente a algum comando específico do motor) e a resposta do atuador seja a mínima possível.

Além disso, a interface permite ter *feedback* visual: i) do tempo de discorrimento da execução do sistema; ii) da resposta em tempo real do classificador; iii) do gerenciamento de memória do *buffer* de armazenamento de dados (para informar se nenhum dado é perdido ao longo do caminho entre a transmissão, aquisição e análise dos dados). Somados à estas informações, a interface gráfica mostra dois gráficos, referentes aos sinais dos sensores de pressão e do microfone de eletreto, em tempo real.

Na *thread* de classificação do sinal em tempo real (quanto à presença ou ausência de escorregamento), foi implementado um algoritmo classificador (que será descrito posteriormente). Somente após o treinamento deste algoritmo, realizado em outro *software* desenvolvido em Matlab<sup>®</sup>, seu modelo ajustado foi inserido.

### 3.2.3 Detecção de Escorregamento

O algoritmo classificador, presente no software desenvolvido em C#, foi importado com os pesos já treinados previamente. Assim, os dados dos sensores são inseridos diretamente no classificador e sua saída representa a resposta do sistema, ou seja, se foi detectado ou não um evento de escorregamento no instante atual.

#### Separação dos dados em amostras

Antes do classificador ser capaz de analisar os dados vindos dos sensores e dar um veredito se estes dados representam um evento ou o outro, ele teve que ser treinado com a apresentação de vários sinais diferentes, vindos de um experimento detalhado na seção 3.3.

Para o processamento dos dados e treinamento do classificador, foi desenvolvido um software em Matlab<sup>®</sup>. Após a aquisição de todos os dados vindos da coleta experimental, estes foram separados em dois grupos, o primeiro com dados referentes ao momento do escorregamento dos objetos e o segundo, com dados referentes ao estado estático, ou seja, em que o objeto estava submetido à uma preensão estabilizada (sem que o objeto caia ou haja escorregamento).

Tendo os dados sido separados em dois grupos, foi realizado um janelamento temporal do sinal. Cada sinal foi reagrupado em diversas amostras de 40 dados, ou seja, representando uma janela temporal de 40 ms. Neste janelamento temporal, foi inserido um *overlap* de 30 pontos, ou seja, o número de dados coincidentes entre um janela e a sua consecutiva é de 30 pontos, então o passo temporal entre um janela e outra é de 10 ms. Assim, a cada passo da janela, eram descartados os primeiros 10 ms de sinal e os 10 ms mais recentes eram acionados na fila. Para cada adição de dados, o sinal era inserido com os dados brutos dos sensores, ou seja, cada passo insere 30 novos dados (referentes a 10 ms de dados de cada um dos três sensores presentes no sensor tátil).

Feita esta divisão, muitos dados referentes à ausência de deslizamento foram excluídos, pois a quantidade de dados relativas ao escorregamentos é muito menor que os outros dados, devido à confecção do protocolo de aquisição dos sinais rotulados. O intervalo de tempo referente às amostras com ausência de escorregamento foi escolhido aleatoriamente, com a condição de que este fosse anterior ao instante de tempo que se iniciou o escorregamento do objeto.

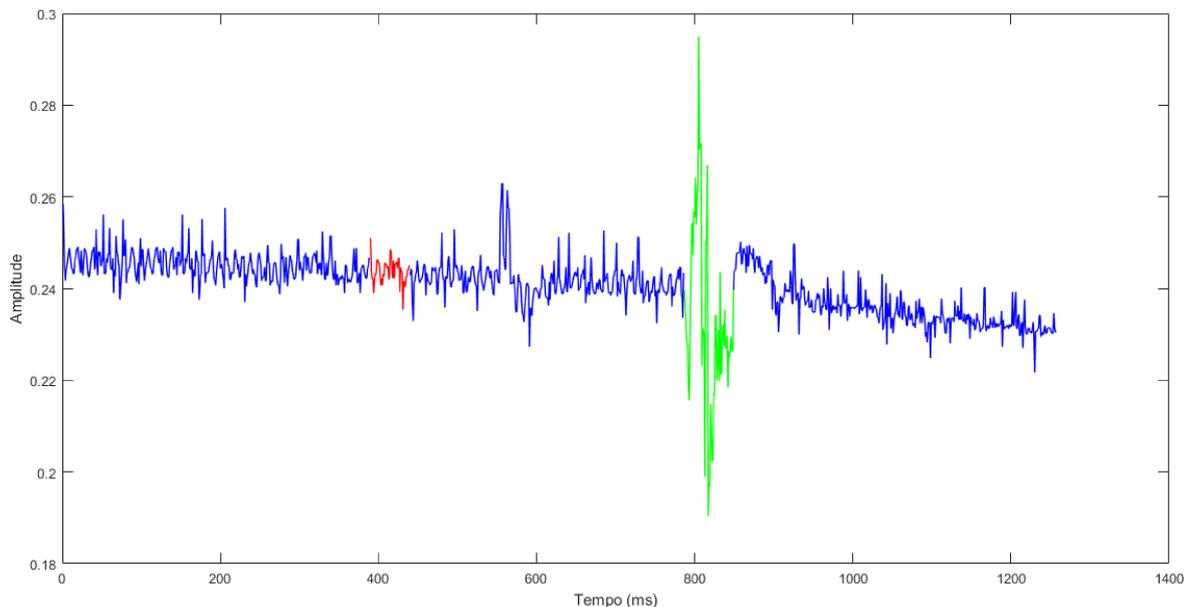
A exclusão destes dados é feita para que haja um balanceamento das amostras. O número de amostras com rótulo, ou *target*, indicando a ocorrência de escorregamento deve ser próximo ao número de amostras rotuladas com ausência de deslizamento.

A Figura 3.10 mostra o sinal de uma coleta experimental, as amostras rotuladas com presença de escorregamento foram extraídas do sinal no intervalo de tempo identificado pela cor verde, enquanto as amostras rotuladas com ausência de escorregamento foram extraídas do sinal no intervalo identificado pela cor vermelha, todos os demais dados foram descartados, para que o tamanho das duas amostras fossem balanceados.

O cuidado de balancear o número de amostras referente a cada classe é importante, pois caso contrário, o algoritmo de aprendizagem fica mais especializado no reconhecimento de certa classe (visto que ele aprendeu mais sobre tal informação) e ao mesmo tempo a outra classe fica com aprendizagem comprometida. Este fenômeno é chamado de *overfitting* e pode comprometer a performance de classificação do algoritmo, pois sua capacidade de generalização depende da diversidade de amostras apresentadas durante a fase de treinamento.

Caso a diversidade das amostras seja pequena, o algoritmo classificador ficará especia-

Figura 3.10: Sinal de uma coleta experimental. As amostras rotuladas com presença de escorregamento são identificadas pela cor verde, enquanto as amostras rotuladas com ausência de escorregamento são identificadas pela cor vermelha.



Fonte: O autor (2020).

lizado em identificar amostras com comportamento próximo àqueles apresentados previamente, porém ao ser apresentada uma nova amostra com características ligeiramente diferentes, seu resultado pode não ser satisfatório, visto que o algoritmo não foi treinado a reconhecer amostras com tais características.

### 3.2.4 Pré-processamento, Extração e Seleção de Características

Após a divisão dos dados em dois grupos (com presença e ausência de escorregamento) e o janelamento dos dados de cada grupo em amostras de 40 ms, os dados estavam prontos para serem inseridos no algoritmo de classificação.

Optou-se por não realizar nenhuma técnica de extração de características no sinal coletado para treinamento. Esta decisão foi tomada visando a aplicação em tempo real, para se obter o menor tempo de resposta possível. No sistema proposto, o tempo de resposta do sistema entre a aquisição do sinal dos sensores e a atuação na força de prensão é um dos fatores mais importantes para o bom funcionamento do projeto. Caso este tempo seja muito longo, o sistema de controle de prensão começará a atuar depois que o objeto cair, o que torna o sistema inútil.

Assim, a escolha de se inserir o sinal bruto diretamente no classificador permite reduzir

o tempo, que seria gasto para o pré-processamento. O padrão de entrada das amostras no algoritmo classificador foi implementado de forma que o número de entradas do classificador fosse o mesmo da dimensão da amostra, ou seja, se cada amostra é um sinal no tempo de 40 ms de cada um dos três sensores (totalizando 120 dados), o algoritmo será configurado para receber 120 entradas e sempre 1 saída binária, referente à presença ou ausência de escorregamento.

### 3.2.5 Treinamento do Classificador

Tendo realizado o escalonamento e separação dos dados em amostras (correspondentes a janelas de 40 ms dos dados dos sensores) já rotuladas, o próximo passo consistiu em apresentar todas estas amostras para um classificador, para que ele pudesse aprender um padrão entre as amostras referentes ao evento de escorregamento e outro padrão referente às amostras de sinal estático (sem presença de deslizamento). Assim, após a fase de treinamento, o algoritmo deveria ser capaz de distinguir a classe de uma nova amostra apresentada, se ela representa um sinal com presença de escorregamento ou se representa um sinal estático.

O método de treinamento utilizado no trabalho foi um treinamento supervisionado, ou seja, durante o processo de aprendizagem, cada amostra é apresentada com sua respectiva resposta. A cada vez que uma nova amostra é apresentada, ocorre um ajuste do modelo matemático do classificador, para que ele aprenda que amostras semelhantes às aquelas apresentadas da classe A (com deslizamento) devem resultar como saída a classe A; e amostras semelhantes às aquelas apresentadas da classe B (sem deslizamento) devem apresentar como saída a classe B.

O treinamento supervisionado só foi possível, pois todas as amostras possuíam seus respectivos *targets*, adquiridos pelo experimento descrito na seção 3.3. O experimento de coleta dos sinais foi realizado com a inserção dos rótulos nos dados, pois o método de treinamento supervisionado apresenta melhores resultados, se comparado ao treinamento não supervisionado [25].

Os dois algoritmos de treinamento supervisionado utilizados foram a Rede Neural Artificial do tipo *MultiLayer Perceptron* (ou Rede Neural *Feedforward*) e a Máquina de Vetores de Suporte (SVM, ou *Support Vector Machines*, do inglês), os testes de análise do desempenho dos algoritmos classificadores são descritos com detalhes na seção 3.4 e seus resultados foram comparados e são mostrados na seção 4.2. Ao final dos testes de comparação do desempenho dos dois algoritmos descritos, foi escolhido aquele que apresentou o melhor resultado.

### 3.2.6 Sistema de Controle da força de prensão

O sistema de controle da força de prensão de objetos, desenvolvido neste trabalho, envolve um conjunto de *softwares* e *hardwares* que são interligados e se comunicam a todo instante. A Figura 3.2 mostra a organização do sistema e como é feita a comunicação dos componentes.

A placa processadora representa o cérebro do sistema, pois ela capta as informações de todos os sensores e as envia ao computador. Além disso, ela controla o atuador do sistema, que é o motor de passo, que por sua vez controla a posição do manipulador com o sensor tátil, alterando a força de prensão do objeto.

Foi implementado um controle incremental em que a resposta do atuador depende da saída do algoritmo classificador, que foi responsável por detectar se havia presença de escorregamento, baseado na análise da forma de onda dos sinais dos sensores.

Este controle incremental tem apenas uma entrada, que é a resposta do classificador. Caso a saída do classificador aponte a ausência de escorregamento, o controlador não executará nenhuma ação e manterá o atuador imóvel, ou seja, não rotacionando o motor de passo. Porém, na situação em que o classificador indicar a presença de escorregamento, o sistema de controle enviará uma informação à placa processadora informando que o atuador deve ser movido, assim o motor de passo será acionado. A equação 3.1 mostra a fórmula utilizada no controle incremental.

$$F_N[t + 1] = \begin{cases} F_N[t] + \delta, & \text{se } c_t = c_{slip} \\ F_N[t] & , \text{ se } c_t = c_{static} \end{cases} \quad (3.1)$$

Após alguns testes, o valor de  $\delta$  foi fixado em 10, ou seja, a cada resposta positiva frente à presença de escorregamento vinda do classificador, o motor de passo sofre uma rotação de 10 passos, o que gera um deslocamento horizontal de  $31.26 \mu\text{m}$ .

