



VISÃO ROBÓTICA NA ANÁLISE AUTOMATIZADA DO PÉ DIABÉTICO

ANTÓNIO PEDRO ALMEIDA BASTOS

novembro de 2025

VISÃO ROBÓTICA NA ANÁLISE AUTOMATIZADA DO PÉ DIABÉTICO

António Pedro Almeida Bastos

**Dissertação para obtenção do Grau de Mestre em
Engenharia Biomédica**

Orientador: Prof. Dr. Luís Filipe Martins Pinto Coelho

Júri:

Presidente:

Joaquim Fernando Almeida Alves, Professor Adjunto, ISEP

Vogais:

Luís Filipe Martins Pinto Coelho, Professor Coordenador, ISEP

Luís João Rodrigues das Neves Correia Mourão, Professor Adjunto, ISEP

Orientador: Prof. Dr. Luís Filipe Martins Pinto Coelho

Júri:

Presidente:

Joaquim Fernando Almeida Alves, Professor Adjunto, ISEP

Vogais:

Luís Filipe Martins Pinto Coelho, Professor Coordenador, ISEP

Luís João Rodrigues das Neves Correia Mourão, Professor Adjunto, ISEP

Porto, outubro 2025

Resumo

A diabetes *mellitus* (DM), geralmente conhecida como diabetes, é uma doença crônica de elevada prevalência, constituindo uma das principais causas de mortalidade e morbidade. A ausência de tratamento pode conduzir a complicações graves, como o pé diabético, pelo que o diagnóstico precoce é fundamental. Na área clínica, existem métodos de diagnóstico, como os testes de sensibilidade do pé diabético com o monofilamento Semmes-Weinstein (SW), cuja repetição e simplicidade tornam a sua automatização vantajosa. Nesta dissertação, foi desenvolvido um sistema de análise do pé diabético como *end-effector* para robô, que permite a aproximação segura ao paciente e suporta a recolha de informação do mesmo pela utilização de sensores. Inicialmente, para o sistema de visão que estima a localização dos pontos em avaliação, foram utilizadas as redes neuronais convolucionais UNet e UNet 3+ para segmentação de imagens da região plantar. Posteriormente, desenvolveu-se um *end-effector* instrumentado, na forma de um sistema de análise de parâmetros como a força e temperatura, utilizando um transdutor de força e um termómetro MLX90614, com transmissão dos dados para o PC. Foram realizados testes para validar o funcionamento do sistema e estudar a influência da tara antes de efetuar medições. Por último, desenvolveu-se um programa em *Python* para controlo do robô UR3e, permitindo automatizar o teste de sensibilidade com o *end-effector* acoplado. A arquitetura UNet revelou melhor desempenho de segmentação, com F1-Score e índice de Jaccard superiores e maior equilíbrio entre *precision* e *recall*, enquanto a UNet 3+ apresentou instabilidade e uma forte dependência do *dataset*. Nos testes com o transdutor, a aplicação da tara mostrou ser essencial para eliminar o *offset* inicial e garantir medições mais fiáveis e reproduzíveis. O sistema robótico desenvolvido demonstrou a viabilidade da automatização do teste com o monofilamento Semmes-Weinstein com o robô UR3e, embora persistam limitações que deverão ser colmatadas em desenvolvimentos futuros. O projeto desenvolvido demonstrou o potencial de aplicações de robôs colaborativos no contexto biomédico, ao automatizar processos e recolher dados de interesse, através de sistemas de análise como os *end-effectors*. Assim, constitui um ponto de partida para o desenvolvimento de futuros trabalhos mais eficientes e adaptáveis aos contextos clínicos em evolução constante.

Palavras-chave: Pé Diabético, Monofilamento Semmes-Weinstein, Segmentação de Imagens, *End-Effector*, Robôs Colaborativos, Automatização

Abstract

Diabetes mellitus (DM), commonly known as diabetes, is a chronic disease with high prevalence, constituting one of the leading causes of mortality and morbidity. Lack of treatment can lead to serious complications, such as diabetic foot, so early diagnosis is essential. In the clinical field, there are diagnostic methods such as diabetic foot sensitivity tests using the Semmes-Weinstein (SW) monofilament, whose repeatability and simplicity make automation advantageous. In this dissertation, a diabetic foot analysis system was developed as an end-effector for a robot, which allows safe approach to the patient and supports the collection of information from the patient through the use of sensors. Initially, for the vision system that estimates the location of the points under evaluation, UNet and UNet 3+ convolutional neural networks were used for image segmentation of the plantar region. Subsequently, an instrumented end-effector was developed in the form of a system for analysing parameters such as force and temperature, using a force transducer and an MLX90614 thermometer, with data transmission to the PC. Tests were carried out to validate the functioning of the system and study the influence of tare before taking measurements. Finally, a Python programme was developed to control the UR3e robot, allowing the sensitivity test to be automated with the end-effector attached. The UNet architecture showed better segmentation performance, with higher F1-Score and Jaccard index and greater balance between precision and recall, while UNet 3+ showed instability and a strong dependence on the dataset. In tests with the transducer, the application of tare proved essential to eliminate the initial offset and ensure more reliable and reproducible measurements. The robotic system developed demonstrated the feasibility of automating the Semmes-Weinstein monofilament test with the UR3e robot, although limitations remain that should be addressed in future developments. The project demonstrated the potential of collaborative robots applications in the biomedical context by automating processes and collecting data of interest through analysis systems such as end-effectors. Thus, it constitutes a starting point for the development of future work that is more efficient and adaptable to constantly evolving clinical contexts.

Keywords: Diabetic Foot, Semmes-Weinstein Monofilament, Automation, Image Segmentation, End-Effector, Collaborative Robots

Agradecimentos

Em primeiro lugar, gostaria de expressar a minha sincera gratidão ao meu orientador, Professor Luís Coelho pela orientação científica, pela disponibilidade e pelos conselhos prestados ao longo de todo este percurso. Agradeço também ao Professor António Ferreira da Silva, pela oportunidade de trabalhar no laboratório de robótica, contribuindo para o enriquecimento e desenvolvimento de novas competências.

Agradeço a todos os professores que transmitiram conhecimentos ao longo do meu percurso, assim como a todos os meus colegas com quem tive o prazer de partilhar vivências e construir amizades.

Por fim, estendo os meus agradecimentos à minha família por todo o apoio incondicional e sacrifícios ao longo destes anos, que constituíram pilares fundamentais para o meu desenvolvimento pessoal e académico.

Índice

1	Introdução	1
1.1	Motivação/Enquadramento	1
1.2	Objetivos	2
1.3	Estrutura da Dissertação	2
2	Conceitos Teóricos	5
2.1	Diabetes Mellitus	5
2.1.1	Patofisiologia	5
2.1.2	Diabetes Tipo I	6
2.1.3	Diabetes Tipo II	6
2.1.4	Prevalência	7
2.1.5	Complicações crónicas graves	7
2.2	Segmentação Automática de Imagens Médicas	8
2.3	Robôs colaborativos e <i>end-effectors</i>	10
3	Revisão Bibliográfica	13
3.1	Métodos manuais de diagnóstico da neuropatia diabética/pé diabético	13
3.1.1	Testes de toque	13
3.1.2	Testes de vibração	14
3.1.3	Termografia	17
3.2	Métodos automatizados de diagnóstico da neuropatia diabética/pé diabético	18
3.2.1	Machine Learning/Deep Learning	18
3.2.2	Wearables	20
3.2.3	Robótica e protótipos	21
4	Metodologia	25
4.1	Segmentação de imagens de pés com marcações dos pontos de teste do monofilamento SW	25
4.1.1	<i>Datasets</i>	25
4.1.2	Arquitetura geral	26
4.1.3	Treinos dos algoritmos UNet e UNet 3+	27
4.2	Sistema <i>End-Effector</i> para avaliação plantar	28
4.2.1	Componentes	28
4.2.2	Desenvolvimento do protótipo e programa	30
4.2.3	Estudo da influência da aplicação de tara no registo de força pelo transdutor	33
4.3	Robô UR3e e acoplamento do <i>end-effector</i>	33
5	Resultados	39
5.1	Imagens de previsão e métricas de avaliação de desempenho da segmentação de imagens	39

5.2	Sistema <i>End-Effector</i>	42
5.2.1	Efeito da tara na recolha de valores de força pelo transdutor	43
5.3	Teste do monofilamento SW automatizado com <i>end-effector</i> acoplado.....	49
6	Conclusões.....	51
6.1	Trabalhos futuros.....	52
	Referências	53
	Anexos	61

Lista de Figuras

Figura 1 – Prevalência da diabetes globalmente, em 2021 [2]	7
Figura 2 – Complicações crónicas tradicionais e emergentes da diabetes, adaptado de [22].....	8
Figura 3 – Diagrama de Venn dos conceitos e classes de <i>machine learning</i> , adaptado de [28] ..	9
Figura 4 – Classificação, localização e segmentação em imagens de objetos únicos e múltiplos [29].....	9
Figura 5 – Comparação de arquiteturas dos modelos: a) UNet; b) UNet 3+ [32].....	10
Figura 6 – a) Pontos principais na avaliação da sensibilidade com o monofilamento SW (planta e dorso do pé) [40]; b) técnica de uso do monofilamento no teste referido [39]	13
Figura 7 – VibraTip™ [61].....	17
Figura 8 – a) Protótipo da palmilha e localização dos sensores; b) Aplicação móvel [70].....	20
Figura 9 – Componentes principais do IMR [72]	21
Figura 10 – a) Protótipo do sistema de monitorização; b) Aplicação do protótipo no teste [73]	22
Figura 11 – Protótipo automatizado desenvolvido por Castellano et al. [74].....	23
Figura 12 – Imagens constituintes do <i>dataset</i> 1: a) fotografia dos pés com fundo preto; b) máscara com a segmentação dos pontos de teste nos dedos dos dois pés	26
Figura 13 – Imagens constituintes do <i>dataset</i> 2: a) imagem dos pés criada por IA; b) máscara com a segmentação dos pontos de teste completo nos dois pés	26
Figura 14 – Arquitetura geral da utilização da UNet e UNet 3+	27
Figura 15 – Sistema <i>end-effector</i> : a) Arduino UNO e respetiva <i>datasheet</i> ; b) célula de carga e respetivo amplificador HX711 [78]	28
Figura 16 – Esquema de montagem do sistema.....	29
Figura 17 – Princípio de funcionamento do transdutor de força [79]	29
Figura 18 - Termómetro infravermelho [82]	30
Figura 19 – Montagem para efetuar a calibração do transdutor de força	31
Figura 20 – Componentes: a) Suporte para o filamento; b) filamento posicionado; c) termómetro infravermelho MLX90614.....	32
Figura 21 – Sistema <i>end-effector</i> completo	32
Figura 22 - Aplicação do <i>end-effector</i> por parte de um operador, perpendicularmente ao pé do voluntário	33
Figura 23 – Robô UR3: a) robô; b) <i>Polyscope</i> (painel interativo do robô)	34
Figura 24 - Definições de dois dos movimentos do robô utilizados no programa: a) “MoveJ”; b) “MoveL”	35
Figura 25 – Painel de controlo da posição, orientação e definição do TCP	35
Figura 26 – Coordenadas de um ponto, em milímetros e orientação do TCP, em radianos	36
Figura 27 – Objetos para definição dos pontos: a) molde do pé com os pontos de contacto; b) <i>end-effector</i> acoplado ao braço robótico	36
Figura 28 – Estrutura do programa desenvolvido no <i>Polyscope</i>	37
Figura 29 – Controlo do robô: a) sistema de controlo externo conectado à caixa de controlo; b) caixa de controlo do robô	38

Figura 30 – Resultados visuais do treino da UNet com o <i>dataset</i> 1: a) imagem original do pé; b) respetiva máscara de segmentação; c) previsão de segmentação do modelo	39
Figura 31 – Resultados visuais do treino da UNet 3+ com o <i>dataset</i> 1 alterado: a) imagem original do pé; b) respetiva máscara da segmentação; c) previsão de segmentação do modelo	39
Figura 32 – Resultados visuais do treino da UNet 3+ com o <i>dataset</i> 2: a) imagem original do pé; b) respetiva máscara de segmentação; c) previsão de segmentação do modelo	40
Figura 33 – Comparação de performance da UNet 3+ com o conjunto de teste do <i>dataset</i> 1 alterado e <i>dataset</i> 2: <i>boxplots</i> das métricas de avaliação de desempenho	40
Figura 34 – Comparação da performance da UNet 3+ com o conjunto de teste do <i>dataset</i> 1 alterado e <i>dataset</i> 2: <i>boxplots</i> das métricas de avaliação de desempenho	41
Figura 35 – Lista de comandos do programa	42
Figura 36 – Teste completo: a) Valores da força, temperatura ambiente e do pé do paciente registadas pelo transdutor de força e sensor de temperatura, respetivamente, nos diferentes pontos; b) apresentação dos resultados agrupados numa tabela	43
Figura 37 – Comparação da força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a uma mulher de 18 anos.....	45
Figura 38 – Comparação da força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a uma mulher de 56 anos.....	46
Figura 39 – Comparação da força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a um homem de 56 anos.....	48
Figura 40 – Ligações entre o computador e caixa de controlo do robô e acoplamento do <i>end-effector</i> ao braço robótico.....	49

Lista de Tabelas

Tabela 1 – Resumo dos estudos analisados relativos ao <i>machine learning</i>	19
Tabela 2 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 18 anos, manualmente e sem tara efetuada antes de cada teste completo	44
Tabela 3 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 18 anos, manualmente e com tara efetuada antes de cada teste completo.....	44
Tabela 4 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 56 anos, manualmente e sem tara efetuada antes de cada teste completo	45
Tabela 5 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 56 anos, manualmente e com tara efetuada antes de cada teste completo.....	46
Tabela 6 – Valores da força registados pelo transdutor de força, nos testes realizados a um homem de 56 anos, manualmente e sem tara efetuada antes de cada teste completo	47
Tabela 8 – Valores da força registados pelo transdutor de força, nos testes realizados a um homem de 56 anos, manualmente e com tara efetuada antes de cada teste completo	47

Acrónimos e Símbolos

Lista de Acrónimos

A/D	Analógico-Digital
AVC	Acidente Vascular Cerebral
CNN	<i>Convolutional Neural Networks</i> (Redes Neurais Convolucionais)
DM	Diabetes <i>Mellitus</i>
DMT1	Diabetes <i>Mellitus</i> Tipo 1
DMT2	Diabetes <i>Mellitus</i> Tipo 2
GPU	<i>Graphics Processing Unit</i> (Unidade de Processamento Gráfico)
HRI	<i>Human Robot Interaction</i> (Interação Humano-Robô)
IDE	<i>Integrated Development Environment</i>
IDF	<i>International Diabetes Federation</i> (Federação Internacional da Diabetes)
IWGDF	<i>International Working Group on the Diabetic Foot</i> (Grupo de Trabalho Internacional do Pé Diabético)
MTAC	<i>Medical Technologies Advisory Committee</i>
NICE	<i>National Institute for Health and Care Excellence</i>
NPSD	Neuropatia Periférica Sensitivo-Motora Diabética
TCP	<i>Tool Center Point</i> (Ponto Central da Ferramenta)
VPT	<i>Vibration Perception Threshold</i> (Limiar de Percepção de Vibração)
SW	<i>Semmes-Weinstein</i>
UR	<i>Universal Robots</i>

Lista de Unidades

°C	Graus Celsius
cm	centímetros

mm	milímetros
mm/s	milímetros por segundo
mm/s²	milímetros por segundo ao quadrado
N	<i>Newton</i> s
°/s	graus por segundo
°/s²	graus por segundo ao quadrado

1 Introdução

O presente capítulo introduz, brevemente, o problema abordado na tese. Desta forma, o mesmo apresenta a motivação/enquadramento, os objetivos propostos e a estrutura das restantes secções que constituem o trabalho.

1.1 Motivação/Enquadramento

A diabetes *mellitus* (DM), geralmente conhecida como diabetes, é uma doença crónica e perigosa, com um grande impacto na vida e no bem-estar, afetando indivíduos de todas as idades, géneros e localizações geográficas, tornando-a uma das causas globais mais prevalentes de mortalidade e morbilidade [1]. A doença ocorre quando os níveis de glucose no sangue aumentam porque existe uma glicogénese e glicogenólise, onde o corpo não consegue produzir uma quantidade suficiente de insulina (hormona produzida pelo pâncreas) ou não consegue utilizar eficazmente a insulina que produz, o que leva a níveis muito elevados de glucose no sangue, levando à hiperglicemia [1],[2]. A DM não tratada pode levar a complicações graves, como o pé diabético, que, quando não acompanhado, pode resultar em feridas graves ou até amputações, pelo que o diagnóstico precoce é fundamental [3].

O acompanhamento do pé diabético é feito em consultas de rotina por profissionais de saúde. O processo de avaliação passa pela análise da sensibilidade da região plantar de forma a identificar zonas que possam ter esta reduzida por ação da doença. Dos vários métodos de avaliação existentes, a abordagem baseada no monofilamento de Semmes-Weinstein é a mais popular devido à sua simplicidade e baixo-custo. No entanto esta técnica tem problemas de fiabilidade e é um pouco demorada quando se pretende uma abordagem mais massificada.

Desenvolvimentos recentes na robótica têm permitido a sua utilização próxima dos humanos. Na área clínica, existem ainda diversas tarefas que, pela sua simplicidade e repetição, podem ser alvo de automatização utilizando robôs. São exemplos a auscultação, a análise dermatológica, e, entre outros, os testes de sensibilidade do pé diabético, sendo este o foco desta dissertação. Pretende-se neste trabalho desenvolver um sistema *end-effector* para um robô que permita a aproximação segura ao paciente e suporte a recolha de informação do mesmo pela utilização de sensores.

1.2 Objetivos

O trabalho tem como objetivo central a construção de um protótipo do sistema de análise do pé diabético como *end-effector* para robô. De forma a obter o produto final, existem objetivos que devem ser atingidos:

- Identificação dos pontos de contacto entre o sistema e o pé através de *Computer Vision*;
- Desenvolvimento de um dispositivo que permita a leitura simultânea de força e temperatura;
- Aquisição e transmissão dos dados recolhidos, via rede sem fios ou por cabo, permitindo o seu registo, análise e leitura no computador;
- Realização automática do teste do monofilamento utilizando um robô colaborativo controlado a partir do computador;
- Integração do sistema de análise *end-effector* com o robô colaborativo;

1.3 Estrutura da Dissertação

A dissertação está dividida em vários capítulos e subcapítulos. Após a primeira secção, “Introdução”, onde o enquadramento e objetivos são abordados, seguem-se os capítulos de “Conceitos Teóricos”, “Revisão Bibliográfica”, “Metodologia”, “Resultados e Discussão” e, por fim, “Conclusões”.

O segundo capítulo, referente aos “Conceitos Teóricos”, introduz vários conceitos referentes ao contexto do trabalho. Primeiro, são apresentadas definições relativas à diabetes *mellitus*, os dois tipos de diabetes (tipo I e II), complicações crónicas graves que podem surgir pela doença, onde se incide sobre a neuropatia periférica e, posteriormente, pé diabético, prevalência da diabetes e neuropatia diabética, segmentação de imagens médicas e, por fim, robôs colaborativos e *end-effectors*.

O terceiro capítulo, “Revisão Bibliográfica”, apresenta todas as abordagens previamente utilizadas para efetuar a análise da termografia, sensibilidade e outros parâmetros do pé diabético, de forma a compreender o tema e métodos existentes.

Posteriormente, a secção da “Metodologia” contém todos os métodos e etapas que constituem o trabalho. Primeiro, apresenta todas as etapas e processos relativos ao treino dos modelos Unet e Unet+++ com dois *datasets*. Posteriormente, serão apresentados os métodos que foram utilizados para construir o sistema *end-effector*, incluindo *hardware* e *software*, assim como o procedimento utilizado para efetuar os testes com um operador, no qual utiliza o sistema de análise para avaliar a influência da presença ou não da tara, antes de realizar medições. Por último, são apresentadas as etapas para efetuar o controlo do robô UR3e, incluindo desenvolvimento do programa e ligações requeridas.

De seguida, o capítulo dos “Resultados e Discussão” apresenta todos os resultados relativos à utilização das redes neuronais convolucionais UNet e UNet 3+, os *outputs* do programa

desenvolvido para recolher dados da força e temperatura do pé, incluindo os resultados dos testes com e sem tara apresentados em tabelas e gráficos e, por último, os resultados do desenvolvimento do programa para controlo do robô UR3e com o *end-effector* acoplado.

Por último, o capítulo “Conclusões” sumariza todos os resultados e observações pertinentes, assim como trabalhos que possam melhorar ou enriquecer o trabalho.

2 Conceitos Teóricos

No capítulo em questão serão apresentados conceitos teóricos relativos à diabetes *mellitus*, ou simplesmente diabetes, os dois tipos característicos da doença, tipo I e II, complicações crônicas graves da diabetes e a prevalência mundial da diabetes e da neuropatia diabética/pé diabético, mundialmente. Posteriormente, serão descritos alguns conceitos relativos à segmentação de imagens médicas e, por fim, relativos à robótica, nomeadamente sobre robôs colaborativos e sistemas *end-effectors*.

2.1 Diabetes Mellitus

2.1.1 Patofisiologia

A diabetes *mellitus* é um grupo de perturbações metabólicas do metabolismo dos hidratos de carbono, em que a glicose é subutilizada como fonte de energia e produzida em excesso devido a uma gliconeogénese e glicogenólise inadequadas e problemas na capacidade de reação à insulina, resultando em hiperglicemia [2],[4]. Sintomas como polidipsia (sede excessiva), poliúria (ingestão excessiva de água) e polifagia (fome excessiva), juntamente com perdas de peso involuntárias, cansaço, fadiga e problemas de visão, caracterizam esta doença [4], [5].

O processo de patogénese da diabetes resulta da destruição das células T dos ilhéus de *Langerhans* ou, como referido anteriormente, desenvolvimento gradual de resistência à insulina e degeneração das células β [6]. A disfunção das células β é um fator importante na progressão da pré-diabetes para a diabetes. A pré-diabetes é uma condição definida por níveis de glicose no sangue para além do intervalo normal, mas que não atingem o limiar da diabetes. Caracteriza-se por uma diminuição da glicose em jejum e/ou da tolerância à glicose, representando uma fase inicial que pode progredir para diabetes tipo 2 (DMT2) [7], [8]. Após a progressão de tolerância normal à glicose para tolerância anormal à glicose, os níveis de glicose no sangue pós-prandial - após uma refeição - aumentam. Posteriormente, pode desenvolver-se hiperglicemia em jejum, à medida que a supressão da gliconeogénese hepática falha [7].

O aparecimento da doença está associado a múltiplos fatores de risco. A genética, a atmosfera, a perda da primeira fase associada ao lançamento da insulina, modo de vida sedentário e falta de exercício físico, tabagismo, bebidas alcoólicas, dislipidemia, sensibilidade celular reduzida, melhoria da atividade do glucagon (hormona produzida pelas células alfa do pâncreas, que aumenta a presença de glicose no sangue) são os principais fatores de risco para o desenvolvimento de pré-diabetes e DM [3], [9]. A obesidade está intrinsecamente ligada ao desenvolvimento da diabetes, em particular da DMT2, através de vários mecanismos. Conduz à resistência à insulina, em que as células do corpo deixam de responder à insulina, causando níveis elevados de glicose no sangue. Este aumento da procura das células β pancreáticas pode resultar na sua disfunção, diminuindo ainda mais a produção de insulina. Além disso, a inflamação crónica de baixo grau associada à obesidade exacerba a resistência à insulina e prejudica a função das células β devido à secreção de citocinas pró-inflamatórias do tecido adiposo [10], [11].

Os três principais tipos de diabetes são diabetes *mellitus* tipo I (DMT1), diabetes *mellitus* tipo II (DMT2), que serão descritos em detalhe nos subcapítulos seguintes e diabetes gestacional, que é geralmente definida como hiperglicemia detetada pela primeira vez, abaixo dos limiares de diagnóstico da diabetes durante ou fora da gravidez [12], [13].

2.1.2 Diabetes Tipo I

A DMT1 é uma doença crónica autoimune caracterizada pelo aumento dos níveis de glicose no sangue (hiperglicemia), que se deve à deficiência de insulina e pela uma destruição das células β pancreáticas, levando a uma deficiência absoluta na secreção de insulina [14], [15]. O início do DMT1 é tipicamente descrito em três fases. Na fase 1, a autoimunidade dos ilhéus (≥ 2 auto-anticorpos) sem disglucemia ocorre no contexto de combinações variáveis de fatores de risco genéticos e ambientais e pode durar desde meses a anos. Na fase 2, desenvolve-se uma disglucemia assintomática e na fase 3 é o início da doença sintomática [15]. Os doentes com DMT1 estão suscetíveis a desenvolver doenças autoimunes, como doença da tiróide autoimune, doença celíaca, doença de Addison e anemia por deficiência de vitamina B12 [16].

2.1.3 Diabetes Tipo II

A DMT2 caracteriza-se por uma deficiência relativa de insulina causada por disfunção das células β pancreáticas e resistência à insulina em órgãos-alvo [17]. Nas fases iniciais da doença, a resistência à insulina nos tecidos periféricos, como o músculo e gordura, está associada a um aumento compensatório da secreção de insulina pelas células β pancreáticas. A insulina segregada promove a utilização da glicose nos tecidos periféricos e diminui a gliconeogénese hepática. Os níveis de insulina em jejum aumentam progressivamente até que as células β não consigam compensar o aumento da resistência à insulina e ocorre falência. Subsequentemente, ocorre perda de células β pancreáticas e da secreção de insulina resulta em níveis de hiperglicemia definidos como DMT2 [18]. A epidemiologia da diabetes tipo 2 é afetada por fatores genéticos e por fatores ambientais. Os fatores genéticos atuam devido à obesidade, caracterizada por um comportamento sedentário e um consumo excessivo de açúcar e de gorduras na alimentação [17]. Como referido anteriormente, um indivíduo numa situação de pré-diabetes está em risco de a doença progredir para DMT2 [7], [8].