## 3.3 Experimento para aquisição dos sinais com seus targets

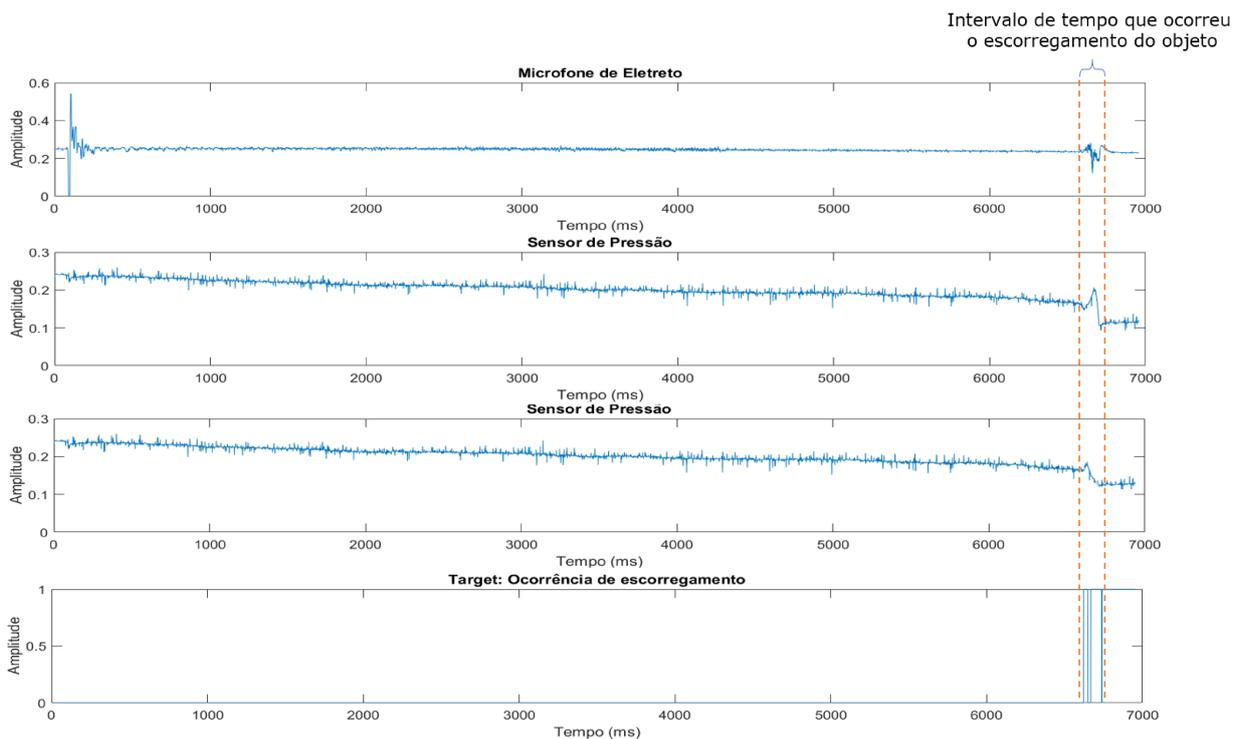
Antes que os dados possam ser classificados quanto à presença ou ausência de escorregamento, o algoritmo classificador deve ser treinado para saber quais sinais representam cada estado. Por esse motivo, foi estabelecido um protocolo de coleta de dados dos sensores para a aquisição dos *targets* do algoritmo de classificação. Esses *targets* são as respostas do algoritmo classificador frente a cada dado de entrada. O protocolo de aquisição dos sinais dos sensores,

com seus respectivos *targets*, inclui a presença de um quarto sensor (que é um foto interruptor acoplado a uma haste perfurada periodicamente espaçada), além do sensor tátil desenvolvido, como pode ser visto na Figura 3.1.

Inicialmente, o objeto é preso entre o sensor tátil e o anteparo vertical fixo. Em seguida, o experimento começa com o motor de passo movendo os sensores lentamente a uma velocidade constante de aproximadamente 0.3 mm/s, para que se afastem do objeto (causando a diminuição da pressão entre o sensor tátil e o objeto prensado) até que o objeto caia. Assim, no momento inicial da queda do objeto, o sinal digital do sensor óptico (foto interruptor) é alterado e este momento é identificado como o início do deslizamento.

A Figura 3.11 mostra os sinais dos sensores de uma amostra após o processo de rotulagem, o intervalo de tempo referente à presença de deslizamento é delimitado pela linha tracejada.

Figura 3.11: Sinais dos sensores de uma amostra após o processo de rotulagem.



Fonte: O autor (2020).

Este experimento foi realizado com 10 objetos diferentes e cada objeto foi submetido a esse protocolo 30 vezes, variando a posição inicial do contato, totalizando 300 coletas. A Figura 3.12 mostra os objetos usados no experimento, foram eles: uma caixa de papelão; um copo de plástico rígido; uma bola de golf; uma bola de bilhar; uma bola de tênis; uma bola de borracha macia; um frasco de vidro; um cilindro aveludado (canudo de formatura); uma tábua

de madeira e um pedaço de borracha espesso do tipo EVA.

A escolha dos objetos foi realizada de modo que houvesse uma variedade de massa, rigidez e rugosidade. Assim, foram formados grupos com objetos com maior massa e rigidez, outro grupo com objetos de menor massa e assim por diante.

Como o número de amostras referentes à ausência de escorregamento foi muito maior do que aqueles com presença de escorregamento, alguns dados foram excluídos, de modo que apenas um curto período de tempo referente à ausência de escorregamento permanecesse. Esta decisão foi tomada para evitar um fenômeno chamado de *overfitting*, que ocorre quando um algoritmo de treinamento supervisionado recebe muitas amostras de uma classe e poucas amostras da outra classe, causando um desbalanceamento no processo de aprendizagem. Assim, o algoritmo pode ficar especializado em um tipo de sinal, mas perde a capacidade de generalização frente a outros sinais.

Figura 3.12: Objetos utilizados durante o experimento de coleta dos sinais de escorregamento.



Fonte: O autor (2020).

## 3.4 Análise do desempenho dos algoritmos classificadores

Foram analisados os desempenhos de dois classificadores: Rede Neural Artificial *Feed-forward* (RNA) e Máquina de Vetores de Suporte (SVM). Ao final, o classificador que apresentou os melhores resultados foi escolhido para ser usado no sistema de controle de prensão online.

### Análise da melhor arquitetura da RNA

Primeiramente foi analisada qual arquitetura da RNA apresenta melhores resultados de classificação para os sinais dos sensores com presença e ausência de escorregamento, por isso foram feitos testes de validação cruzada (descrita com mais detalhes na seção 3.7) em que o número de camadas escondidas foi variado, assim como o número de neurônios em cada camada escondida foi alterado. Após encontrar a arquitetura com o maior valor de acurácia de classificação, esta foi mantida para os testes posteriores.

O primeiro teste foi realizado fixando o número de neurônios em cada camada escondida para o valor de 20 (este número foi definido segundo um teste prévio, utilizando uma RNA simples de apenas uma camada). Assim, o número de camadas escondidas foi analisado desde o valor 1 até 5. Para cada caso, foi feita a validação cruzada. Após encontrar o número de camadas escondidas em que se obteve a melhor taxa de classificação correta, o número de neurônios por camada escondida foi variado entre 5, 10, 20 e 30 neurônios. Optou-se por não utilizar um número muito grande de neurônios ou de camadas escondidas, pois o tempo de processamento de classificação no sistema em tempo real seria comprometido, caso a arquitetura da RNA fosse muito complexa.

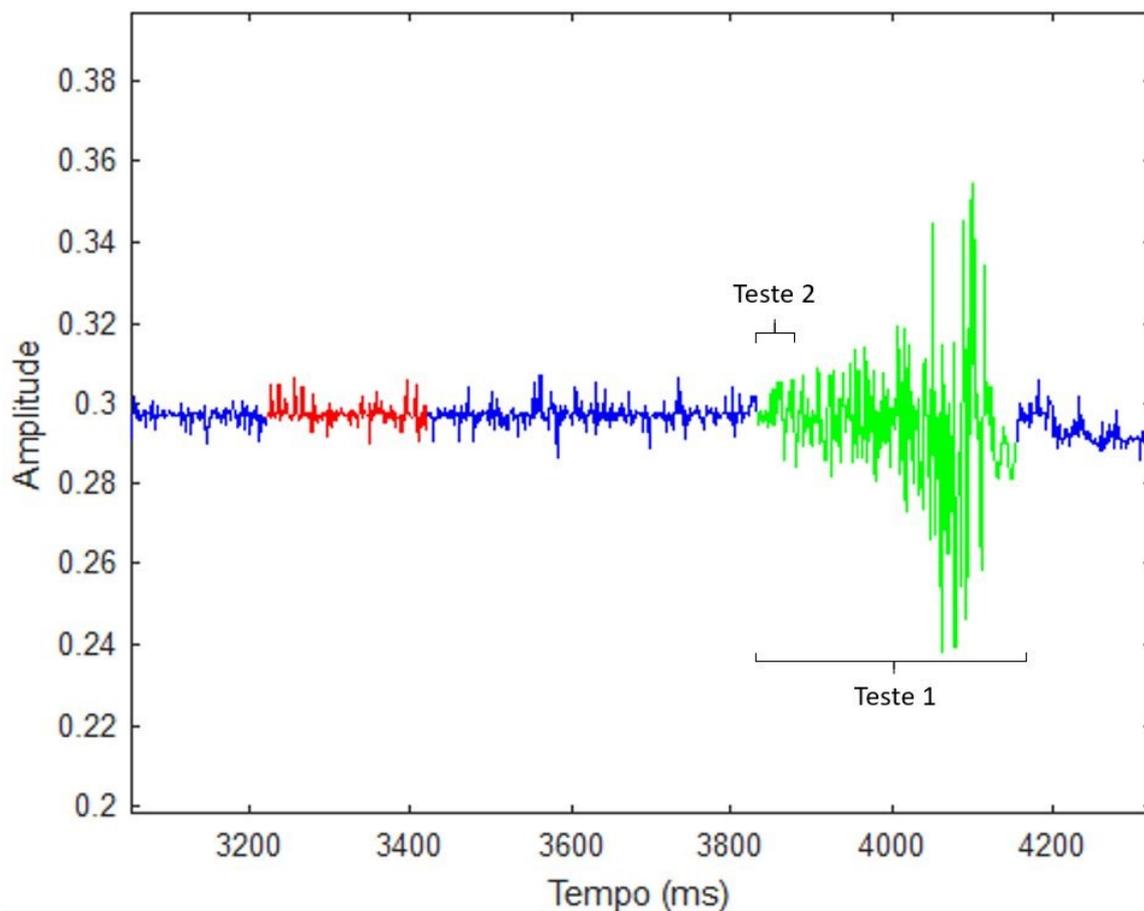
Os resultados podem ser vistos na seção 4.2.1. Após ter sido concluída a fase de análise da melhor arquitetura da RNA, o número de neurônios e camadas escondidas com o melhor resultado foi fixado para os testes seguintes.

### Análise da influência das amostras de treinamento

Visto que nos sinais coletados no experimento da seção 3.3 era possível identificar o instante de tempo de início e término de cada evento de escorregamento, foram realizados alguns testes em que o tamanho e quantidade das amostras de entrada para o algoritmo classificador eram alterados. Primeiramente, no teste 1, todas as janelas do sinal (ou amostras) referentes ao tempo total de escorregamento foram utilizadas para o treinamento do algoritmo. No teste 2, somente as amostras referentes aos primeiros 40 ms do escorregamento (indicando o deslizamento iminente) foram utilizadas no treinamento. A Figura 3.13 ilustra a localização das

amostras de treinamento para cada um dos casos, para uma certa coleta. Assim como mostrado na Figura 3.10, a Figura 3.13 apresenta o intervalo de tempo referente ao escorregamento em verde e as amostras utilizadas representando a ausência de escorregamento, em vermelho, o restante do sinal não foi utilizado com entradas para o treinamento do algoritmo classificador.