2.1.4 Prevalência

Globalmente, estima-se que existam, aproximadamente, 240 milhões de doentes com diabetes *mellitus* não diagnosticada. De acordo com o relatório de 2021 da Federação Internacional da Diabetes (IDF, do inglês *International Diabetes Federation*), “IDF *Diabetes Atlas 2021 10th Edition*” o número de doentes com diabetes *mellitus* foi de 536.6 milhões de pessoas, com idades compreendidas entre 20 e 79 anos, representando cerca de 10,5% da população total e registaram-se 6.7 milhões de mortes. Para 2030, a previsão retrata um aumento significativo para os 643 milhões (11,3% da população) e em 2045, o número de pessoas com diabetes atingirá os 783.2 milhões de pessoas (12,2% da população), o que se torna alarmante, visto que a diabetes é uma doença que requer muitos esforços financeiros por parte dos Serviços Nacionais de Saúde dos vários países. O valor global das despesas da saúde, em 2021, foi de 966 mil milhões de dólares e tal valor tende a aumentar para 1054 mil milhões de dólares, em 2045 [2], [19]. A Figura 1 apresenta um mapa mundial, onde é possível analisar a prevalência da diabetes *mellitus* nos vários países.

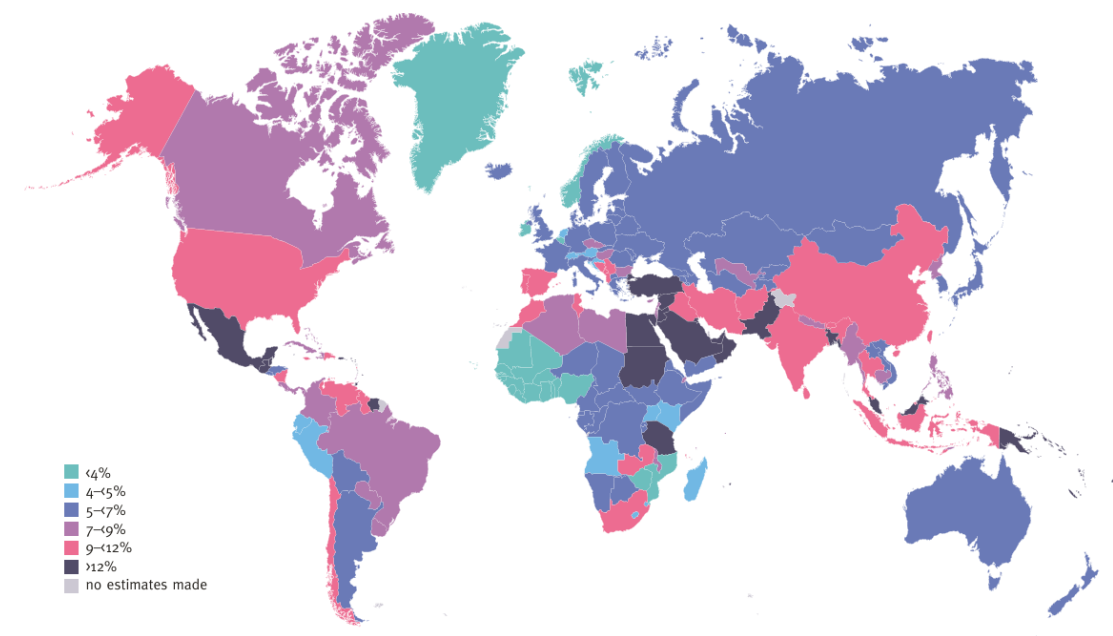


Figura 1 – Prevalência da diabetes globalmente, em 2021 [2]

Relativamente à neuropatia/pé diabético, a prevalência global inclui 131 milhões de pessoas (1,77% da população mundial) com problemas nas extremidades inferiores relacionados com a diabetes, dos quais 105.6 milhões (95% UI 85,5-128) apenas com neuropatia, 18.6 milhões (15.0-22.9) com úlceras nos pés, 4.3 milhões (3.7-4.9) com amputação sem prótese e 2.5 milhões (2.1-3.0) com amputação com prótese [20].

2.1.5 Complicações crónicas graves

Os doentes afetados por uma destas doenças podem desenvolver complicações crónicas graves, incluindo retinopatia, nefropatia, neuropatia periférica, doença cardiovascular, entre outras [21]. Na Figura 2, estão reunidas todas as complicações crónicas que se podem desenvolver a

partir da diabetes *mellitus*, divididas em complicações tradicionais, ou seja, as mais comuns e complicações emergentes, onde podem existir possíveis associações.

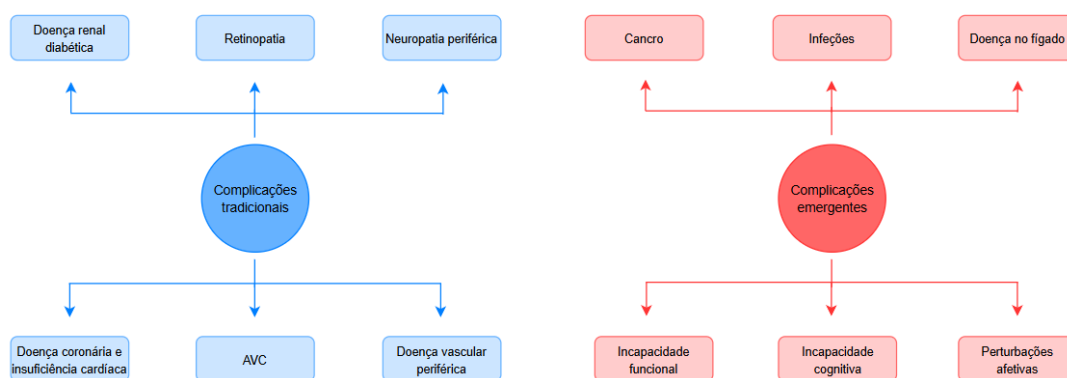


Figura 2 – Complicações crónicas tradicionais e emergentes da diabetes, adaptado de [22]

A neuropatia periférica sensitivo-motora diabética (NPSD) é uma das principais complicações da diabetes *mellitus* e é definida como uma polineuropatia sensitivo-motora simétrica, que resulta de alterações metabólicas e microvasculares, secundárias à hiperglicemia crónica e a outros fatores de risco cardiovasculares. Os nervos periféricos são danificados devido a estes fatores, o que resulta na perda de sensibilidade e alterações na pressão plantar, constituindo o principal fator precipitante das complicações do pé diabético, incluindo úlceras e neuroartropatia de *Charcot*, que, frequentemente, resultam em amputação dos membros inferiores. Outras sequelas clínicas da NPSD incluem dor neuropática (NPSD dolorosa) e um risco acrescido de quedas [23], [24]. O ponto de partida é nos dedos dos pés, bilateralmente, progredindo para o resto dos pés e pernas numa “distribuição em meia”. Assim que estabelecida nos membros inferiores, os membros superiores podem ser afetados [24].

Segundo o “*International Working Group on the Diabetic Foot (IWGDF)*” a úlcera do pé diabético é um conjunto de sintomas secundários à diabetes atual ou anterior, incluindo cortes na pele, ulceração, infeção ou destruição do tecido do pé, o que reflete em parte a natureza complexa e imprecisa deste conceito [25], [26]. No prazo de 2 anos, após a cicatrização de uma úlcera do pé diabético, a mortalidade é de 23% e aumenta para 71% aos 10 anos após uma úlcera incidente [23], [24].

2.2 Segmentação Automática de Imagens Médicas

Nos últimos anos a análise de imagens evolui significativamente devido ao surgimento de ferramentas de inteligência artificial. O machine learning (ML) (em português - aprendizagem de máquina), uma subclasse da inteligência artificial, é uma autoaprendizagem baseada em algoritmos que significam que o sistema aprende a partir da sua experiência. Por exemplo, aprende o padrão conforme o tipo de dados introduzidos no sistema e responde a partir da sua aprendizagem na saída. Neste caso, o sistema torna-se mais “inteligente” com o tempo, sem envolvimento humano. Para tal, utiliza um algoritmo de aprendizagem estatística que aprende e melhora automaticamente [27]. Durante as últimas décadas, o domínio do ML trouxe uma variedade de avanços notáveis em algoritmos de aprendizagem sofisticados e técnicas de pré-

processamento eficientes. Um destes avanços foi a evolução das redes neuronais artificiais para arquiteturas cada vez mais profundas com capacidades de aprendizagem melhoradas, resumidas como deep learning (em português - aprendizagem profunda). Em comparação com ML, aprende com a sua experiência, mas com uma grande base de dados (dataset) ou grandes informações fornecidas na entrada. O termo “deep “ ou “profundo” refere-se às várias camadas entre a entrada e a saída de uma rede neuronal, enquanto nas redes neuronais superficiais estão presentes no máximo duas camadas entre a entrada e a saída da rede neuronal [27], [28]. A Figura 3 apresenta um diagrama de Venn, onde é possível perceber as relações entre conceitos de machine learning.

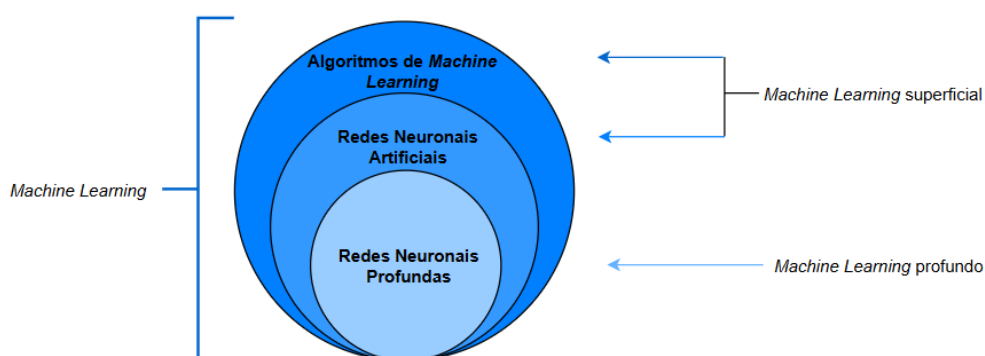


Figura 3 – Diagrama de Venn dos conceitos e classes de *machine learning*, adaptado de [28]

Uma das grandes áreas de aplicação das técnicas de aprendizagem automática na saúde é a análise automática de imagens. Neste contexto existem diversas tarefas que podem ser solicitadas a este sistemas, como se pode observar na Figura 4.

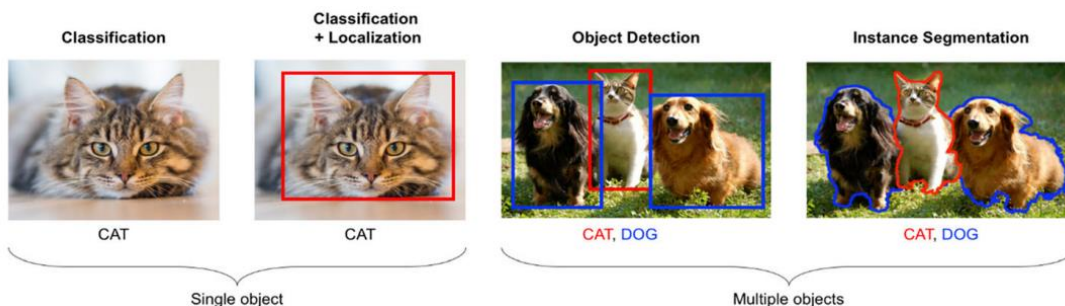


Figura 4 – Classificação, localização e segmentação em imagens de objetos únicos e múltiplos [29]

Neste trabalho procura-se identificar quais as zonas da região plantar que deverão ser alvo de avaliação. Neste sentido, a tarefa de segmentação, onde se pretende identificar zonas específicas da imagem é a que mais se compatibiliza com a área em foco.

A segmentação de imagens médicas desempenha um papel crucial na deteção de várias doenças e tumores. Duas das técnicas de imagiologia médica mais utilizadas são o ultrassom e a tomografia computadorizada (TC). Tradicionalmente, a delineação de estruturas patológicas a partir de imagens médicas tem sido efetuada manualmente. No entanto, este procedimento é extremamente demorado e requer conhecimentos clínicos adequados para obter resultados com de interesse clínico. Recentemente, as técnicas de *deep learning* têm sido bem sucedidas

numa vasta gama de aplicações de *Computer Vision*, como o reconhecimento de objetos e a segmentação semântica, definida como a classificação das características das imagens com base nos pixels. Além disso, estas técnicas, em particular a segmentação semântica, têm sido aplicadas com êxito no domínio das imagens médicas. Os métodos atuais de segmentação de imagens médicas utilizam principalmente Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Networks*), devido à sua rápida velocidade de inferência e à sua representação forte de características. As operações convolucionais extraem características locais de uma imagem através da extração de características de pixels vizinhos. Para tal, desenvolveu-se uma variedade de modelos de segmentação baseados em CNN, como as redes totalmente convolucionais, UNet, UNet 3+ e DeepLab, entre outros [30], [31].

A UNet é uma das técnicas mais antigas e utilizadas na segmentação de imagens médicas, desenvolvida por Olaf Ronneberger, Philipp Fischer e Thomas Brox, com base numa arquitetura de codificador-descodificador (*encoder-decoder*), neste caso, em forma de “U”. Este modelo pode ser bem treinado com menos amostras e, apesar do pequeno conjunto de dados de treino, fornece uma segmentação precisa [30], [31]. A UNet 3+ é uma nova arquitetura em forma de U projetada para explorar totalmente recursos multiescala, para melhorar a segmentação de imagens médicas. Ao contrário da UNet padrão, que emprega conexões de salto (*skip connections*) e liga diretamente as camadas correspondentes do codificador e do decodificador, o UNet 3+ redesenha essas conexões para incorporar caminhos de salto (*skip pathways*) em escala total. Isto envolve a integração de detalhes de baixo nível com semântica de alto nível em várias escalas de mapas de recursos, obtidas por meio de conexões de salto em escala total e supervisão profunda, permitindo uma segmentação mais precisa e consciente dos limites [32].