Figura 3.13: Localização das amostras utilizadas no treinamento, em uma coleta, durante os testes 1 e 2. A cor verde representa a localização das amostras com *target* de presença de escorregamento e a cor vermelha representa as amostras com *target* de ausência de escorregamento. O sinal representado em azul não foi considerado no treinamento do classificador.



Fonte: O autor (2020).

Após cada um dos treinamentos descritos acima, foi feita a validação (descrita detalhadamente na seção 3.7) e calculada a performance de classificação em cada caso, para cada classificador.

A fase de treinamento foi dividida em duas partes (como descrito acima) para se verificar a performance dos algoritmos classificadores em comparação com a quantidade e qualidade das amostras apresentadas.

No primeiro estudo, todas as amostras referentes ao escorregamento foram apresentadas no treinamento. Neste caso, foi avaliada a capacidade de generalização do classificador frente a

uma grande variedade de dados de entrada. Caso a performance para este teste for inferior aos demais, significa que é preciso refinar os dados e estreitar a quantidade de amostras para somente aquelas que identificam, com características mais marcantes, o evento de escorregamento.

No segundo estudo, apenas as amostras referentes ao deslizamento iminente foram consideradas. Assim, foi analisada a capacidade de reconhecimento de detalhes. É importante ressaltar que o sinal referente ao escorregamento iminente apresenta menor variação de amplitude, se comparado ao sinal de escorregamento total, o que pode impor um desafio maior ao classificador se apenas este sinal for considerado, visto que ele apresenta maior semelhança ao sinal estático.

Ao final deste teste, foram mantidas as amostras de treinamentos, em que o classificador obteve o melhor resultado de acurácia de classificação. Após encontrar o melhor conjunto de amostras para o treinamento, foi avaliada a performance de classificação entre tamanhos diferentes de janelas, sendo elas de 10 ms, 20 ms, 30 ms e 40 ms.

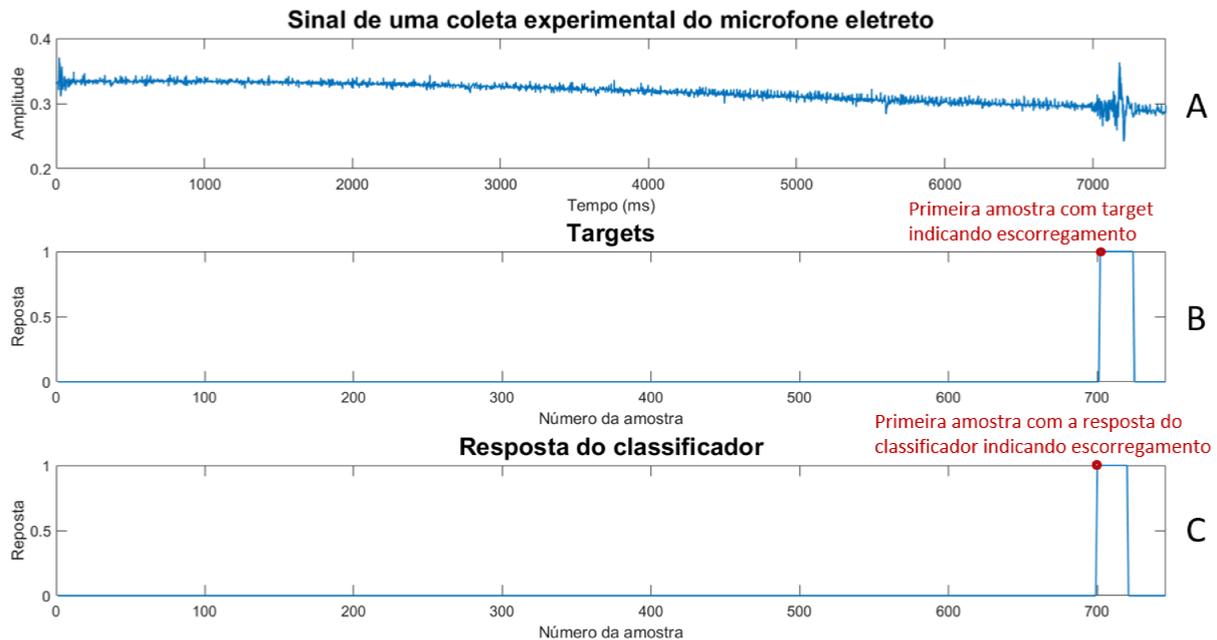
### 3.5 Análise da primeira classificação correta do evento de escorregamento em sinais offline

Após escolher o melhor classificador, sendo aquele que foi treinado com o melhor conjunto de amostras, foi realizado uma terceira análise de desempenho dos algoritmos de classificação. Esta fase de testes consistiu em analisar qual foi a primeira amostra classificada corretamente (na presença de escorregamento) e identificar o início da amostra na coordenada temporal, ou seja, se a primeira amostra que foi classificada corretamente tem início no tempo de 15.019 s e o primeiro instante em que ocorre o deslizamento iminente se inicia no tempo de 15.000 s, o tempo total para o classificador identificar a primeira amostra referente ao deslizamento é de 0.019 s, ou 19 ms. Por meio deste teste, é possível identificar o tempo de resposta do classificador, para reconhecer um evento de escorregamento, dentre um sinal offline.

A Figura 3.14 mostra a resposta do classificador frente aos *targets* definidos previamente durante o experimento de coleta dos dados dos sensores. O tempo de resposta representa o intervalo de tempo entre a primeira amostra com *target* indicando escorregamento (rotulada a partir da primeira mudança de sinal do sensor óptico, descrito com mais detalhes na seção 3.3) e a primeira amostra, cujo classificador indicou presença de escorregamento.

Para este teste, foram realizados 20 treinamentos do algoritmo classificador e em cada um deles, o sinal de uma coleta aleatória para cada objeto era retirado da fase de treinamento,

Figura 3.14: Sinal coletado pelo microfone de eletreto (A); *targets* de cada amostra de 40 ms, coletados a partir da variação do sinal digital do sensor óptico no experimento para aquisição dos sinais e *targets*(B); resposta do classificador para cada amostra (C).



Fonte: O autor (2020).

e as amostras deste sinal eram utilizadas para a análise do tempo de resposta.

### 3.6 Análise da performance do sistema de controle da força de preensão, em tempo real

Ao final do estudo sobre os melhores parâmetros de ajuste do classificador e o seu tempo médio de classificação, quando na presença do sinal offline, o último fator a ser analisado foi a performance do sistema de controle da força de preensão, em tempo real. Nesta etapa, o algoritmo classificador já treinado foi importado ao software de controle em tempo real (desenvolvido em C# e descrito anteriormente na seção 3.2.2) já com seus pesos ajustados durante o treinamento prévio. Foi escolhido o treinamento em que houve o menor erro de classificação, dentre todos os testes realizados, portanto foi escolhido o classificador do tipo Rede Neural Artificial com três camadas escondidas e 10 neurônios em cada uma das camadas.

O cálculo da performance do sistema online consistiu em realizar 10 ensaios para cada objeto. Assim, foi verificado o número de vezes em que o sistema foi capaz de manter a estabilização da preensão do objeto, ou seja, sem deixar o objeto cair ao chão.

O experimento para análise da performance foi realizado seguindo os passos do experimento descrito na seção 3.3, mas desta vez a força de prensão não foi reduzida até que o objeto caísse. Ao invés disso, os sinais eram adquiridos e logo eram inseridos no classificador para que ele pudesse analisar se estava ocorrendo um escorregamento ou não. Caso a resposta do classificador fosse positiva para a presença de escorregamento, um comando era enviado ao microcontrolador, que por sua vez controlava o motor de passo para que ele parasse de afastar o sensor tátil, mas ao contrário, para que aumentasse a força de prensão a cada vez que o escorregamento fosse detectado, seguindo a equação 3.1, objetivando evitar a queda do objeto.

Ao final, os resultados são comparados com os trabalhos de Veiga et al. [43] e Chu et al. [5]. É importante dizer que os trabalhos comparados não seguiram exatamente a mesma metodologia de análise experimental e criação do sistema de controle, por isso a comparação feita se aplica no âmbito qualitativo, visto que os resultados foram obtidos por metodologias semelhantes, porém com diferenças importante entre elas.

### 3.7 Validação do algoritmo de classificação

A validação cruzada utilizada nos testes desse trabalho foi do tipo *k-fold*, com  $k$  igual a 5, ou seja, as amostras foram divididas em 5 subconjuntos. Em cada uma das 5 iterações, um subconjunto é utilizado para a validação do modelo, enquanto as amostras dos quatro subconjuntos restantes são utilizadas para o treinamento do algoritmo classificador, assim é calculada a porcentagem de classificações corretas das amostras do grupo de validação. Este processo de validação cruzada é repetido  $k$  (5) vezes, de forma que cada um dos subconjuntos seja utilizado uma vez como teste para a validação do modelo.

Por exemplo, considerando um grupo de amostras divididas em 5 subconjuntos S1, S2... S5, na primeira iteração do algoritmo de validação *k-fold*, S1 será utilizado para teste e os outros subconjuntos (S2 a S5) serão utilizados para o treinamento. Na segunda iteração, S2 será utilizado para teste e o restante dos subgrupos é utilizado para o treinamento, incluindo o subgrupo S1 que foi utilizado para o teste na primeira iteração. Assim, esta troca de subconjuntos é repetida sucessivamente pelo número de subconjuntos formados, até que todos sejam utilizados para o teste exatamente uma vez.

Ao final, é calculada a média dos  $k$  valores de porcentagem de acerto de cada iteração. O objetivo do método *k-fold*, de repetir os testes diversas vezes é aumentar a confiabilidade da estimativa do desempenho do classificador.

# Capítulo 4

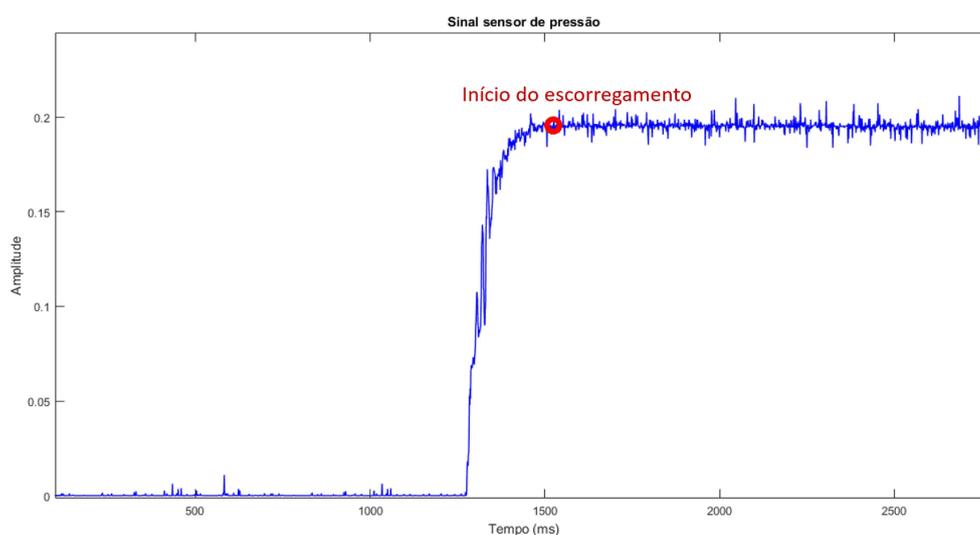
## Resultados

### 4.1 Experimento para análise da sensibilidade de sensores para detecção de escorregamento

Serão mostrados aqui os sinais dos dois sensores analisados frente a sua resposta quando na presença de deslizamento de suas superfícies contra outra superfície externa. O experimento de coleta dos sinais destes sensores é descrito com mais detalhes na seção 3.1.1.

É mostrado na Figura 4.1 o sinal do sensor de pressão FSR400 quando pressionado e deslizado sobre uma superfície emborrachada, sem desníveis ou protuberâncias, por 15 cm. O início do escorregamento é mostrado pelo círculo vermelho.