A Figura 5 a) representa uma arquitetura do modelo UNet e a Figura 5 b) representa uma arquitetura do modelo UNet 3+.

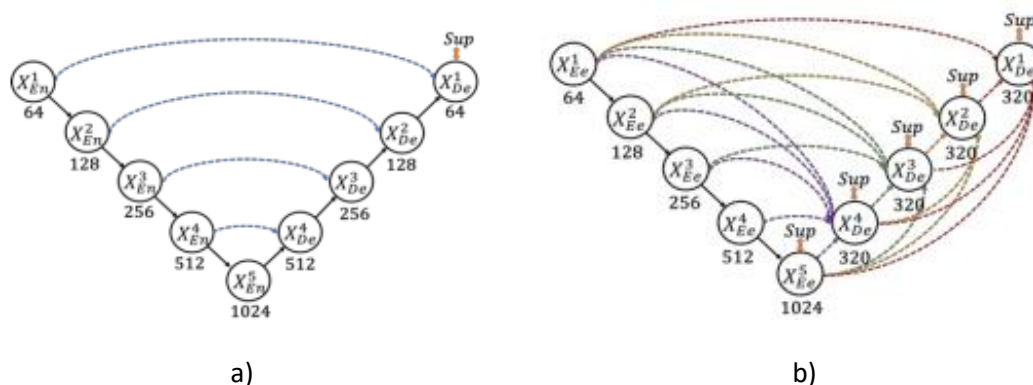


Figura 5 – Comparação de arquiteturas dos modelos: a) UNet; b) UNet 3+ [32]

2.3 Robôs colaborativos e *end-effectors*

A interação humano-robô (do inglês, *Human Robot Interaction* ou HRI) explora as melhorias na cooperação entre humanos e máquinas. Tradicionalmente, tem sido aplicada a robôs de serviço, mas atualmente está a tornar-se um pilar fundamental da Indústria 4.0. No passado recente, o conceito de robô industrial era um braço robótico numa linha de montagem, interagindo com

outras máquinas e longe dos humanos. O paradigma tem vindo a mudar e já existem muitos robôs projetados para trabalhar em conjunto com humanos e a tendência atual dos fabricantes de braços robóticos, é que os robôs possam trabalhar em conjunto com humanos para realizar tarefas em conjunto, conhecidos como robôs colaborativos ou *cobots* [33]. Por exemplo, uma das fabricantes conhecidas de *cobots* é a *Universal Robots* (UR), que oferecem os modelos UR3, UR5, UR10 e outra série de robôs colaborativos. O robô UR3 pode transportar cargas úteis de até 3 kg e foi concebido para tarefas mais leves em comparação com outras versões dos robôs da série UR, sendo utilizado para a montagem de peças eletrônicas leves na indústria. O robô UR5 pode transportar cargas úteis de até 5 kg e é adequado para aplicações de peso médio. É empregue em aplicações industriais, como montagem de peças de peso médio e aplicações de manutenção de máquinas. Outra versão do robô da série UR, o UR10 tem uma capacidade de carga útil de 10 kg e foi desenvolvido para realizar aplicações relativamente pesadas. O robô UR 10 tem uma repetibilidade mais alta e é empregue com configurações de segurança para evitar colisões com operadores humanos [34].

As tarefas de colaboração e cooperação com operadores humanos são consideradas como diferentes tipos de interações. Embora os termos sejam frequentemente usados de forma permutável na investigação em HRI, é importante enfatizar que eles têm significados conceituais diferentes. Ambas as tarefas envolvem interação e um objetivo comum, no entanto, elas diferem na natureza das interações durante a tarefa. Quando robôs e operadores humanos trabalham juntos durante tarefas cooperativas, os operadores humanos e os robôs concentram-se em várias subtarefas que, em última análise, produzem o mesmo resultado. Isto significa que o robô e o humano trabalham de forma independente, mas em direção a um objetivo comum. Ao contrário disso, numa tarefa colaborativa, é necessária uma coordenação, pois todas as tarefas são concluídas simultaneamente por um operador humano e um robô. A colaboração é, portanto, uma série de esforços conjuntos direcionados a um objetivo comum, e as ações do robô e do humano são fortemente dependentes. Dessa forma, os robôs colaborativos formam um subconjunto de um grupo maior de robôs cooperativos [34].

Nos últimos anos, os *end-effector* têm assumido um papel cada vez mais importante na investigação científica e em aplicações de engenharia, abrangendo setores como a indústria militar, processos de soldadura, em aplicações médicas, entre outras áreas. O *end-effector* de um robô corresponde ao elemento operacional na extremidade da sua cadeia cinemática, sendo o componente que entra em contacto com o ambiente para executar tarefas como agarrar ou processar objetos. Habitualmente, é acoplado mecanicamente após o pulso do robô e pode ser uma ferramenta de manipulação, como uma garra, ou simplesmente uma ferramenta de processamento. Adicionalmente, pode servir como uma ferramenta de inspeção, por exemplo, um sensor ou uma câmara [35], [36].

3 Revisão Bibliográfica

3.1 Métodos manuais de diagnóstico da neuropatia diabética/pé diabético

3.1.1 Testes de toque

3.1.1.1 Teste com monofilamento Semmes-Weinstein de 10 gf

No teste com monofilamento Semmes-Weinstein (SW) de 10 gf é utilizado um fio de *nylon*, calibrado e não invasivo, de baixo custo, simples e preciso, que se dobra depois de aplicada uma força de 10 gf. Estes monofilamentos são calibrados para produzir uma tensão de curvatura consistente e para minimizar a vibração da mão do médico enquanto está a ser aplicado. O teste fornece uma medida padrão da capacidade de um paciente para sentir um ponto de pressão e avaliar a sensibilidade do mesmo a um toque ligeiro [37], [38]. De forma a realizar o teste, o examinador deve aplicar perpendicularmente o monofilamento na superfície da pele, com força suficiente para dobrar ou entortar e este processo completo deve durar, aproximadamente, dois segundos. No entanto, se existirem úlceras, calos, cicatrizes ou tecidos necróticos, não se aplica o monofilamento diretamente nas lesões [39]. Os pontos de contacto estão representados na Figura 6 a) e a técnica de utilização do monofilamento está representada na Figura 6 b).




Figura 6 – a) Pontos principais na avaliação da sensibilidade com o monofilamento SW (planta e dorso do pé) [40]; b) técnica de uso do monofilamento no teste referido [39]

O examinador deve perguntar ao doente se sente a pressão aplicada (reposta de “sim” ou “não”) e, de seguida, onde sente a pressão. O processo é repetido duas vezes no mesmo local, com alternância com pelo menos uma aplicação “simulada”, em que não existe toque (totalizando três perguntas por local) e, por último, como avaliação final, existe sensação protetora se o paciente responder corretamente a duas de três aplicações e ausente se houver duas em três respostas erradas [39]. Se um indivíduo só consegue perceber filamentos mais grossos, que requerem mais força para se dobrarem, tem uma maior deficiência sensorial do que alguém que consegue detetar monofilamentos mais finos [41].

Alguns estudos avaliaram o teste do monofilamento como um caminho válido no diagnóstico da NPSD e pé diabético, apresentando uma elevada especificidade e sensibilidade [42], [43], [44]. No entanto, existem algumas limitações no uso destes monofilamentos, como fatores que interferem no seu funcionamento ou a insuficiência de se realizar diagnósticos apenas com o monofilamento.

Segundo Haloua et al. [45], existem alguns fatores que influenciam as propriedades físicas dos filamentos, como a força de curvatura. A humidade e temperatura nos ambientes onde se realizam os testes, afetam os filamentos, o que pode provocar erros nos diagnósticos e, conseqüentemente, tratamentos errados [45]. De acordo com o estudo realizado por Dube et. al [37], a utilização solitária do monofilamento SW não é o ideal, defendendo a utilização de outro método de diagnóstico, para que, em conjunto, a sensibilidade e especificidade do teste sejam melhoradas [37]. Seguindo a mesma ideia, Raymond et. al [46], combinaram o teste de monofilamento 5,07/10gf com um teste de vibração temporizado de três disponíveis (diapasão tradicional, diapasão eletrônico e *biothesiometer*) e concluíram que, apesar de não haver um processo de diagnóstico ideal, a combinação de várias ferramentas é a melhor abordagem. Entre os três testes de vibração, o diapasão eletrônico revelou-se o melhor [46].

3.1.1.2 Teste de toque Ipswich

O teste de toque Ipswich tem como objetivo a percepção tátil, através de toques leves com a ponta do dedo indicador do examinador, nas pontas do primeiro, terceiro e quinto dedos de ambos os pés (6 locais) durante 1-2 s, na seguinte sequência: primeiro dedo do pé direito, quinto dedo do pé direito, primeiro dedo do pé esquerdo, quinto dedo do pé esquerdo, terceiro dedo do pé direito e terceiro dedo do pé esquerdo [47]. Requer uma formação mínima, para que qualquer profissional de saúde e pessoas autorizadas possam realizá-lo sem esforço, com custos baixos e ferramentas simples [48].

Khumchum et al. [47] apresentaram uma comparação entre o teste de Ipswich e o teste com o monofilamento SW (método de referência). No estudo de Khumchum et al., o teste de Ipswich mostrou sensibilidade de 70,8% e especificidade de 98,6% quando comparado com a referência, constituindo uma alternativa válida, se os monofilamentos não estiverem disponíveis para uso. No entanto, os autores referem que, devido à baixa sensibilidade que apresentou, deve ser utilizado com cuidado [47]. Dutra et al. [49] também realizaram um estudo comparativo entre os dois testes, onde o teste de Ipswich apresentou uma sensibilidade de 83,33% e especificidade de 97,66%, demonstrando, uma vez mais, a utilidade do teste de Ipswich. Em contraste, a sensibilidade neste caso foi significativamente maior [49].

3.1.2 Testes de vibração

Os testes de vibração envolvem a avaliação da raiz nervosa posterior da coluna vertebral, que é responsável tanto pela propriocepção como pela vibração. A propriocepção consiste no sentido da posição e movimento dos membros e do corpo na ausência de visão. A mesma inclui dois componentes, o sentido da posição estacionária dos membros (sentido da posição dos membros) e o sentido do movimento dos membros (cinestesia). O tornozelo e a falange distal do hálux são os dois locais onde os testes de vibração são normalmente efetuados [50], [51]. A ausência de vibração no hálux está fortemente associada a um risco elevado de aparecimento de úlceras no pé [52].

De forma a efetuar os testes de vibração, o examinador pode utilizar um diapasão, *biothesiometer* /*neurothesiometer* e o VibraTip™.

3.1.2.1 Diapasão

Um podologista testa, normalmente, o limiar de percepção vibratório (VPT, do inglês *Vibration Perception Threshold*) com um diapasão. Os diapasões estão amplamente disponíveis no mercado e são uma forma simples de avaliar a sensação vibratória. Para testar, ativam o diapasão e aplicam-no na ponta distal do dedo grande do pé (hálux). Uma resposta anormal é interpretada se o doente deixar de sentir a vibração antes do examinador, que continua a sentir a vibração enquanto segura no diapasão [53].

No estudo de Ghosh et al. [54], foram realizados testes com diapasões de 128 Hz, 256 Hz e 512 Hz, para medir o limiar de percepção de vibração em pacientes com diabetes e compará-los com indivíduos saudáveis, escolhidos ao acaso. Os testes de vibração foram realizados nos membros superiores e inferiores. Os autores verificaram que havia uma diferença altamente significativa ($P < 0,0001$) nos limiares de percepção de vibração entre os casos diabéticos e os controlos saudáveis, o que indica que os pacientes diabéticos apresentam uma sensibilidade reduzida aos estímulos vibratórios. A correlação entre a sensibilidade e a vibração e os níveis de açúcar no sangue foi registada, com um coeficiente de correlação de Pearson (r) de cerca de -0.5, indicando uma correlação negativa parcial, onde à medida que os níveis de açúcar no sangue aumentam, a sensibilidade à vibração tende a diminuir. Por último, os diapasões de 128 Hz e 256 Hz foram particularmente eficazes ao avaliar a sensibilidade perceptiva nos doentes diabéticos [54].

Yoshikawa et al. [55] utilizaram um diapasão de 128 Hz, ligeiramente modificado, com o objetivo de determinar a utilidade deste instrumento na previsão de desenvolvimento de calosidades e úlceras nos membros inferiores. No total, examinaram-se 108 indivíduos (56 saudáveis e 52 com NPSD) para avaliar a presença/ausência de calosidades, amplitude de movimento da dorsiflexão do tornozelo, sensibilidade vibratória e sensibilidade ao toque. Os autores mostraram que uma deficiência na sensação vibratória era um indicador mais forte da formação de calos do que outros fatores, como a duração da diabetes ou o índice de massa corporal. Além disso, a sensibilidade vibratória na primeira falange distal foi considerada um forte indicador de úlceras, sobrepondo-se à presença de calosidades e outros fatores. Os testes no mesmo local apresentaram uma maior sensibilidade e especificidade para detetar a formação de calos em comparação com o teste no maléolo medial, o que está de acordo com a teoria de que a NPSD tende a afetar de forma mais severa os locais distais [55].