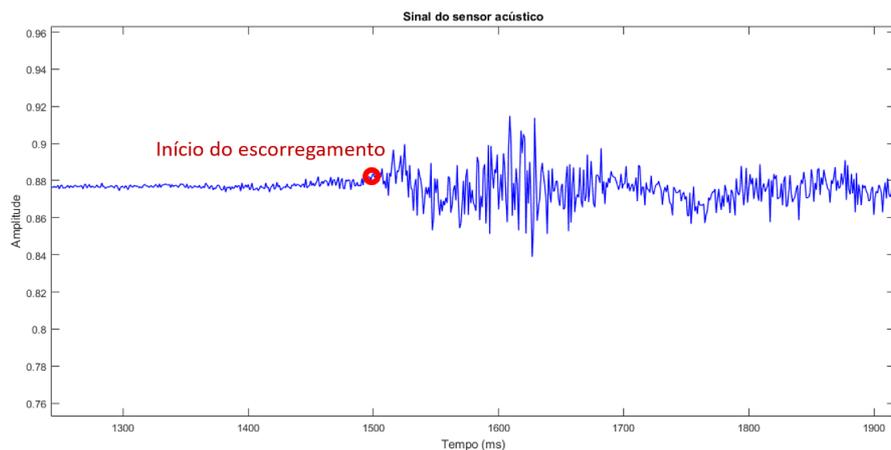
Figura 4.1: Amostra do sinal do sensor de pressão durante o experimento para análise de sua sensibilidade frente à presença de escorregamento.



Fonte: O autor (2020).

A Figura 4.2 mostra o sinal temporal coletado do sensor acústico, do tipo microfone de eletreto, seguindo o mesmo padrão de coleta experimental. O sensor acústico foi pressionado e deslizado contra a mesma superfície emborrachada durante 15 centímetros. O início do escorregamento é mostrado pelo círculo vermelho.

Figura 4.2: Amostra do sinal do sensor acústico durante o experimento para análise de sua sensibilidade frente à presença de escorregamento.



Fonte: O autor (2020).

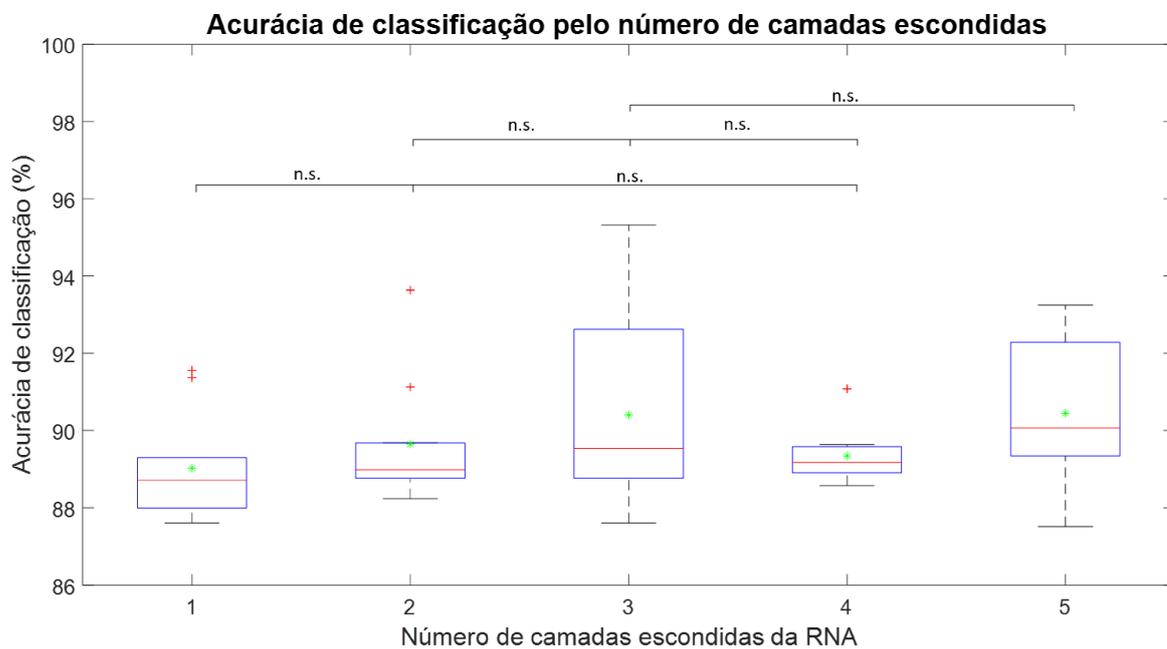
## 4.2 Comparação de performance entre RNA e SVM

### 4.2.1 Análise da melhor arquitetura da Rede Neural Artificial

A Figura 4.3 mostra a acurácia de classificação (calculada pela validação cruzada  $k$ -fold descrita na seção 3.7), quando é alterado o número de camadas escondidas da Rede Neural Artificial (RNA). O número de neurônios por camadas se manteve igual em todas as camadas intermediárias e foi fixado em 20. Para cada um dos testes, o algoritmo foi treinado e validado por 20 vezes e o resultado é mostrado na figura. Para esta e todas as análises posteriores mostradas através de *boxplots*, foi rodado um teste t-pareado entre cada par de resultados com nível de confiança em 95%. Assim, é indicado pelo símbolo n.s. caso não haja diferença estatística entre duas distribuições.

A seguir, o número de camadas escondidas, ou intermediárias, foi mantido em 3 e foi alterado o número de neurônios presentes em cada camada intermediária da Rede Neural Artificial. A quantidade de neurônios por camada se manteve constante em todas as camadas intermediárias.

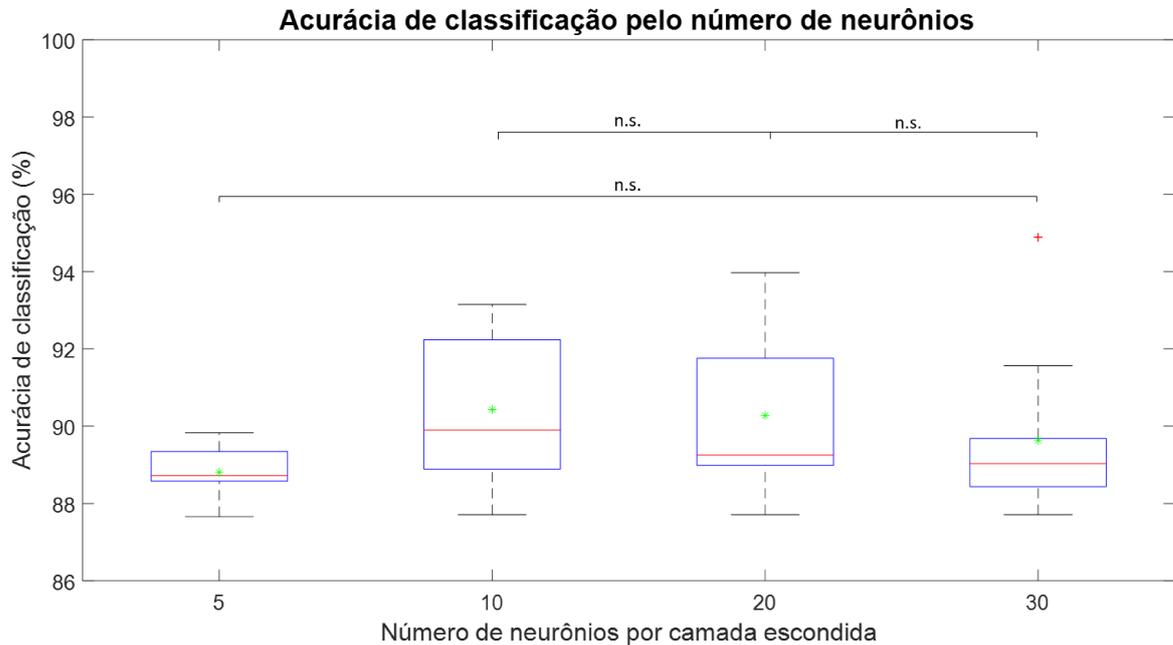
Figura 4.3: Acurácia de classificação da Rede Neural Artificial pelo número de camadas escondidas, a quantidade de neurônios por camada foi fixada em 20. O símbolo n.s. indica que não há diferença estatística entre dois resultados e o asterisco verde mostra média de cada distribuição.



Fonte: O autor (2020).

Mais uma vez, para cada uma das quatro análises, o algoritmo classificador foi treinado e validado por 20 vezes e a distribuição dos 20 ensaios para as quatro análises é mostrada na Figura 4.4.

Figura 4.4: Acurácia de classificação da Rede Neural Artificial pelo número de neurônios por camada escondida. O símbolo n.s. indica que não há diferença estatística entre dois resultados e o asterisco verde mostra média de cada distribuição.



Fonte: O autor (2020).

#### 4.2.2 Análise do tamanho das amostras utilizadas como entrada aos classificadores

Após a verificação da arquitetura da Rede Neural Artificial que obteve os melhores resultados de acurácia para a classificação entre as duas classes (presença e ausência de escorregamento), decidiu-se manter o número de camadas escondidas igual a 3 e o número de neurônios por camada escondida igual a 10. O próximo teste consistiu em analisar a acurácia de classificação frente ao tamanho das amostras que seriam inseridas como entrada para os classificadores.

No primeiro teste, foram utilizadas amostras de 10 ms de duração. Isto quer dizer que em cada iteração do treinamento do classificador, ele recebia como entrada os dados brutos dos três sensores (dois sensores de pressão e um acústico) coletados durante 10 ms, o que equivale a 10 dados por sensor, totalizando 30 dados (que foram agrupados em sequência na forma de um array). Na próxima iteração, as entradas do treinamento do classificador corresponderam à próxima amostra, deslocada em 10 ms no tempo, dos dados dos sensores.

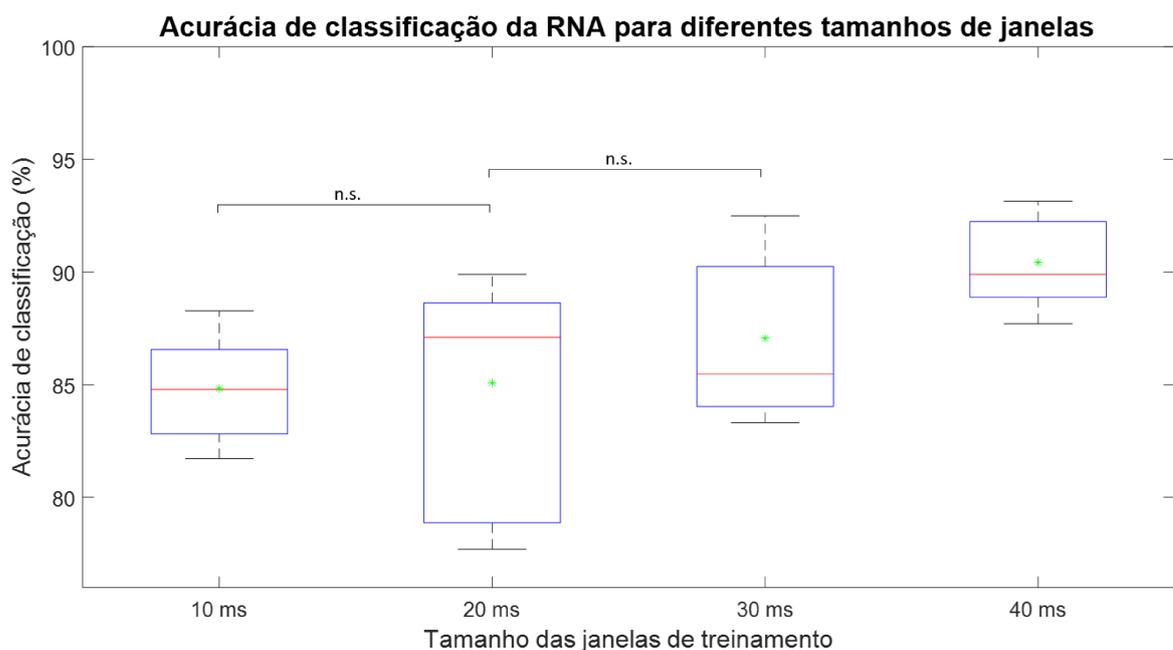
Assim, primeiramente os algoritmos classificadores foram configurados para receber 30 dados dos sensores (referentes a 10 ms de cada um dos três sensores). No segundo teste, em

que o tamanho das amostras foi fixado em 20 ms, a quantidade de dados de entrada para os classificadores foi alterada para 60 dados. No terceiro teste, foram consideradas amostras de entrada de 30 ms (90 dados) e no último, amostras de 40 ms (120 dados).

Em todos os casos analisados, o passo entre uma janela e outra foi mantido constante e igual a 10 ms, ou seja, mesmo que uma amostra do sinal fosse considerada com tamanho de 40 ms, a próxima amostra extraída do sinal original seria a anterior deslocada em 10 pontos para frente, fazendo assim com que 30 pontos sejam sempre coincidentes entre uma amostra e a sua sucessora, caracterizando um *overlap* de 30 pontos entre duas janelas.

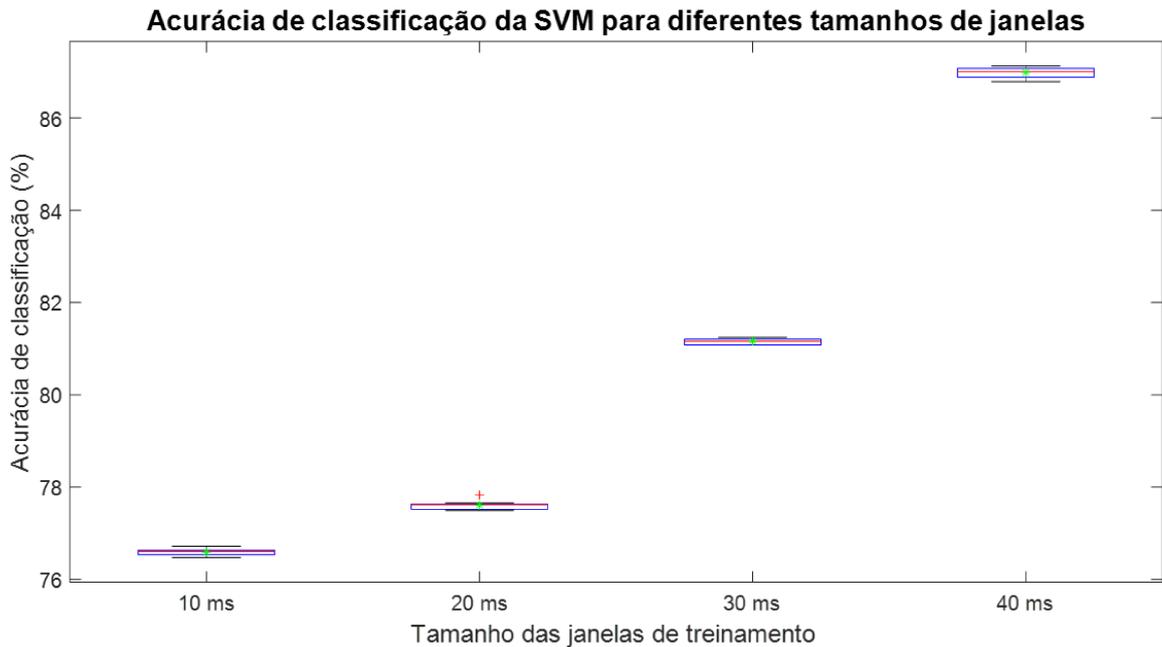
A Figura 4.5 mostra a acurácia de classificação da Rede Neural Artificial quando esta foi treinada com amostras de 10, 20, 30 e 40 ms. A Figura 4.6 mostra os resultados da acurácia de classificação da Máquina de Vetores de Suporte seguindo o mesmo teste. Para cada um dos testes em cada um dos dois classificadores, foram feitos 20 treinamentos diferentes e a distribuição dos resultados é mostrada na forma de diagramas de caixa.

Figura 4.5: Comparação da acurácia de classificação da RNA para diferentes tamanhos das janelas temporais dos dados. O símbolo n.s. indica que não há diferença estatística entre dois resultados e o asterisco verde mostra média de cada distribuição.



Fonte: O autor (2020).

Figura 4.6: Comparação da acurácia de classificação da SVM para diferentes tamanhos das janelas temporais dos dados. O asterisco verde mostra média de cada distribuição.



Fonte: O autor (2020).

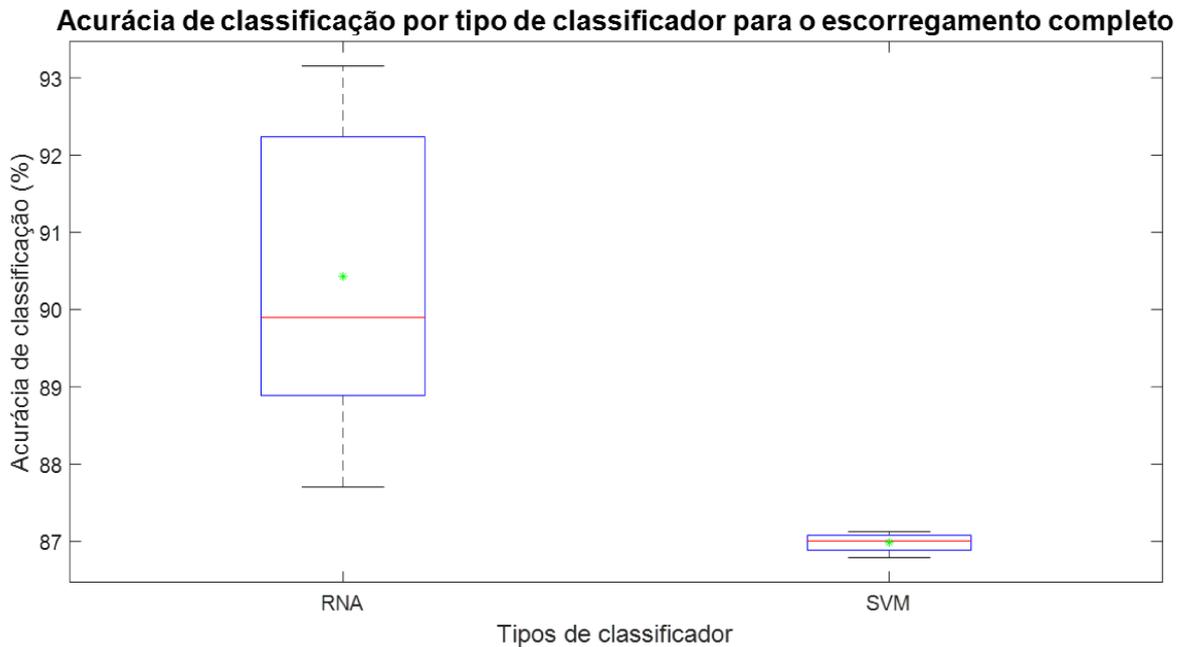
### 4.2.3 Análise da influência da qualidade das amostras durante o treinamento

Ao final dos testes para análise do tamanho das amostras dos sinais de entrada, sua duração foi mantida fixa em 40 ms para todas as seguintes análises. O próximo teste consistiu em alterar a quantidade e qualidade das amostras para o treinamento dos algoritmos. Para isto, primeiramente foram consideradas todas as amostras referentes ao período de escorregamento e no segundo teste, apenas a primeira amostra de dados da região de escorregamento foi considerada. As amostras referentes à ausência de escorregamento foram mantidas sempre constantes em todos os casos.

Na Figura 4.7, são mostrados os valores de acurácia de classificação entre a Rede Neural Artificial (mantendo 3 camadas escondidas e 10 neurônios por camada) e a Máquina de Vetores de Suporte para quando foram utilizadas as amostras durante todo o período de escorregamento.

Na Figura 4.8, apenas a primeira amostra de 40 ms foi considerada, pois esta representa o primeiro instante de escorregamento, também chamado de escorregamento iminente, ou incipiente. Para os dois testes realizados, foram feitos 20 ensaios para cada um dos classificadores.

Figura 4.7: Comparação da acurácia de classificação entre a RNA e a SVM, considerando o escorregamento total. O asterisco verde mostra média de cada distribuição.



Fonte: O autor (2020).

#### 4.2.4 Análise da primeira classificação correta do evento de escorregamento em sinais offline

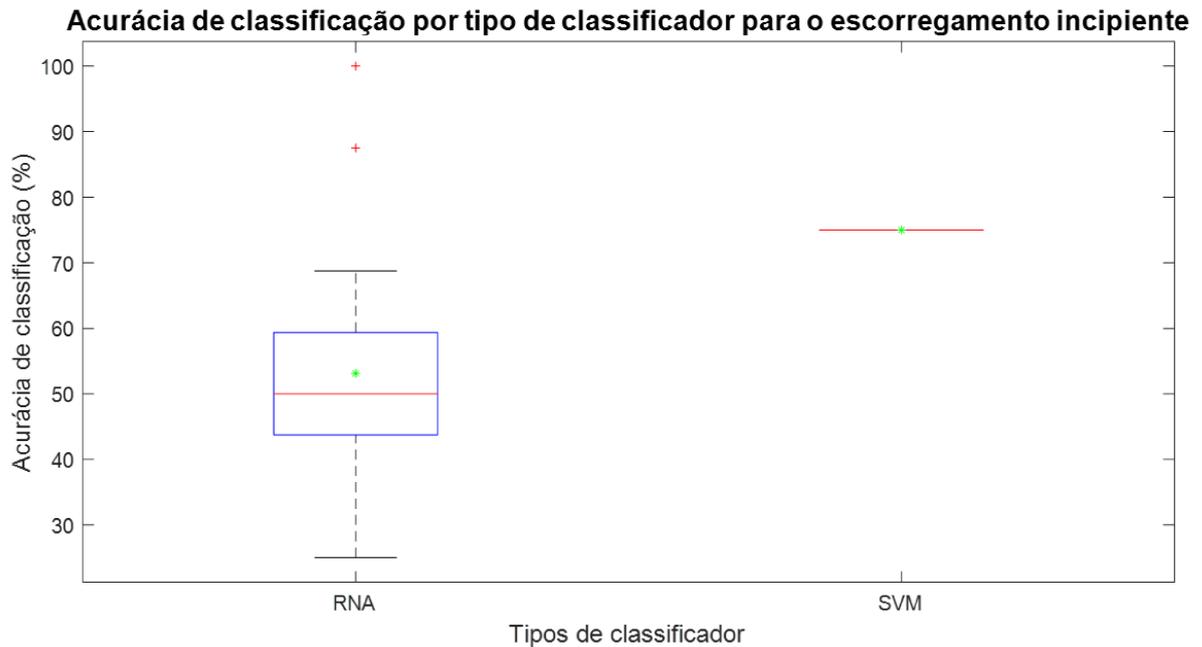
Os resultados obtidos anteriormente levaram na escolha da Rede Neural Artificial como sendo o melhor classificador para o presente trabalho, como será melhor discutido na seção 5.2. Assim, somente a RNA foi utilizada para as seguintes análises.

No próximo teste, foram analisados os sinais *offline*, coletados durante o experimento descrito na seção 3.3. Após dividir os sinais de cada coleta em diversas amostras com duração de 40 ms, foi analisada a resposta do classificador e esta foi comparada com os *targets* de cada amostra.

O cálculo do tempo de resposta do classificador foi realizado pela diferença entre o *timestamp* da primeira amostra classificada corretamente para a presença de escorregamento e o *timestamp* do primeiro *target* referente ao escorregamento (obtido pela variação do sinal do sensor óptico, pelo experimento de coleta dos sinais). Para este teste, foram realizados 20 treinamentos da Rede Neural Artificial e em cada um deles, o sinal de uma coleta, escolhida aleatoriamente, para cada objeto era retirada da fase de treinamento, e as amostras deste sinal eram utilizadas para a fase de teste.

A Figura 4.9 apresenta a distribuição dos resultados da diferença entre o índice da

Figura 4.8: Comparação da acurácia de classificação entre a RNA e a SVM, considerando apenas o escorregamento incipiente. O asterisco verde mostra média de cada distribuição.