Chattopadhyay et al. [56] realizaram um estudo que incidiu sobre a eficácia da utilização de um diapasão de 128 Hz como alternativa prática ao *biothesiometer* para o rastreio de neuropatia periférica diabética em doentes com diabetes num hospital no leste da Índia. Com uma amostra de 149 pacientes, a investigação encontrou uma correlação estatisticamente significativa entre o teste do diapasão e o limiar de percepção de vibrações medido pelo *biothesiometer*. Especificamente, um tempo de corte do diapasão de 4,8 segundos demonstrou uma sensibilidade de 76% e uma especificidade de 77% para o diagnóstico de neuropatia ligeira, enquanto a ausência de sensação do diapasão demonstrou uma sensibilidade de 70% e uma especificidade de 90% para a deteção de neuropatia grave. Estes resultados sugerem que o diapasão, sendo mais acessível e mais simples de utilizar, pode servir como uma ferramenta de rastreio fiável e eficiente da NPSD, em contextos clínicos em que os recursos podem ser

limitados, reforçando a necessidade da sua implementação nos cuidados de rotina dos diabéticos para melhorar o diagnóstico precoce e a gestão desta complicação comum [56].

3.1.2.2 *Biothesiometer/Neurothesiometer*

O *biothesiometer*, também conhecido como *neurothesiometer*, é um dispositivo portátil utilizado para fornecer uma avaliação semiquantitativa do limiar de percepção vibratório. À semelhança do diapasão, o teste é feito no hálux. A ponta do dispositivo é posicionada na superfície superior do dedo grande do pé, com a sonda equilibrada verticalmente na falange do dedo, onde a intensidade é aumentada até o doente sentir a vibração. O valor obtido é designado por VPT. Este procedimento deve ser realizado, primeiro, numa área próxima e, posteriormente, regista-se a média de três medições para cada dedo grande do pé. Um valor de VPT > 25 V (volts) é considerado anormal, valores entre 16 e 24 V indicam risco intermédio e valores < 15 V indicam baixo risco. A vantagem deste dispositivo em relação ao diapasão é que os resultados não são binários (normal/anormal) e podem ser quantificados [57].

Dash e Thakur [58] mediram o limiar de percepção de vibração com um *biothesiometer* - a sonda vibrou com amplitude proporcional ao quadrado da tensão - aplicado perpendicularmente no local do teste com uma pressão constante, em 60 doentes diabéticos, metade com NPSD e metade sem NPSD. Entre os doentes com NPSD, 70,1% tiveram teste positivo, mas 30,0% não apresentaram alterações, possivelmente devido à subjetividade do método de diagnóstico. Mesmo sem sintomas, 50,0% dos indivíduos sem NPSD, tinham neuropatia Grau I, o que indica que a NPSD pode ser subclínica e silenciosa, aumentando o risco de úlceras e amputações. O processo de diagnóstico demonstrou boa correlação com outros testes e apresentou sensibilidade de 83% para prever úlceras num período de quatro anos [58].

3.1.2.3 *VibraTip™*

O *VibraTip™* (Figura 7) é um dispositivo semelhante a um pequeno porta-chaves que proporciona uma vibração quase silenciosa, com amplitude e frequência semelhantes às de um diapasão calibrado de 128 Hz, concebido para detetar NPSD em doentes com diabetes tipo 1 e tipo 2, como parte de uma revisão pelo *Medical Technologies Advisory Committee* (MTAC) do *National Institute for Health and Care Excellence* (NICE) [59].

Tentolouris et al. [60] examinaram o desempenho do *VibraTip™* para o diagnóstico de perda de sensibilidade protetora em comparação com o monofilamento SW de 10 gf, considerado o método de referência neste estudo. A investigação envolveu a avaliação de 100 doentes e incluiu contribuições de um diabetologista consultor, de um enfermeiro especialista em diabetes e de um podologista. Os resultados demonstraram que o *VibraTip™* apresentou uma boa sensibilidade e especificidade para o diagnóstico de perda de sensibilidade protetora. A concordância entre os profissionais de saúde que realizaram os testes foi satisfatória, indicando a fiabilidade dos resultados. Os autores concluíram que esta ferramenta pode servir como uma ferramenta de rastreio eficaz na gestão da diabetes, embora seja necessária mais investigação para confirmar a sua eficácia em contextos clínicos mais alargados e o seu potencial para reduzir as complicações do pé diabético [60].



Figura 7 – VibraTip™ [61]

3.1.3 Termografia

A termografia por infravermelhos é um procedimento seguro, repetível e não invasivo que mede e mapeia a distribuição da temperatura que é irradiada das superfícies do corpo. Uma câmara de infravermelhos identifica e monitoriza a quantidade de radiação emitida e traduz este valor numa temperatura. Estas projeções permitem a identificação do calor que o corpo irradia e produzem imagens com padrões térmicos fisiológicos específicos, que podem ser recolhidos de acordo com normas específicas, permitindo que a qualidade desta técnica aumente no futuro. A variação da temperatura dos pés em doentes com neuropatia é um elemento preditivo do aparecimento de úlceras, pelo que a termografia de infravermelhos, devido às suas características e facilidade de utilização, é uma boa ferramenta para detetar esta diferença de temperatura [62]. Câmaras térmicas e RGB de baixo custo, disponíveis no mercado, foram integradas em vários protótipos concebidos para a monitorização remota de neuropatias do pé diabético, a fim de detetar padrões de temperatura anormais nos pés do indivíduo, que são um indicador precoce da formação de uma úlcera [63].

No estudo realizado por González et al. [64], a termografia por infravermelhos foi utilizada como uma técnica não invasiva para monitorizar a temperatura do pé em doentes diabéticos, apresentando várias vantagens e desvantagens. Como vantagem, permitiu a aquisição rápida de dados em várias regiões do pé, facilitando a deteção de anomalias na temperatura que poderiam indicar problemas subjacentes, como inflamação ou isquemia, promovendo assim uma intervenção precoce [64].

A investigação de Kumar et al. [65] incidiu sobre a recolha e seleção de estudos sobre a aplicação de imagiologia térmica com infravermelhos em ortopedia. Com esta análise identificaram vantagens e desvantagens associadas. Esta tecnologia facilita a monitorização em tempo real das respostas ao tratamento, ajudando na avaliação de condições como infeções periprotésicas e complicações do pé diabético, melhorando assim os resultados dos doentes e reduzindo a necessidade de procedimentos invasivos. No entanto, o estudo também aponta desvantagens, como a influência de fatores ambientais, o que pode afetar a sua precisão e fiabilidade. Além disso, embora possa identificar áreas localizadas de hiperemia, carece de especificidade, o que torna difícil determinar a causa exata das alterações de temperatura detetadas. A necessidade de pessoas treinadas para interpretar as imagens térmicas acrescenta outra camada de complexidade, uma vez que os utilizadores não treinados podem interpretar

mal os resultados. Adicionalmente, as condições subjacentes, como a neuropatia, podem confundir os resultados, limitando a eficácia da termografia em determinadas populações de doentes. Por conseguinte, continua a ser essencial utilizá-la juntamente com outras modalidades de diagnóstico para uma avaliação abrangente do doente [65].

3.2 Métodos automatizados de diagnóstico da neuropatia diabética/pé diabético

3.2.1 Machine Learning/Deep Learning

Para além do uso da termografia, González et al. [64] integraram uma tecnologia móvel (desenvolvimento de uma meia), potenciando a monitorização remota da saúde, permitindo que os doentes recebessem alertas instantâneos. No entanto, o método não está isento de dificuldades; as leituras de temperatura podem ser influenciadas pelas condições ambientais, o que leva à variabilidade dos resultados e o facto de o estudo se centrar em avaliações a curto prazo, pode não refletir eficazmente as condições dos doentes a longo prazo [64].

O estudo conduzido por Khosa et al. [66] incidiu no reconhecimento automático de úlceras do pé diabético, utilizando dados de reconhecimento automático, uma questão crítica para indivíduos com diabetes *mellitus*. Os autores utilizaram termogramas disponíveis, publicamente, de doentes diabéticos e de um grupo de controlo, para detetar alterações na temperatura plantar associadas a úlceras. Ao explorar vários níveis de dados de termogramas - ao nível da imagem, ao nível de *patch* e uma combinação de ambos - os autores utilizaram várias técnicas de *machine learning* e de *deep learning*. Entre os modelos pré-treinados analisados, a ResNet50 e a DenseNet121 foram as técnicas proeminentes, juntamente com uma rede neuronal convolucional personalizada (CNN, do inglês *Convolutional Neural Networks*) desenvolvida especificamente para esta tarefa. O modelo demonstrou um desempenho superior na classificação de úlceras em comparação com os modelos ResNet50 e DenseNet121 pré-treinados. Atingiu uma sensibilidade elevada de 0,970 e uma especificidade de 0,958 ao nível da imagem, com uma exatidão de 97,1%. Ao nível do *patch*, manteve resultados sólidos com uma sensibilidade de 0,839, uma especificidade de 0,889 e uma exatidão de 93%, bem como uma pontuação F1 global de 0,891, consistente em todos os níveis. Em contrapartida, o ResNet50 e o DenseNet121 apresentaram sensibilidades mais baixas (por exemplo, ResNet50: 0,565 ao nível do *patch*), especificidades (ResNet50: 0,913 ao nível do *patch*) e exatidões (ResNet50: 83,2% e DenseNet121: 79,1% ao nível da mancha). A investigação realçou o papel da imagem termográfica combinada com metodologias computacionais avançadas para facilitar a deteção precoce e melhorar potencialmente os resultados dos pacientes em risco de desenvolver úlceras [66].

O artigo de autoria de Thotad et al. [67] apresenta uma nova abordagem para a deteção precoce de úlceras do pé diabético, utilizando o modelo de *deep learning* EfficientNet, num *dataset* de 844 imagens de pés, que inclui pés saudáveis e com úlceras. O modelo treinado utilizou uma divisão do *dataset* em 60% para treino, 20% para validação e 20% para teste. Ao equilibrar eficazmente a largura e profundidade da rede, assim como a resolução da imagem, o modelo EfficientNet superou significativamente os modelos tradicionais, como AlexNet, GoogleNet, VGG16 e VGG19, alcançando valores positivos: 98,97% de exatidão, 99,00% de precisão, 98,00% de recordação e 98,00% de pontuação F1. O desempenho apresentado não só validou a eficácia

do modelo EfficientNet na classificação de imagens de pés normais ou com úlceras, como também reflete a sua capacidade de aplicação prática em contextos de cuidados de saúde [67].

Goyal et al. [68] apresentaram uma abordagem inovadora para a detecção e localização em tempo real de úlceras do pé diabético utilizando *deep learning* em dispositivos móveis. O estudo enfatiza o desenvolvimento de um modelo robusto, utilizando um *dataset* de 1775 imagens de úlceras do pé diabético, validadas por profissionais médicos. Ao implementar o modelo Faster R-CNN com InceptionV2 e utilizar o *transfer learning* de duas camadas, os autores alcançaram uma precisão média de 91.8% e uma velocidade de inferência de 48 milissegundos, juntamente com um tamanho do modelo de apenas 57,2 *megabytes*. O desempenho do modelo foi avaliado tanto numa placa de desenvolvimento “NVIDIA Jetson TX2”, como num protótipo de uma aplicação Android, demonstrando a sua utilidade em cenários do mundo real. Testes preliminares na aplicação revelaram a capacidade de detectar com precisão a maioria das úlceras sem falsos positivos, destacando o potencial de tais sistemas para auxiliar no diagnóstico e monitorização de úlceras em contextos de cuidados de saúde remotos. Por último, é sugerido que podem ser feitas outras melhorias através da expansão do conjunto de dados e da incorporação de características de diagnóstico adicionais para melhorar a experiência do utilizador e a eficácia em contextos clínicos [68].

Costa et al. [69] desenvolveram um sistema automatizado para identificar os locais de teste do exame do monofilamento SW em imagens da planta do pé, para ajudar na gestão do pé diabético. Os autores criaram um novo *dataset* de fotografias da planta do pé de alta resolução (cerca de 90 imagens de 15 indivíduos – 9 mulheres e 6 homens), tiradas em condições de iluminação e posicionamento não controladas para imitar os ambientes clínicos do mundo real, onde os nove pontos do teste de sensibilidade, representados na Figura 3a), foram desenhados nas imagens. O *pipeline* incidiu sobre *Computer Vision*, que combina processamento de imagem e *deep learning* (binarização, transformação de distâncias e outras técnicas comuns de processamento de imagens) para segmentar o pé e isolar nove locais de teste específicos (áreas do hálux, dedos dos pés, planta do pé e calcanhar). O sistema identificou corretamente pelo menos 7 dos 9 locais de teste em mais de 86,0% das imagens, e quatro locais foram corretamente localizados em mais de 98,3% dos casos. A iluminação irregular, o alinhamento do pé e a interferência de marcadores foram os desafios identificados [69]. A Tabela 1 apresenta um resumo dos pontos mais importantes a retirar dos quatro estudos analisados.