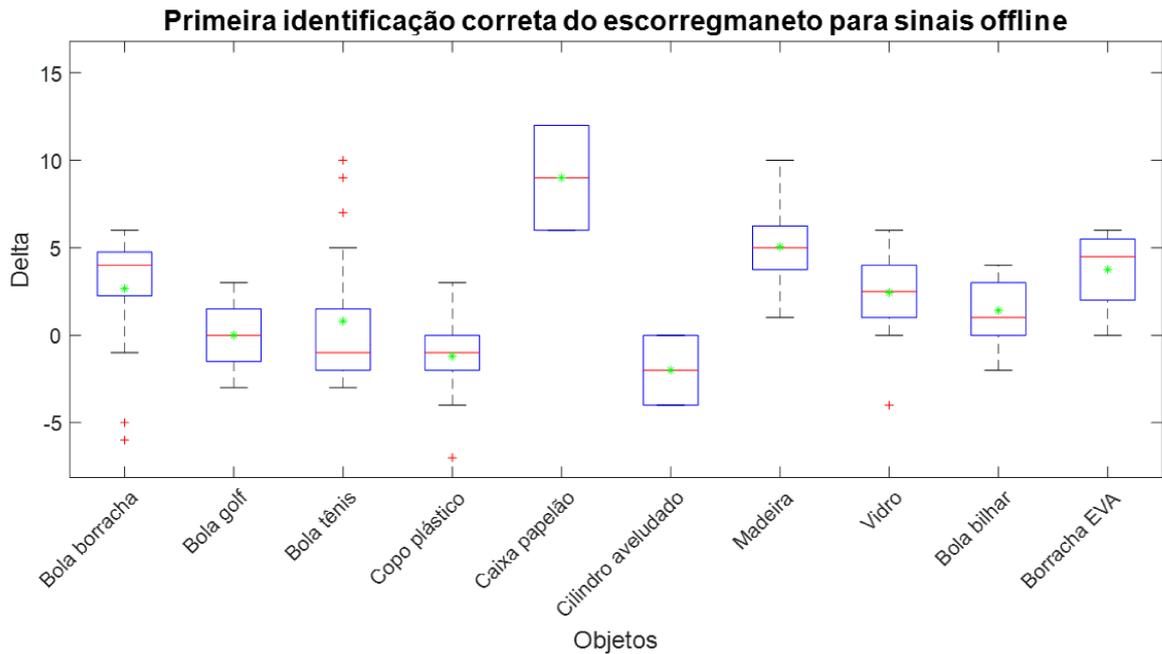
Fonte: O autor (2020).

primeira amostra classificada corretamente e a primeira amostra com *target* indicando a presença de escorregamento. A Tabela Tabela 4.1 mostra o tempo de resposta, convertendo a diferença entre cada amostra por 10 ms, o que apresenta o tempo gasto para a aquisição entre duas amostras. Tempos negativos significam que a classificação correta do evento de escorregamento ocorreu algumas amostras antes da primeira amostra rotulada com a presença de escorregamento pelo sinal do sensor óptico.

Tabela 4.1: Informação da diferença entre a primeira amostra classificada corretamente e a primeira amostra com *target* indicando escorregamento convertida para o tempo, multiplicando a diferença entre cada amostra por 10 ms.

Objetos	Primeira identificação correta do escorregamento
Caixa de papelão	90 ms
Copo de plástico rígido	-10 ms
Bola de golf	0 ms
Bola de bilhar	10 ms
Bola de tênis	-10 ms
Bola de borracha macia	40 ms
Frasco de vidro	25 ms
Cilindro aveludado	-20 ms
Tábua de madeira	50 ms
Borracha espessa	45 ms

Figura 4.9: Diferença entre o índice da primeira amostra classificada corretamente e a primeira amostra com *target* indicando a presença de escorregamento (Delta) para cada objeto.



Fonte: O autor (2020).

A Tabela 4.2 apresenta a acurácia da RNA, ou seja, a porcentagem de acerto de classificações verdadeiras positivas, para o evento de escorregamento, dentre os 20 ensaios realizados.

Tabela 4.2: Porcentagem de classificações corretas do evento de escorregamento, para os 20 ensaios.

Objetos	Classificações corretas do evento de escorregamento para os 20 ensaios
Caixa de papelão	10%
Copo de plástico rígido	100%
Bola de golf	100%
Bola de bilhar	100%
Bola de tênis	100%
Bola de borracha macia	75%
Frasco de vidro	80%
Cilindro aveludado	10%
Tábua de madeira	85%
Borracha espessa	20%

#### 4.2.5 Análise da performance do sistema de controle em tempo real

A última análise consistiu em testar a capacidade do sistema de controle da prensão para diferentes objetos. Foram realizados 10 ensaios para cada objeto e foi verificado o número de vezes em que houve a estabilização da prensão, ou seja, quando a força de prensão foi

ajustada para que o objeto ficasse preso entre o sensor tátil e o anteparo fixo, e não caísse.

A Tabela 4.3 mostra a porcentagem dos ensaios em que o sistema conseguiu estabilizar a prensão, para cada objeto.

Tabela 4.3: Porcentagem dos ensaios em que houve estabilização da prensão, por objeto.

<b>Objetos</b>	<b>Porcentagem dos ensaios com estabilização da prensão, por objeto.</b>
Caixa de papelão	20%
Copo de plástico rígido	100%
Bola de golf	100%
Bola de bilhar	90%
Bola de tênis	100%
Bola de borracha macia	80%
Frasco de vidro	80%
Cilindro aveludado	30%
Tábua de madeira	80%
Borracha espessa	40%

# Capítulo 5

## Discussões

### 5.1 Experimento para análise da sensibilidade de sensores para detecção de escorregamento

Analisando os sinais coletados de escorregamento dos sensores de pressão FSR400 e acústico, apresentados nas Figuras 4.1 e 4.2, respectivamente, é possível observar uma diferença significativa de seu comportamento durante o deslizamento, para os dois casos. Nas duas imagens, o deslizamento dos sensores contra as superfícies se inicia, aproximadamente, no instante de tempo de 1.5 s (ou 1500 ms no eixo x do gráfico). É possível perceber que o sinal do sensor acústico teve um ganho considerável em amplitude de pico a pico e também em frequência, a partir do tempo de 1.5 s, e manteve este comportamento posteriormente.

Porém, analisando o sinal do sensor de pressão, nota-se que houve um ganho de amplitude no sinal (referente ao aumento da pressão aplicada sobre ele) e ele se manteve constante por um curto período de tempo, até que no instante de tempo de 1.5 s, o escorregamento se iniciou. É possível notar que neste curto período entre o fim do pressionamento do sensor (sem deslizamento) e o início do escorregamento, não houve variação perceptível do sinal.

Diante disso, foi escolhido o sensor acústico para a aquisição de sinais a serem classificados quanto a presença ou ausência de escorregamento, pois ele sempre apresentou variação do sinal quando na presença de escorregamento, se comparado aos instantes de tempo em que não houve o deslizamento do sensor contra a superfície.

## 5.2 Comparação de performance entre RNA e SVM

### 5.2.1 Análise da melhor arquitetura da Rede Neural Artificial

Antes de se iniciar os testes de comparação de desempenho entre a Rede Neural Artificial e a Máquina de Vetores de Suporte, é importante garantir que os dois algoritmos estejam configurados da melhor forma possível, para que a comparação seja mais justa para ambos os lados. Por isso, foi feita a análise de qual arquitetura da Rede Neural Artificial traz melhores resultados de acurácia de classificação para a presença e ausência de escorregamento. Este ajuste fino do número de neurônios e camadas internas foi feito somente para a RNA, pois a SVM não possui um número variável de parâmetros internos que possam ser alterados. Visto que foram utilizadas bibliotecas prontas em Matlab<sup>®</sup> na utilização dos dois algoritmos (*feedforwardnet* para a RNA e *fitcsvm* para a SVM), um dos únicos parâmetros possíveis de serem alterados foi a quantidade de neurônios e camadas internas na RNA, por isso este foi o único ajuste interno feito nos algoritmos classificadores durante o trabalho.

Entre as cinco opções de quantidade de camadas internas na RNA testadas, foi escolhido o número de 3 camadas internas, pois os resultados entre 3 e 5 não apresentaram diferença estatística significativa. Por não haver diferença estatística significativa, optou-se por escolher o menor número de camadas, para que o modelo matemático da RNA se torne menos complexo e assim, diminua o custo computacional do sistema, quando operado em tempo real.

Em relação à análise do número de neurônios por camada escondida, optou-se por escolher o número 10, pois os resultados entre 10, 20 e 30 neurônios não apresentaram diferença estatística significativa entre eles, mas, novamente, o valor 10 é menor e isto implica a redução do custo computacional do sistema em funcionamento online, ou em tempo real. Além disso, a distribuição dos resultados de acurácia para 10 neurônios por camada apresentou o maior valor de mediana entre todos, o que se torna um outro motivo para a sua escolha.

Diante destes resultados, foi mantida a arquitetura de 3 camadas internas, ou escondidas, e 10 neurônios por camada, e esta organização foi mantida para todos os estudos seguintes.

### 5.2.2 Análise da influência do tamanho das amostras na acurácia de classificação dos algoritmos

Após ter sido escolhida a arquitetura da Rede Neural Artificial que apresentou os melhores resultados de acurácia de classificação para os testes realizados, o próximo teste consistiu em analisar a influência do tamanho das janelas, ou amostras de entrada para os algoritmos

classificadores.

É possível perceber pela Figura 4.5 que os melhores resultados de acurácia foram obtidos para os tamanhos de janela iguais a 30 ms e 40 ms, não havendo diferença estatística significativa entre eles, pois a medida da distribuições dos resultados para a janela de 40 ms teve o mesmo valor do interquartil superior da distribuição dos resultados para a janela de 30 ms. Este fato torna as duas populações (de janelas de 30 ms e 40 ms) estatisticamente semelhantes.

Quando se analisa a Figura 4.6, é possível notar que todas as populações dos resultados de acurácia (de janelas de 10 ms, 20 ms, 30 ms e 40 ms) são distintas estatisticamente uma das outras, pois os valores dentro dos intervalos interquartis não coincidem em nenhuma das quatro populações. Além disso, os resultados com o tamanho da janela em 40 ms foram os que apresentaram melhor acurácia de classificação.

Diante do fato de os resultados para o tamanho da janela serem melhores com 40 ms para a SVM e não haver diferença estatística para 30 ms e 40 ms para o caso da RNA, foi escolhida que a partir desta análise, todos os testes posteriores tiveram o tamanho das amostras de entrada iguais a 40 ms, pois esta apresentou os melhores resultados gerais.

Os resultados obtidos foram melhores quando se considerou a maior janela, pois quando se aumenta o tamanho da janela, maior é a resolução temporal das amostras que serão inseridas no classificador. Para o algoritmo classificador, uma maior resolução temporal permite analisar melhor o comportamento de um sinal ao longo do tempo. Porém, foi decidido não aumentar mais o tamanho da janela, para que o custo computacional de aquisição e processamento dos dados pelo classificador não seja um problema no funcionamento do sistema online.

Como pode ser observado na Figura 4.6, o fato dos resultados para a SVM apresentarem distribuições mais curtas do que os resultados da RNA, ou seja, com menor distância interquartil, pode ser explicado pela forma do treinamento da Máquina de Vetores de Suporte, que encontra o hiperplano de separação pela maximização dos vetores de suporte, como é descrito com mais detalhes na seção 2.5.2. Neste caso não há muita variação da posição do hiperplano de separação para diferentes treinamentos, o que torna os resultados mais próximos, mesmo para diversas vezes em que o treinamento é executado.

Quando se trata das Redes Neurais Artificiais, o ajuste de seus pesos se inicia com valores aleatórios e estes vão se modificando no sentido da minimização do gradiente do erro da resposta obtida e desejada entre duas iterações consecutivas. Esta minimização do gradiente do erro, a depender das condições iniciais das amostras e pesos, pode resultar na convergência da matriz de pesos para um mínimo local. Como um mínimo local de uma execução do

treinamento pode ser diferente do mínimo local de outra execução do treinamento, muitas vezes a matriz de pesos apresenta valores diferentes ao final de diversos treinamentos (mesmo quando apresentadas as mesmas amostras em todas as vezes), exatamente por este fator de aleatoriedade.

Dito isto, é possível perceber que a distribuição dos resultados de acurácia para a RNA foi mais aberta (com maior distância interquartil) que a distribuição dos resultados de acurácia da SVM. Assim, pode-se dizer que a precisão do método de SVM é melhor, por apresentar resultados mais próximos uns dos outros em diferentes execuções do treinamento.

### **5.2.3 Análise da primeira classificação correta do evento de escorregamento em sinais offline**

Analisando a Figura 4.9, pode-se ver a distribuição dos valores de tempo de resposta do classificador, para cada um dos objetos. Pode-se observar que os seguintes objetos: bola de golf, bola de tênis e copo de plástico rígido (copo de formatura) apresentaram resultados próximos, sem diferença estatística significativa entre eles, e apresentaram a mediana em torno de 0. Para estes casos, pode-se dizer que o classificador foi capaz de identificar o início do escorregamento no mesmo tempo que o experimento detectou o início da queda do objeto. Estes três objetos apresentam rigidez elevada, massa moderada (se comparada aos outros objetos) e textura com alto coeficiente de atrito, por isso apresentaram bons resultados de resposta do classificador. Além disso, como é possível observar na tabela 4.2, o classificador conseguiu identificar o evento de escorregamento com verdadeiro positivo em 100% dos 20 ensaios realizados, para os três objetos citados acima.

Quando a atenção é direcionada à bola de borracha pode-se notar que a distribuição de seus resultados apresentou mediana com valor de 40 ms e que o classificador conseguiu identificar corretamente alguma amostra com presença de escorregamento em 75% dos ensaios realizados. O seu tempo de resposta superior aos três objetos citados acima (bola de golf, bola de tênis e copo de plástico rígido) pode ser explicado pela sua menor rigidez. Por ser um objeto mais macio, as ondas de vibração vindas do deslizamento entre as superfícies são mais atenuadas, do que se comparadas às de um objeto rígido. Porém, o nível de acerto de classificação para este objeto foi relativamente alto (75%), pois a superfície da bola de borracha apresenta alto coeficiente de atrito. Assim, pode-se inferir que a baixa rigidez afeta os resultados negativamente (pois atenua mais fortemente as onda de vibração que chegam ao sensor acústico) e que a superfície mais rugosa afeta positivamente o resultado, por produzir sinais de maior

amplitude e frequência no sensor acústico.

Ao analisar os resultados da caixa de papelão e do cilindro aveludado, percebe-se que o número de vezes em que o classificador conseguiu identificar amostras referentes ao escorregamento, para os 20 ensaios, foi bastante baixo (10% dos ensaios). Este resultado mostra que a diferença entre os sinais referentes à presença e ausência de escorregamento, para estes dois objetos, é pequena e por isso, o classificador não conseguiu separar muito bem as amostras referente às duas classes. Uma peculiaridade destes dois objetos é a sua baixa massa, sendo estes, os objetos mais leves dentre todos utilizados no trabalho.

Como é mostrado na Figura 2.1, quanto menor a massa do objeto a ser segurado, menor será a força normal bilateral necessária para a estabilização de sua prensão. Seguindo o mesmo raciocínio, quanto menor a força de prensão entre o sensor acústico e o objeto, menor será a amplitude da onda de vibração quando as duas superfícies são deslizadas entre si. Por isso é que a diferença entre sinais com presença e ausência de escorregamento foram pouco significativas, para estes dois objetos, o que levou à baixa acurácia de classificação da RNA para estes casos. Ao analisar o tempo de resposta entre a caixa de papelão e o cilindro aveludado, percebe-se que o classificador levou em média 90 ms para identificar o escorregamento na caixa de papelão e para o cilindro aveludado, -20 ms. Por a caixa de papelão apresentar superfície menos rugosa, é necessário que haja um escorregamento mais intenso (com maior velocidade) para que produza um sinal com características que facilitem a sua classificação, frente ao sinal estático, por isso o seu tempo de resposta foi mais lento. O mesmo raciocínio é válido para o cilindro com veludo. Sua superfície apresenta maior coeficiente de atrito, por isso o início de seu escorregamento é suficiente para produzir sinais com maior frequência, o que permite a classificação de amostras com escorregamento mais rapidamente.

Os resultados obtidos com tempo negativos significam que o classificador conseguiu identificar o início do escorregamento antes que a primeira amostra fosse rotulada com presença de escorregamento. Como este rótulo teve origem num experimento em que o início do escorregamento foi identificado como a queda de uma haste perfurada em no mínimo 1 mm, pode ocorrer que o escorregamento tenha se iniciado de fato antes de o sensor óptico ter detectado o início da queda do objeto, justamente pela sua resolução mínima de 1 mm. Por isso, são obtidos valores negativos referentes ao tempo de resposta do classificador.

Ao direcionar a análise para o tempo de resposta da tábua de madeira, percebe-se que o seu resultado apresentou mediana em 50 ms e acurácia de classificação de 85%. O valor do tempo de resposta se localiza ao centro entre os valores mínimos e máximos para todos os objetos. Este resultado foi obtido, pois o objeto apresenta massa elevada e superfície mais lisa

do que a maioria dos outros objetos.

A classificação do escorregamento para a borracha espessa do tipo EVA apresentou tempo de resposta semelhante ao da tábua de madeira (45 ms), porém sua acurácia foi baixa (20%). Sobre este resultado, pode-se inferir que devido o material ser construído quase puramente de borracha macia, a sua capacidade de atenuação da amplitude da onda de vibração é elevada. Por isso, a RNA não foi capaz de distinguir tão bem os sinais com presença e ausência de escorregamento, o que levou à baixa acurácia.

Por fim, decidiu-se agrupar a análise dos resultados do frasco de vidro e da bola de bilhar, pois os dois materiais apresentam textura e rigidez próximas. Porém uma característica que os diferencia é a sua massa, sendo mais elevada na bola de bilhar. Pelo fato de possuir maior massa, a bola de bilhar obteve tempo de resposta menor e melhor acurácia de classificação, se comparada aos resultados do frasco de vidro. Estes resultados fortalecem os indícios de que a massa é um fator importante para a detecção de sinais de escorregamento pelo sensor acústico. Além disso, a elevada rigidez se mostra, novamente, importante para se ter bons resultados vindos do classificador.

### 5.3 Análise da performance do sistema em tempo real

Comparando as Tabelas 4.3 e 4.2, é possível notar que os valores de acurácia de classificação do evento de escorregamento se mostraram próximos quando foi analisado o sinal coletado offline e o sistema com funcionamento online.

Este resultado prova que o experimento de coleta dos sinais offline obteve dados bastante próximos àqueles adquiridos dos sensores em tempo real. Por isso, é possível utilizar os dados coletados no experimento para o treinamento da RNA, e a matriz de pesos obtida deste treinamento pode ser inserida no sistema de controle *online*.

A acurácia de classificação para alguns casos (como a borracha do tipo EVA e o cilindro aveludado) foi superior no sistema *online*, pois a posição inicial do objeto pode ter sido variada, o que gerou o aumento da superfície de contato entre o sensor acústico e o objeto e assim, o sinal do escorregamento pode ter sofrido aumento em amplitude ou frequência, o que melhorou a diferenciação entre as amostras referentes às duas classes e levou ao melhor resultado de acurácia.

É possível comparar os resultados obtidos neste trabalho com os resultados de outros autores. Veiga F. et al. [43] e Chu et al. [5] realizaram um experimento semelhante ao apresentado neste documento, eles utilizaram técnicas de Machine Learning para identificar o

escorregamento em diferentes materiais, analisando os sinais de diversos sensores em tempo real. O parâmetro de avaliação escolhido pelos dois autores foi a porcentagem de vezes que o classificador conseguiu identificar corretamente o escorregamento. Mesmo que estes autores não tenham utilizado exatamente a mesma métrica de validação da utilizada neste trabalho, é possível dizer que a porcentagem de classificação correta do escorregamento leva à estabilização da prensão do objeto, por isso foi feita esta comparação. Veiga F. et al. obteve os melhores resultados com uma SVM e Chu et al. utilizou o algoritmo de Random Forest para validação do seu trabalho.

Comparando a performance do algoritmo para a detecção do escorregamento para objetos mais rígidos e com baixa rugosidade (ou seja, com características próximas ao do copo de plástico rígido), Veiga F. et al. conseguiu uma acurácia de classificação de 97.54%, enquanto Chu et al. conseguiu uma acurácia de 94.17%. Comparando os resultados dos dois autores com os resultados obtidos neste trabalho, é possível dizer que foi atingido um ganho na acurácia para objetos rígidos, visto que foi obtida uma acurácia de 100%.

Quando é analisada a acurácia de classificação para objetos mais macios, como a bola de borracha, Veiga F. et conseguiu uma acurácia de classificação de 97.74% e Chu et al. conseguiu uma acurácia de 51.18%. Para esta situação, o sistema desenvolvido neste trabalho obteve desempenho de 80%, o que foi mais satisfatório que Chu et al., porém Veiga F. et atingiu os melhores resultados.

Os resultados da performance do sistema apontados na Tabela 4.3 mostram que o sistema desenvolvido atingiu bons resultados para a estabilização da prensão em objetos mais rígidos, porém não se comportou tão bem para objetos muito macios e com pouca massa.

Isto se mostrou como uma limitação, devido ao sensor utilizado ter seu princípio de funcionamento baseado na captação de vibração gerada pelo escorregamento entre a superfície do sensor e o objeto a ser prensado. Quando há um escorregamento em um objeto mais macio, ou com pouca massa, a amplitude e frequência da onda de vibração são atenuadas e assim não são muito bem diferenciados pelo algoritmo classificador, o que compromete a detecção do escorregamento e a estabilização da prensão para objetos com estas características.

Assim, é possível dizer que a massa do objeto tem influência positiva na classificação do escorregamento. Objetos com maior massa, ao deslizarem, geram vibrações com maior amplitude, enquanto objetos com maior rugosidade geram ondas de vibração com maior frequência.

# Capítulo 6

## Conclusões

É possível concluir que o sistema implementado apresentou bons resultados no controle da prensão de objetos. Porém, para objetos com baixa rigidez e massa, os resultados foram menos satisfatórios. Estes resultados se devem, principalmente, às limitações do hardware, que geraram uma baixa relação de sinal ruído. Diante disso, para os casos de objetos com pequena massa e baixa rigidez, o sinal dos sensores quando na presença de escorregamento foi bastante similar ao sinal quando na ausência de escorregamento, o que fez com que o classificador não conseguisse diferenciar muito bem estes dois comportamentos.

No entanto, se o circuito condicionar for incrementado de forma que o sinal de entrada do classificador (sinais dos sensores) tenha amplitudes adequadas, o dispositivo proposto terá bons resultados para objetos com características diversas, sendo equiparado aos melhores sistemas descritos na literatura.

São propostos como trabalhos futuros, a incrementação do circuito condicionador dos sensores, de modo que a relação de sinal ruído seja melhorada e assim haja mais diferença nos sinais referentes à presença e ausência de escorregamento. Isto é importante para aumentar a acurácia do algoritmo classificador. Outro trabalho futuro proposto é a importação do algoritmo classificador (já treinado) para o microcontrolador, para que o sistema fique totalmente embarcado e não tenha necessidade de se conectar a um PC para realizar a classificação dos dados dos sensores.