Tabela 1 – Resumo dos estudos analisados relativos ao *machine learning*

Referência	Modelo utilizado	Tamanho do <i>dataset</i>	Desempenho
[66]	ResNet50, DenseNet21 e CNN	334 imagens	Sensibilidade: 0,970 Exatidão: 0,971
[67]	EfficientNet	844 imagens	Exatidão: 0,9897 Precisão: 0,9900
[68]	Faster R-CNN com InceptionV2	1775 imagens	Precisão: 0,918
[69]	UNet	90 imagens	-

3.2.2 Wearables

Moulaei et al. [70] desenvolveram palmilhas com vários sensores integrados (Figura 8 a)), de forma a medir três parâmetros: pressão, temperatura e humidade, a partir dos pés de doentes com diabetes, de forma a controlar o desenvolvimento de NPSD e aparecimento de úlceras. De forma a construir o protótipo, utilizaram um microcontrolador Arduino, sensores de força/pressão, sensores de temperatura e humidade, baterias, um módulo HC-05 (conexão por *Bluetooth*), um conversor, um módulo integrado LM324 DI e resistências. Além disso, o sistema está conectado com uma aplicação móvel (Figura 8 b)), o que permite que os pacientes recebam alertas quando um dos parâmetros apresenta valores anormais, contribuindo, assim, para uma manutenção proativa. Os sensores do dispositivo foram avaliados quanto à sua precisão em relação aos padrões estabelecidos, através de testes que envolveram indivíduos diabéticos e saudáveis. Os resultados revelaram uma sensibilidade elevada (100%) e precisão (92,5%) dos sensores de pressão em comparação com o sistema “Pedar”, enquanto os sensores de temperatura e humidade também demonstraram um desempenho fiável. No entanto, o estudo tem limitações, como a pequena dimensão da amostra, que pode afetar a generalização dos resultados. Além disso, o custo do equipamento e avaliação restringiu o número de participantes, salientando a necessidade de mais investigação com coortes maiores para avaliar melhor a utilidade do projeto e o seu impacto nos resultados dos doentes e nos comportamentos de monitorização própria em diversas populações [70].

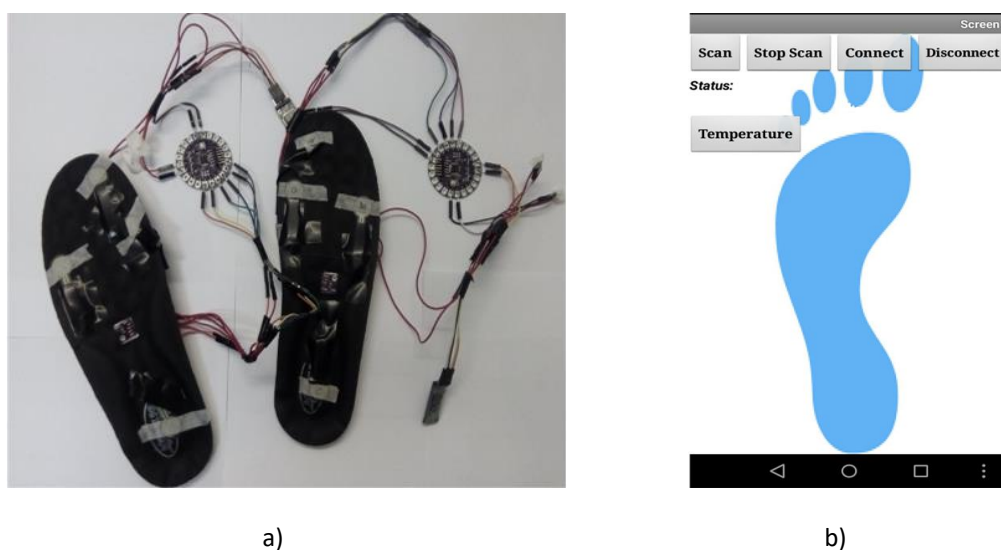


Figura 8 – a) Protótipo da palmilha e localização dos sensores; b) Aplicação móvel [70]

Chatwin et al. [71] investigaram a eficácia de um sistema inteligente de palmilhas sensíveis à pressão, na redução da pressão plantar em pacientes com alto risco de úlceras do pé diabético. A pressão da planta do pé foi medida através de 8 sensores, com uma taxa de amostragem de 8 Hz. Num ensaio aleatório controlado que envolveu 46 pacientes com NPSD e histórico de úlceras, todos os participantes foram divididos num grupo de intervenção (GI), que recebeu *feedback* contínuo através das palmilhas e um grupo de controlo (GC), que não recebeu qualquer *feedback*. Ao longo do período de estudo de 18 meses, o GI teve significativamente menos episódios de pressão alta em comparação com o GC, demonstrando uma resposta de aprendizagem em que os doentes começaram a evitar atividades que desencadeavam alertas de pressão alta. Esta redução nos episódios de pressão elevada sugeriu que o *feedback* contínuo

e personalizado do sistema de palmilhas inteligentes pode ser uma estratégia eficaz para prevenir o aparecimento de úlceras em indivíduos de alto risco, ilustrando uma aplicação prática da tecnologia na gestão das complicações do pé relacionadas com a diabetes [71].

3.2.3 Robótica e protótipos

Wilasrusmee et al. [72] descrevem o desenvolvimento e validação de um “Inspetor de Monofilamentos Robótico (IMR)”, que se trata de um novo dispositivo concebido para melhorar o processo de diagnóstico da NPSD (Figura 9). O protótipo é constituído por três componentes principais: *software* informático, uma caixa de controlo (ARM7) e o mecanismo robótico. O *software* gere todas as funções, permitindo aos profissionais de saúde introduzir os dados demográficos dos doentes e os resultados dos testes. A caixa de controlo, equipada com um microcontrolador ARM7, atua como intermediário, processando os comandos do programa e transmitindo-os ao dispositivo robótico de teste, enquanto trata das respostas do doente durante o teste. O mecanismo robótico está programado para aplicar o monofilamento em locais específicos do pé do paciente com força e duração consistentes. O IMR procura resolver as limitações do teste tradicional do monofilamento, que depende frequentemente da administração manual e pode introduzir variabilidade relativa aos examinadores, que pode comprometer a precisão do diagnóstico. O estudo incluiu 71 participantes, 40 dos quais foram diagnosticados com diabetes e 31 eram controlos saudáveis e teve como objetivo comparar a eficácia do IMR com testes estabelecidos, como o teste com o monofilamento SW e o VPT. Os resultados indicaram que o IMR obteve uma excelente concordância com o teste com o monofilamento e o VPT, demonstrando fiabilidade. De forma notável, o teste robótico também revelou uma maior prevalência de neuropatia entre os doentes diabéticos com úlceras nos pés, sugerindo uma potencial superioridade em relação aos métodos de teste manuais tradicionais. O estudo conclui que o IMR pode ser uma ferramenta eficaz, reproduzível e de fácil utilização para uso clínico de rotina, melhorando significativamente a deteção precoce e a gestão da neuropatia diabética e reduzindo assim o risco de complicações graves associadas à doença [72].




Figura 9 – Componentes principais do IMR [72]

Choi e Ahn [73] desenvolveram um sistema de monitorização inovador (Figura 10 a)), concebido para medir os módulos elásticos do tecido plantar em doentes diabéticos, com o objetivo principal de detetar precocemente úlceras nos pés. Desta forma, criaram um sistema portátil que integra vários componentes, incluindo uma sonda, um sensor de força, um atuador linear, um microcontrolador, um módulo de visualização, uma bateria e uma caixa. Esta conceção dá prioridade à facilidade de utilização e acessibilidade, permitindo aos doentes efetuar a automonitorização do estado do seu pé de forma conveniente. A eficácia do sistema

foi validada através de uma série de testes efetuados em fantasmas de tecido de silicone, seguidas de testes no tecido plantar de seres humanos, que visaram, especificamente, zonas do pé propensas a úlceras, nomeadamente a cabeça do metatarso e o calcâneo (Figura 10 b)). Os resultados indicaram que o sistema estimou consistentemente os módulos elásticos, com valores de 108.4 kPa para uma profundidade de palpação de 3 mm e 108.9 kPa para uma profundidade de 5 mm. Estes resultados sublinham a capacidade do sistema de monitorização em fornecer medições objetivas e quantificáveis, que são fundamentais para avaliar as alterações nas propriedades do tecido plantar, que podem indicar o início ou a progressão de úlceras. Além disso, o estudo abre terreno para futuros esforços de investigação, que visam a colaboração com instituições de cuidados de saúde, centrando-se na medição dos módulos elásticos em doentes diabéticos e na monitorização das alterações do seu estado ao longo do tempo. Esta abordagem tem o potencial de melhorar os cuidados prestados aos doentes e de melhorar os resultados através de intervenções atempadas [73].



Figura 10 – a) Protótipo do sistema de monitorização; b) Aplicação do protótipo no teste [73]

Castellano et al. [74] realizaram um estudo comparativo entre dois métodos: o teste tradicional do monofilamento SW e um novo protótipo automático (Figura 11). A ferramenta automatizada consiste num sistema mecânico com um monofilamento 10 gf montado, controlado por um motor de passo e um microcontrolador Arduino. Inclui um transdutor de força que mede e garante aplicação precisa da força, um mecanismo que estabiliza, proporcionando movimentos precisos e um sistema de controlo que permite testes automatizados e padronizados da sensibilidade do pé em diferentes locais. O sistema também é capaz de tornar aleatório os locais de teste e avaliar falsos positivos, aumentando a sua fiabilidade e padronização em relação aos métodos manuais tradicionais. O objetivo do estudo incidiu sobre a capacidade que o protótipo em oferecer medições precisas e com padrão. Os participantes foram divididos em três grupos: controlo saudáveis, pacientes com DMT2 com neuropatia e pacientes com DMT2 sem neuropatia. O teste de sensibilidade envolveu a aplicação manual do monofilamento em 26 locais em cada pé e o uso do protótipo para medir os limiares de sensibilidade nos mesmos locais. Os resultados mostraram que a ferramenta automatizada identificou que 21-24% dos locais considerados sensíveis pelo monofilamento eram insensíveis, indicando um possível subdiagnóstico com o método tradicional. Nos controlo saudáveis, os limiares de sensibilidade correlacionaram-se significativamente com a idade, mas não foi encontrada tal relação com outros parâmetros médicos, como índice de massa corporal ou níveis de glicemia. O dispositivo também apresentou uma taxa aproximada de falsos positivos de 11%, influenciada por erros

do dispositivo e do procedimento. Em suma, o estudo sugere que a ferramenta automatizada poderá melhorar a precisão e a consistência da avaliação da NPSD, reduzindo a dependência de métodos com a precisão do operador [74].




Figura 11 – Protótipo automatizado desenvolvido por Castellano et al. [74]

4 Metodologia

Através da análise da literatura e dos estudos referidos apresentados no capítulo “Revisão Bibliográfica”, verifica-se que existem algumas abordagens de diagnóstico da neuropatia e pé diabético. No entanto, no campo das técnicas automatizadas, existe possibilidade de inovação e combinação de alguns métodos num só projeto. Então, a metodologia apresentada neste capítulo, dissecar todos os pontos abordados e processos realizados, com o objetivo de construir o protótipo para o diagnóstico desta condição.

O primeiro subcapítulo apresenta todos os métodos relativos à segmentação de imagens de pés com os pontos de teste de sensibilidade com o monofilamento SW, seguido do subcapítulo relativo ao desenvolvimento do *end-effector*, finalizando com os métodos para controlo do robô.

4.1 Segmentação de imagens de pés com marcações dos pontos de teste do monofilamento SW

O primeiro passo consistiu na segmentação e previsão dos pontos do teste de sensibilidade com o monofilamento SW, a partir de imagens de pés. A abordagem seguiu a linha de trabalho de Costa et al. [69], que passou pelo uso de algoritmos de *machine learning* para segmentação, como a UNet, que foi também utilizada neste trabalho. Para além disso, explorou-se a UNet 3+, que está descrita no artigo de Huang et al. [32], onde os mesmos apresentam os fundamentos da arquitetura, as inovações introduzidas, as inovações introduzidas relativamente à UNet original e os testes que realizaram. O código está disponível para utilização em [75]. Para construir, treinar e testar o modelo, foram utilizadas as bibliotecas *Keras* e *Tensorflow*, que proporcionam um ambiente flexível, eficiente e fácil de utilizar para conceber, treinar e implementar modelos de *deep learning*. O *TensorFlow* oferece capacidades computacionais otimizadas, permitindo o tratamento eficiente de dados em grande escala e arquiteturas de rede complexas, enquanto o *Keras* funciona como uma API (do inglês, *Application Programme Interface*) de alto nível que simplifica a construção de modelos. O uso de ambas facilita o desenvolvimento mais rápido, personalização mais fácil e a implementação eficaz da rede proposta com suporte para aceleração do GPU (do inglês, *Graphics Processing Unit*), o que é essencial para treinar modelos em *datasets* de imagens médicas [32].

4.1.1 Datasets

Neste trabalho foram utilizados dois *datasets*, sendo um deles proveniente do trabalho desenvolvido por Costa et al. [69] e é constituído por duas pastas: uma contendo 46 fotografias de pés humanos com um fundo preto, de forma a isolar os pés de cada um dos participantes e outra com as respetivas 46 máscaras da segmentação dos pontos de interesse, embora apenas os dedos dos pés tenham sido marcados. As fotografias apresentam dimensões de 512x512 píxéis, no formato “.jpg” e as máscaras apresentam as mesmas dimensões no formato “.gif”. A Figura 12 a) e mostra um exemplo de uma fotografia e a Figura 12 b) um exemplo da respetiva

máscara da segmentação dos pontos. Para efeitos de escrita, será referenciado como “*dataset 1*”.




Figura 12 – Imagens constituintes do *dataset 1*: a) fotografia dos pés com fundo preto; b) máscara com a segmentação dos pontos de teste nos dedos dos dois pés

O segundo *dataset* tem a mesma estrutura do anterior, mas neste caso as imagens dos pés foram criadas por Inteligência Artificial (IA), totalizando 103 imagens de IA e 103 máscaras de segmentação. As dimensões das imagens dos pés são 1024x1024, no formato “.jpg” e as máscaras têm as mesmas dimensões, porém no formato “.png”. A Figura 13 a) e mostra um exemplo de uma fotografia e a Figura 13 b) um exemplo da respectiva máscara da segmentação dos pontos. Para efeitos de escrita, o mesmo será referenciado como “*dataset 2*”.



Figura 13 – Imagens constituintes do *dataset 2*: a) imagem dos pés criada por IA; b) máscara com a segmentação dos pontos de teste completo nos dois pés

4.1.2 Arquitetura geral

A Figura 14 apresenta a arquitetura geral ou *pipeline* que descreve esquematicamente todo o processo desde a recolha das imagens de pés até à previsão da segmentação do modelo.

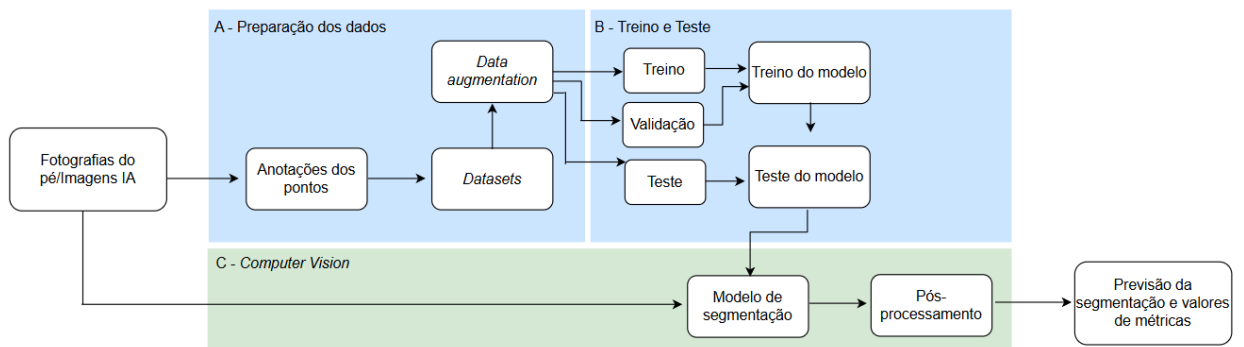


Figura 14 – Arquitetura geral da utilização da UNet e UNet 3+

O bloco A apresenta as etapas da preparação de dados, começando pelas anotações dos pontos nas imagens de pés, que vão constituir os *datasets*. Posteriormente, as imagens passam por um conjunto de técnicas, denominado *data augmentation* que são divididas em novas subpastas de treino e teste, que vão ser utilizadas para o treino e teste do modelo, respetivamente. O bloco B começa com o treino do modelo, onde o conjunto de dados foi dividido em três subconjuntos independentes: conjunto de treino (64%), utilizado para o ajuste e treino do modelo; conjunto de validação (20%), que acompanha o desempenho do treino e, por fim, conjunto de teste (16%), reservado para a avaliação final do treino. De seguida, ocorre o teste do modelo, utilizando o ficheiro ".h5" gerado no treino e onde todas as imagens foram normalizadas e processadas. Para cada imagem, é gerada uma previsão da segmentação, guardada posteriormente numa representação comparativa, constituída pela imagem do pé, máscara de referência e previsão. Adicionalmente, a análise quantitativa incluiu métricas como accuracy (exatidão), F1-Score, índice de Jaccard (IoU), recall e precision (precisão). Estes resultados são exportados para um ficheiro ".csv" para serem interpretados.

4.1.3 Treinos dos algoritmos UNet e UNet 3+

No primeiro treino, o *dataset 1* foi utilizado para o treino da UNet, sem qualquer alteração nas imagens ou no seu número. Para comparação, criou-se um *dataset* proveniente do anterior, onde as todas imagens foram redimensionadas para 384x384 pixéis e utilizadas no treino da UNet 3+. Por fim, treinou-se a UNet 3+ com um conjunto de dados proveniente do *dataset 2*, no qual as imagens foram redimensionadas para 384x384 pixéis e o seu número ligeiramente reduzido. O objetivo passou por perceber o funcionamento e desempenho dos algoritmos de *machine learning* na segmentação destas imagens, comparando os resultados visuais e de métricas. Para treinar os algoritmos, recorreu-se ao *Visual Studio Code* e ao *Google Colab*.

4.2 Sistema *End-Effector* para avaliação plantar

4.2.1 Componentes

O principal objetivo passa por avaliar a condição do pé diabético e, para tal, é fundamental medir sensibilidade e pressão sentida pelos pacientes, através do sistema *end-effector*, que é constituído por uma célula de carga de 2 kg (ver Anexo A), que está conectada a um conversor A/D (analógico para digital) de 24 bits, com duas entradas de canal analógico, com um amplificador embutido e ganho programável (Figura 15 b)), denominado HX711 (ver Anexo B), que fará a ponte de ligação entre a célula e o Arduino UNO (Figura 15 a)). Este último foi uma ferramenta amplamente utilizada durante a licenciatura e o mestrado em Engenharia Biomédica.

Um transdutor de força é um tipo de sensor utilizado para converter uma carga ou força numa alteração de tensão, onde a sua alteração depende da pressão gerada pela carga. Esta contém um extensómetro, um componente eletrónico que mede a pressão e é configurado como um circuito de ponte de *Wheatstone*, consiste em quatro resistências ligadas em série e em paralelo. O extensómetro tem a forma de uma folha metálica ou de um fio metálico isolante (isolamento) ligado ao sensor da célula de carga que pode medir a pressão resultante da carga. Os sensores de célula de carga são feitos de vários materiais, como alumínio e aço inoxidável [76].

O Arduino é uma plataforma de computação física de código aberto baseada numa placa microcontroladora simples e num ambiente de desenvolvimento que implementa a linguagem “*Processing*”, Arduino IDE, que foi originalmente concebida para que qualquer pessoa criasse protótipos eletrónicos [77].




Figura 15 – Sistema *end-effector*: a) Arduino UNO e respetiva *datasheet*; b) célula de carga e respetivo amplificador HX711 [78]

Então, de forma a usar o transdutor de força, procedeu-se à montagem do circuito da Figura 16, onde se ligou a célula de carga ao amplificador HX711, que, posteriormente, é ligado ao microcontrolador.




Figura 16 – Esquema de montagem do sistema

As ligações entre o transdutor de força e o módulo HX711 são as seguintes: fio vermelho – pino “E+”; fio preto – pino “E-”; fio branco – pino “A-” e o fio verde conecta a “A+”, podendo estes dois permutar entre si. Posteriormente, o pino VCC e GND do módulo conecta aos 5 V e GND do Arduino, respetivamente. Os pinos DT e SCK podem ser ligados a qualquer um dos 14 pinos de *input/output* digitais do Arduino UNO.

Para medir a pressão efetuada, o transdutor possui um mecanismo específico, representado na Figura 17. O elemento sensor ou mola é o principal componente estrutural da mesma. Este é concebido de forma a desenvolver uma deformação, diretamente proporcional à carga aplicada, onde uma força molecular atua entre as moléculas que constituem o objeto, gerando uma força interna que tenta evitar a deformação. Quando a força externa é equilibrada com a força interna do objeto, a deformação do objeto cessa. Neste momento, a força interna por unidade de área que é gerada na secção transversal do objeto é designada por “tensão” e a alteração das dimensões por unidade das dimensões originais é designada por “deformação”. O extensómetro utiliza o princípio da alteração da resistência de muitos metais quando estes são alongados ou contraídos. Uma vez que a resistência depende da resistividade, do comprimento e da área da secção transversal do material e quanto mais comprido for o fio metálico, maior será a resistência [79].




Figura 17 – Princípio de funcionamento do transdutor de força [79]

Outro parâmetro a ser recolhido é a temperatura do pé do paciente, pelo que, utilizou-se como sensor de temperatura, o MLX90614.

O termómetro infravermelho MLX90614, presente na Figura 18, é um sensor de temperatura sem contacto compatível com o Arduino, fabricado pela “JOY-IT/SIMAC Electronics GmbH” (ver Anexo C). Este tipo de sensor mede a temperatura ambiente e de um objeto, neste último através da radiação infravermelha, na forma de uma onda eletromagnética através da luz emitida num objeto [80]. O sensor comunica por I²C (do inglês, *Inter-Integrated Circuit*), pelo que, de forma a comunicar com o microcontrolador, é necessário, para além das ligações básicas de alimentação do sensor (o pino VCC liga aos 3,3 V ou 5 V e GND ao pino GND) ligar os pinos SDA e SCL do sensor aos pinos SDA e SCL do Arduino (pinos analógicos A4 e A5, respetivamente) [81].



Figura 18 - Termómetro infravermelho [82]

4.2.2 Desenvolvimento do protótipo e programa

Neste trabalho, é necessário medir a força exercida pelo robô, até que o monofilamento dobre e a temperatura do pé do paciente. Portanto, é necessário criar uma plataforma estável para que seja possível medir corretamente os parâmetros pretendidos, assim como desenvolver um código para o Arduino que permita calibrar e registar os valores da força que o transdutor regista, através da deformação e da temperatura medida pelo sensor.

O código foi desenvolvido no Arduino IDE (ver Anexo D), um ambiente de programação para o Arduino e outros microcontroladores. Neste caso, foi necessário instalar uma biblioteca relativa ao módulo HX711. O programa permite a calibração do transdutor de força e regista as medições de força e temperatura nos pontos do teste com o monofilamento SW e foi estruturado da seguinte forma:

- Inicialização das bibliotecas, variáveis de calibração e estrutura de dados;
- Calibração do sistema: tara e cálculo do fator de escala a partir de um peso de referência conhecido;
- Execução dos testes: teste de um só ponto e teste completo com os 9 pontos (dados da força e temperatura recolhidos);
- Gestão dos resultados: apresentação em formato de tabela e possibilidade de armazenamento na EEPROM.

Na fase de inicialização, importaram-se as bibliotecas necessárias ao desenvolvimento do programa: “HX711.h”, “EEPROM.h”, “Wire.h” e “Adafruit_MLX90614.h” definindo os pinos de ligação ao HX711 (DT e SCK) e as posições de memória onde seriam gravados os parâmetros de calibração. Além disso, foi criada uma estrutura “Point” para registar, em cada ponto de teste, a força máxima, a força média, duração da aplicação e a validade do processo de contacto.

Para calibrar o transdutor, a base deve estar totalmente apoiada numa superfície plana, para que haja estabilidade e, na extremidade oposta, a presença de uma plataforma, atendendo ao mecanismo demonstrado na Figura 17. A montagem utilizada para efetuar a calibração do sistema é apresentada na Figura 19. Sempre que o utilizador calibra o sistema, é necessário remover qualquer peso na plataforma superior, para que depois seja aplicada uma tara e, seguidamente, inserir o valor de um peso de referência conhecido. A partir das leituras obtidas, calcula-se o fator de conversão entre unidades digitais e gramas, gravando este valor e o *offset* na EEPROM para evitar a repetição deste processo, sempre que o programa é utilizado de novo. Neste caso, o valor utilizado para a calibração foi 840g, correspondente a uma lata com feijão e líquido.





Figura 19 – Montagem para efetuar a calibração do transdutor de força

Com o sistema calibrado, procedeu-se à execução da experiência. O programa aguarda até que a força aplicada ultrapasse um limiar mínimo de 0,300g, de forma a verificar que existe contacto com o transdutor. No entanto, é apenas um limite físico de deteção, não a unidade final de medição.

O teste completo engloba todos os 9 pontos (os locais exatos são mostrados no monitor) e, no final, os resultados das medições são agrupados numa tabela, onde aparece uma coluna com a força registada, tempo de medição – igual para todos – e validação do ponto. Aquando da realização do teste, é possível o registo de valores da força negativos por parte do transdutor, devido ao modo diferencial do amplificador HX711, pelo que os valores da força registados pelo transdutor e apresentados no monitor estão sempre em módulo.

No primeiro teste aplicou-se uma força ligeira com o dedo, com o propósito de verificar o funcionamento do sistema e, assim, continuar o procedimento. Com o funcionamento do transdutor assegurado, o objetivo seguinte passou para a implementação de um suporte para o filamento, assim como assegurar funcionamento do sensor MLX90614. A Figura 20 a) mostra

o suporte para o filamento, a Figura 20 b) o filamento posicionado e a Figura 20 c) o sensor de temperatura MLX90614.



a)

b)

c)

Figura 20 – Componentes: a) Suporte para o filamento; b) filamento posicionado; c) termómetro infravermelho MLX90614

O suporte foi concebido em *nylon* (baseado no protótipo apresentado por Castellano et al. [74]), com o objetivo de oferecer mais estabilidade ao filamento, incluindo a possibilidade de trocá-lo assim que necessário, com o auxílio de uma ferramenta. A base retangular apresenta dimensões de 8.4 x 3.3 x 1.5 cm (comprimento x largura x altura). A estrutura vertical possui dimensões de 1.5 x 3.0 x 4.5 cm, incorporando um corte com 1.5 x 2.0 x 3.7 cm. No topo da estrutura, existe uma abertura circular com 0.2 cm de diâmetro. Para fixar o filamento, existe um botão colado na base do suporte, que apresenta as medidas exatas para que o filamento esteja fixado (0.4 cm de diâmetro), evitando, assim, movimentos indesejados. As ligações do sensor MLX90614 foram feitas utilizando uma *breadboard*. De seguida, efetuaram-se novos testes, desta forma com a recolha dos dados do transdutor e do sensor de temperatura, em simultâneo. A Figura 21 apresenta o sistema *end-effector* completo.