# Referências Bibliográficas

- [1] Brigida Cristina Fernandes Batista. *Soluções de Equações Diferenciais Usando Redes Neurais de Múltiplas camadas com os métodos da Descida mais íngreme e Levenberg-Marquardt*. PhD thesis, Dissertação de mestrado, PPGME-ICEN-UFPA, 2012. <http://dx.doi.org/10.1.1/jpb001>.
- [2] Lucia Beccai, Stefano Roccella, Alberto Arena, Francesco Valvo, Pietro Valdastri, Arianna Menciassi, Maria Chiara Carrozza, and Paolo Dario. Design and fabrication of a hybrid silicon three-axial force sensor for biomechanical applications. *Sensors and Actuators A: Physical*, 120(2):370–382, 2005. <http://doi.org/10.1016/j.sna.2005.01.007>.
- [3] Alberto Dellacasa Bellingegni, Emanuele Gruppioni, Giorgio Colazzo, Angelo Davalli, Rinaldo Sacchetti, Eugenio Guglielmelli, and Loredana Zollo. Nlr, mlp, svm, and lda: a comparative analysis on emg data from people with trans-radial amputation. *Journal of neuroengineering and rehabilitation*, 14(1):82, 2017. <http://doi.org/10.1186/s12984-017-0290-6>.
- [4] Dudley S Childress. Historical aspects of powered limb prostheses. *Clin Prosthet Orthot*, 9(1):2–13. 1985.
- [5] Vivian Chu, Ian McMahon, Lorenzo Riano, Craig G McDonald, Qin He, Jorge Martinez Perez-Tejada, Michael Arrigo, Naomi Fitter, John C Nappo, Trevor Darrell, et al. Using robotic exploratory procedures to learn the meaning of haptic adjectives. In *2013 IEEE International Conference on Robotics and Automation*, pages 3048–3055. IEEE, 2013. <http://doi.org/10.1109/ICRA.2013.6631000>.
- [6] Darryl PJ Cotton, Paul H Chappell, Andy Cranny, Neil M White, and Steve P Beeby. A novel thick-film piezoelectric slip sensor for a prosthetic hand. *IEEE sensors journal*, 7(5):752–761, 2007. <http://doi.org/10.1109/JSEN.2007.894912>.
- [7] Andy Cranny, Darryl PJ Cotton, Paul H Chappell, SP Beeby, and NM White. Thick-film

- force and slip sensors for a prosthetic hand. *Sensors and Actuators A: Physical*, 123:162–171, 2005. <http://doi.org/10.1016/j.sna.2005.02.015>.
- [8] Ravinder S Dahiya, Giorgio Metta, Maurizio Valle, and Giulio Sandini. Tactile sensing—from humans to humanoids. *IEEE transactions on robotics*, 26(1):1–20, 2009. <http://doi.org/10.1109/TRO.2009.2033627>.
- [9] Dzung Viet Dao, Susumu Sugiyama, Shinichi Hirai, et al. Development and analysis of a sliding tactile soft fingertip embedded with a microforce/moment sensor. *IEEE Transactions on Robotics*, 27(3):411–424, 2011. <http://doi.org/10.1109/TRO.2010.2103470>.
- [10] P Dario, R Lazzarini, R Magni, and SR Oh. An integrated miniature fingertip sensor. In *MHS'96 Proceedings of the Seventh International Symposium on Micro Machine and Human Science*, pages 91–97. IEEE, 1996. <http://doi.org/10.1109/MHS.1996.563407>.
- [11] Venketesh N Dubey and Richard M Crowder. A dynamic tactile sensor on photoelastic effect. *Sensors and Actuators A: Physical*, 128(2):217–224, 2006. <http://doi.org/10.1016/j.sna.2006.01.040>.
- [12] Maria Teresa Francomano, Dino Accoto, and Eugenio Guglielmelli. Artificial sense of slip—a review. *IEEE Sensors Journal*, 13(7):2489–2498, 2013. <http://doi.org/10.1109/JSEN.2013.2252890>.
- [13] MT Francomano, D Accoto, Elisa Morganti, Leandro Lorenzelli, and E Guglielmelli. A microfabricated flexible slip sensor. In *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechanics (BioRob)*, pages 1919–1924. IEEE, 2012. <http://doi.org/10.1109/BioRob.2012.6290907>.
- [14] Isao Fujimoto, Yoji Yamada, Tetsuya Morizono, Y Umetani, and Takashi Maeno. Development of artificial finger skin to detect incipient slip for realization of static friction sensation. In *Proceedings of IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, MFI2003.*, pages 15–20. IEEE, 2003. <http://doi.org/10.1109/MFI-2003.2003.1232571>.
- [15] Akio Gofuku, Yutaka Tanaka, and Junji Tsubot. Development of a flexible artificial hand system equipped with a slip sensor. *JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing*, 43(2):378–386, 2000. <https://doi.org/10.1299/jsmec.43.378>.

- [16] Mohamed G Gouda and Nicholas J Multari. Stabilizing communication protocols. *IEEE Transactions on Computers*, (4):448–458, 1991. <http://doi.org/10.1109/12.88464>.
- [17] Martijn Goudbeek, Anne Cutler, and Roel Smits. Supervised and unsupervised learning of multidimensionally varying non-native speech categories. *Speech communication*, 50(2):109–125, 2008. <http://doi.org/10.1016/j.specom.2007.07.003>.
- [18] S Hackwood, G Beni, LA Hornak, R Wolfe, and TJ Nelson. A torque-sensitive tactile array for robotics. *The International Journal of Robotics Research*, 2(2):46–50, 1983. <http://doi.org/10.1177/027836498300200204>.
- [19] EGM Holweg, H Hoeve, W Jongkind, Lorenzo Marconi, Claudio Melchiorri, and Claudio Bonivento. Slip detection by tactile sensors: algorithms and experimental results. In *Proceedings of IEEE International Conference on Robotics and Automation*, volume 4, pages 3234–3239. IEEE, 1996. <http://doi.org/10.1109/ROBOT.1996.509205>.
- [20] Koh Hosoda, Yasunori Tada, and Minoru Asada. Internal representation of slip for a soft finger with vision and tactile sensors. In *IEEE/RSJ International Conference on Intelligent Robots and Systems*, volume 1, pages 111–115. IEEE, 2002. <http://doi.org/10.1109/IRDS.2002.1041373>.
- [21] Koh Hosoda, Yasunori Tada, and Minoru Asada. Anthropomorphic robotic soft fingertip with randomly distributed receptors. *Robotics and Autonomous Systems*, 54(2):104–109, 2006. <http://doi.org/10.1016/j.robot.2005.09.019>.
- [22] Robert D Howe and Mark R Cutkosky. Dynamic tactile sensing: Perception of fine surface features with stress rate sensing. *IEEE transactions on robotics and automation*, 9(2):140–151, 1993. <http://doi.org/10.1109/70.238278>.
- [23] Atsutoshi Ikeda, Yuichi Kurita, Jun Ueda, Yoshio Matsumoto, and Tsukasa Ogasawara. Grip force control for an elastic finger using vision-based incipient slip feedback. In *2004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)(IEEE Cat. No. 04CH37566)*, volume 1, pages 810–815. IEEE, 2004. <http://doi.org/10.1109/IROS.2004.1389452>.
- [24] Gareth James, Daniela Witten, Trevor Hastie, and Robert Tibshirani. *An introduction to statistical learning*, volume 112. Springer, 2013.

- [25] Nathalie Japkowicz. Supervised versus unsupervised binary-learning by feedforward neural networks. *Machine Learning*, 42(1-2):97–122, 2001. <http://doi.org/10.1023/A:1007660820062>.
- [26] RS Johansson and G Westling. Programmed and triggered actions to rapid load changes during precision grip. *Experimental brain research*, 71(1):72–86, 1988. <http://doi.org/10.1007/BF00247523>.
- [27] Neupsy Key. The somatosensory system: Receptors and central pathways.
- [28] Peter J Kyberd and Paul H Chappell. Characterization of an optical and acoustic touch and slip sensor for autonomous manipulation. *Measurement Science and Technology*, 3(10):969, 1992.
- [29] Martin Långkvist, Lars Karlsson, and Amy Loutfi. A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42:11–24, 2014. <http://doi.org/10.1016/j.patrec.2014.01.008>.
- [30] Hans Dieter Luke. The origins of the sampling theorem. *IEEE Communications Magazine*, 37(4):106–108, 1999. <http://doi.org/10.1109/35.755459>.
- [31] Takashi Maeno, Kazumi Kobayashi, and Nobutoshi Yamazaki. Relationship between the structure of human finger tissue and the location of tactile receptors. *JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing*, 41(1):94–100, 1998. <http://doi.org/10.1299/jsmec.41.94>.
- [32] Claudio Melchiorri. Slip detection and control using tactile and force sensors. *IEEE/ASME transactions on mechatronics*, 5(3):235–243, 2000. <http://doi.org/10.1109/3516.868914>.
- [33] Andrei Nakagawa-Silva, Nitish V Thakor, John-John Cabibihan, and Alci-mar B Soares. A bio-inspired slip detection and reflex-like suppression method for robotic manipulators. *IEEE Sensors Journal*, 19(24):12443–12453, 2019. <http://doi.org/10.1109/JSEN.2019.2939506>.
- [34] Thanapant Raicharoen, Chidchanok Lursinsap, and Paron Sanguanbhokai. Application of critical support vector machine to time series prediction. In *Proceedings of the 2003 International Symposium on Circuits and Systems, 2003. ISCAS'03.*, volume 5, pages V–V. IEEE, 2003. <http://doi.org/10.1109/ISCAS.2003.1206419>.

- [35] Stuart J Russell and Peter Norvig. *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited, 2016.
- [36] Hamidreza N Sani and Sanford G Meek. Characterizing the performance of an optical slip sensor for grip control in a prosthesis. In *2011 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 1927–1932. IEEE, 2011. <http://doi.org/10.1109/IROS.2011.6095181>.
- [37] Hiroyuki Shinoda, Shinya Sasaki, and Katsuhiko Nakamura. Instantaneous evaluation of friction based on arctic tactile sensor. In *Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No. 00CH37065)*, volume 3, pages 2173–2178. IEEE, 2000. <http://doi.org/10.1109/ROBOT.2000.846350>.
- [38] Phil Simon. *Too big to ignore: the business case for big data*, volume 72. John Wiley & Sons, 2013.
- [39] Mandayam A Srinivasan, JM Whitehouse, and Robert H LaMotte. Tactile detection of slip: surface microgeometry and peripheral neural codes. *Journal of neurophysiology*, 63(6):1323–1332, 1990. <http://doi.org/10.1152/jn.1990.63.6.1323>.
- [40] Yuji Suzuki, Daigo Miki, Masato Edamoto, and Makoto Honzumi. A mems electret generator with electrostatic levitation for vibration-driven energy-harvesting applications. *Journal of Micromechanics and Microengineering*, 20(10):104002, 2010. <http://doi.org/10.1088/0960-1317/20/10/104002>.
- [41] Mohsin I Tiwana, Stephen J Redmond, and Nigel H Lovell. A review of tactile sensing technologies with applications in biomedical engineering. *Sensors and Actuators A: physical*, 179:17–31, 2012. <http://doi.org/10.1016/j.sna.2012.02.051>.
- [42] Marc R Tremblay and Mark R Cutkosky. Estimating friction using incipient slip sensing during a manipulation task. In *[1993] Proceedings IEEE International Conference on Robotics and Automation*, pages 429–434. IEEE, 1993. <http://doi.org/10.1109/ROBOT.1993.292018>.
- [43] Filipe Veiga, Herke Van Hoof, Jan Peters, and Tucker Hermans. Stabilizing novel objects by learning to predict tactile slip. In *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 5065–5072. IEEE, 2015. <http://doi.org/10.1109/IROS.2015.7354090>.

- [44] G Westling and Roland S Johansson. Responses in glabrous skin mechanoreceptors during precision grip in humans. *Experimental brain research*, 66(1):128–140, 1987. <http://doi.org/10.1007/BF00236209>.
- [45] Daisuke Yamada, Takashi Maeno, and Yoji Yamada. Artificial finger skin having ridges and distributed tactile sensors used for grasp force control. In *Proceedings 2001 IEEE/RSJ International Conference on Intelligent Robots and Systems. Expanding the Societal Role of Robotics in the the Next Millennium (Cat. No. 01CH37180)*, volume 2, pages 686–691. IEEE, 2001. <http://doi.org/10.1109/IROS.2001.976249>.
- [46] Libo Yuan. A novel fiber-optic slide-sensing scheme. *Optical Fiber Technology*, 7(4):340–349, 2001. <http://doi.org/10.1006/ofte.2001.0362>.