Figura 21 – Sistema *end-effector* completo

4.2.3 Estudo da influência da aplicação de tara no registo de força pelo transdutor

A exposição a contextos reais é fundamental para validar o funcionamento de um equipamento. De tal forma, realizaram-se medições em superfícies com diferentes propriedades, como pés de três voluntários saudáveis, neste caso, um indivíduo do sexo masculino e dois indivíduos do sexo feminino, com idades distintas. Para efeitos de comparação, um conjunto de medições foi efetuada sem tara do sistema antes de medir e outro, onde antes de cada sessão, procedeu-se à tara do sistema e à higienização da ponta do filamento que toca nas superfícies. Os testes realizados em humanos foram consentidos e sempre que houve algum problema, como desconforto da pessoa ou problemas nas medições, o teste foi interrompido. Em cada teste, o operador segurou o sistema perpendicularmente à superfície e ao ponto de teste, da forma mais rigorosa possível. Aquando do contacto, aguardou-se cerca de 1 a 2 segundos, questionando o indivíduo se sentiu o toque. Repetiu-se o processo para os 9 pontos, continuamente, até totalizar 3 testes completos, com intervalo entre cada um. O sensor de temperatura está posicionado o mais próximo possível do pé, idealmente numa posição mais elevada, de forma a registar a temperatura do pé da melhor forma possível. A Figura 22 apresenta o método de medição com este procedimento.





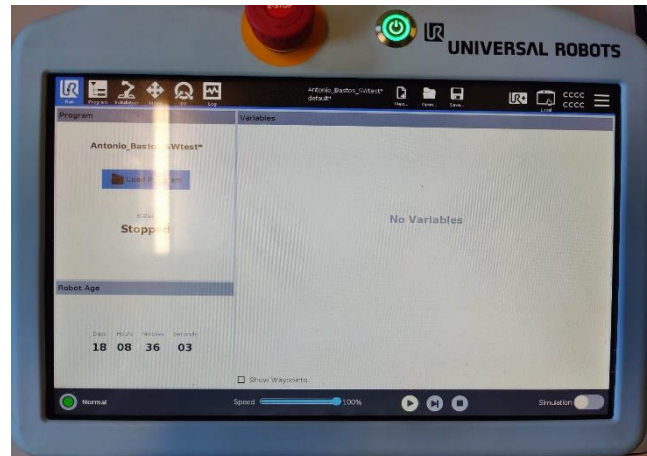
Figura 22 - Aplicação do *end-effector* por parte de um operador, perpendicularmente ao pé do voluntário

4.3 Robô UR3e e acoplamento do *end-effector*

Neste trabalho, o robô colaborativo utilizado foi o UR3e fabricado pela *Universal Robots* (ver Anexo C), presente na Figura 23 a), que possui um painel uma interface de *software*, o *Polyscope*, que permite controlar as ações do robô, representado na Figura 23 b) e o controlo local e remoto do mesmo.



a)

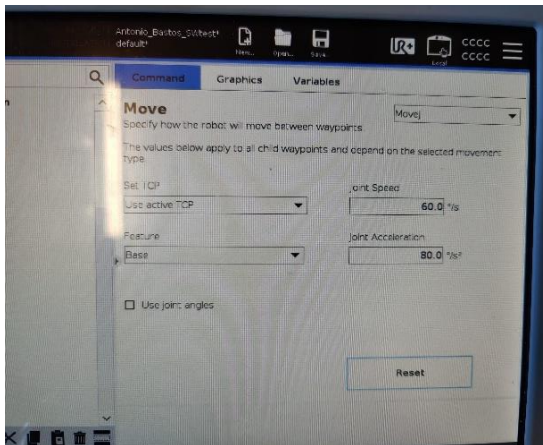


b)

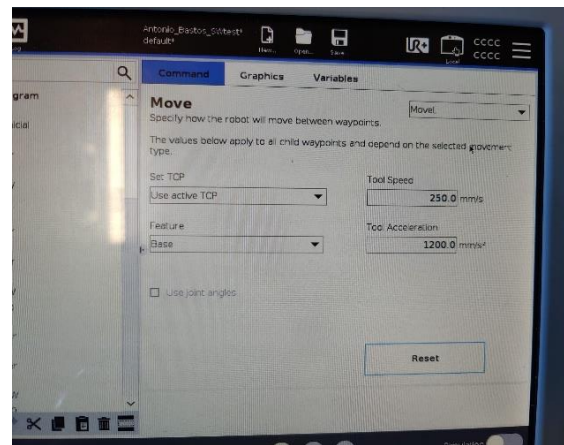
Figura 23 – Robô UR3: a) robô; b) *Polyscope* (painel interativo do robô)

Em primeiro lugar, desenvolveu-se um programa utilizando o *Polyscope*, visando simular um teste com o monofilamento SW, sendo o robô o operador do mesmo. Para tal, existem os 9 pontos do teste (pontos de contacto), já abordados, um ponto de aproximação da ferramenta (que após o contacto retorna a essa mesma posição) e um ponto inicial. De forma a mover o robô para cada um desses pontos, existe a possibilidade de escolher entre 3 “Moves”, onde, neste caso, dois foram utilizados: “MoveJ” e “MoveL”, movimento da articulação e movimento linear, respetivamente. O primeiro faz com que as articulações do robô operem independentemente para alcançar uma posição da forma mais rápida e eficiente possível e o segundo, desloca o *end-effector* em linha reta desde a posição inicial até ao alvo, executando tarefas com precisão alta, simplificando-as, como por exemplo, soldagens.

No programa desenvolvido, “MoveJ” foi usado para alcançar todos os pontos exceto os de contacto, onde foram aplicados “MoveL”, pois permite maior controlo sobre a velocidade e aceleração do movimento, tendo em conta a procura de uma aproximação segura e controlada do *end-effector* ao paciente, algo fundamental neste processo. A Figura 24 a) apresenta as opções do “MoveJ” e a Figura 24 b) é relativa ao “MoveL”. Em ambas é possível conhecer os parâmetros que o utilizador pode definir de acordo com o seu propósito, como velocidade e aceleração angulares da articulação no “MoveP” (em $^{\circ}/s$, graus por segundo; $^{\circ}/s^2$, graus por segundo ao quadrado, respetivamente) e velocidade e aceleração da ferramenta no “MoveL” (em mm/s, milímetros por segundo; mm/s^2 , milímetros por segundo ao quadrado, respetivamente). No programa desenvolvido, as variáveis do movimento de articulação não foram alteradas (valores presentes na respetiva imagem) e no movimento linear definiu-se a velocidade em 10 mm/s e a aceleração em $50 mm/s^2$. Estes valores foram definidos por segurança na operação da máquina, no entanto, sujeitos a ajustes para refinar o processo.



a)



b)

Figura 24 - Definições de dois dos movimentos do robô utilizados no programa: a) "MoveJ"; b) "MoveL"

Após a definição do movimento pretendido, é necessário a definição do alvo ou *waypoint*. O TCP (do inglês, *Tool Center Point*), é o ponto específico no *end-effector* (ferramenta), pelo que os *waypoints* são definidos com o TCP devidamente calibrado, com a opção "Base" a ser selecionada em "Feature". Para definir as coordenadas (em mm, milímetros) de cada um dos pontos, utilizaram-se os comandos de direções do *Polyscope* (lado esquerdo da interface na Figura 25), que controlam o movimento das articulações, a orientação e posição do TCP em radianos, como demonstrado na Figura 26.

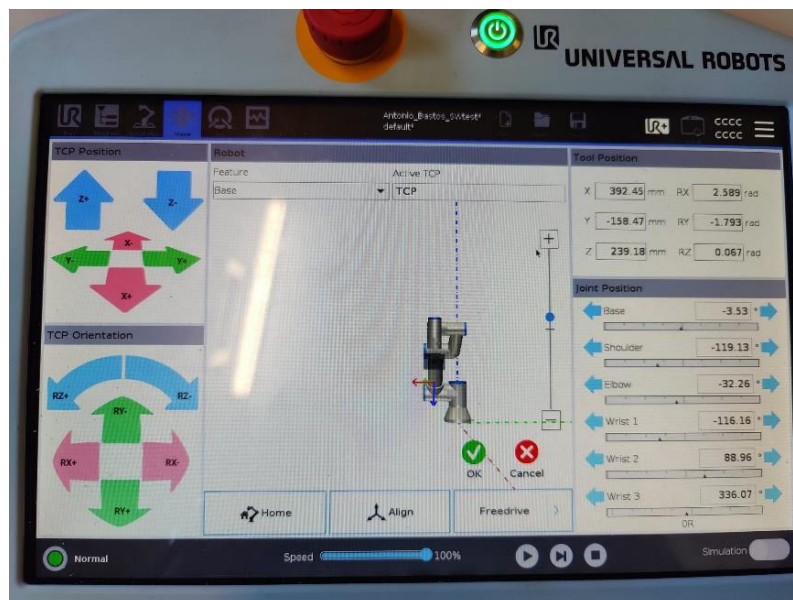


Figura 25 – Painel de controlo da posição, orientação e definição do TCP





Figura 26 – Coordenadas de um ponto, em milímetros e orientação do TCP, em radianos

Os pontos de contacto foram desenhados num molde de um pé e utilizou-se o protótipo do *end-effector* (apenas a parte do transdutor de força, para facilitar a junção ao braço robótico e o movimento do mesmo), com um suporte em alumínio que permite o acoplamento ao braço do robô, para definir a posição da ferramenta no momento de aproximação (designação de PX_apr, com X a ser o número do ponto) e no contacto (designação de PX_SW), de forma que o processo fosse o mais rigoroso possível. Adicionalmente, foram adicionados comandos “Wait”, definidos para 2 segundos, onde o robô permanece em contacto com o molde. A Figura 27 a) apresenta o molde do pé, a Figura 27 b) mostra a junção do *end-effector* com o braço robótico e a Figura 28 demonstra a estrutura do programa, indicado no *Polyscope* como “Robot Program”.



a)



b)

Figura 27 – Objetos para definição dos pontos: a) molde do pé com os pontos de contacto; b) *end-effector* acoplado ao braço robótico




Figura 28 – Estrutura do programa desenvolvido no Polyscope

Posteriormente, desenvolveu-se um programa na linguagem *Python*, com o *Visual Studio Code* como ambiente de desenvolvimento, que seguiu a estrutura do programa anterior. O envio de programas em *URScript* foi realizado através de *sockets*, permitindo a execução de sequências definidas externamente ao *Polyscope*, utilizando a comunicação *TCP/IP* (do inglês, *Transmission Control Protocol/Internet Protocol*). A conexão acontece a partir da ligação de um cabo de rede RJ45 entre o computador e um sistema de controlo externo, apresentado na Figura 29 a), que está conectado à caixa de controlo principal do robô (Figura 29 b)), permitindo a comunicação via *Ethernet*. No computador, definiu-se manualmente o “IPv4 Address” como 169.254.192.100, para comunicar com o robô, cujo IP é 169.254.192.229 e definiu-se a máscara de rede como 255.255.255.0. No programa desenvolvido é necessário indicar o IP do robô através da variável “HOST” e “PORT” que corresponde à porta 30002.



a)



b)

Figura 29 – Controlo do robô: a) sistema de controlo externo conectado à caixa de controlo; b) caixa de controlo do robô

As coordenadas definidas anteriormente foram convertidas para metros, unidades do Sistema Internacional, de modo que sejam compatíveis com os requisitos do URScript, embora a orientação do TCP tenha sido mantida em radianos. O programa seguiu uma estrutura modular, no qual os nove pontos de teste foram armazenados numa lista de coordenadas – aproximação (apr), contacto (sw) e retorno (ret). A partir desta lista, o código em Python gera automaticamente a sequência URScript. Cada ciclo de teste compreendeu: 1º – movimento de aproximação (“movep”), 2º – movimento linear até ao contacto (“move”), 3º – tempo de permanência em contacto (dwell) de 1 ou 2 s e 4º – retorno ao ponto de aproximação (movep). Os parâmetros de velocidade e aceleração foram diferentes para os movimentos de aproximação (0,01 m/s; 0,07 m/s²) e para os movimentos de contacto (0,008 m/s; 0,05 m/s²). Para ser possível a execução do programa, o robô tem de estar no modo remoto, no Polyscope. O código de controlo do robô pode ser consultado no Anexo F.

5 Resultados

Neste capítulo serão apresentados todos os resultados obtidos, consequentes dos processos descritos no capítulo anterior, assim como a discussão de todos os parâmetros necessários. Este capítulo está dividido em três partes, a primeira relativa à segmentação das imagens, seguida dos resultados provenientes do sistema *end-effector*, finalizando com o controlo do robô e acoplamento do *end-effector*.

5.1 Imagens de previsão e métricas de avaliação de desempenho da segmentação de imagens

Após o teste do modelo, foram gerados os resultados, que consistem em imagens contendo, cada uma, uma imagem original do pé (a), respetiva a máscara de segmentação (b) e a previsão de segmentação proveniente do modelo (c). Para efeitos de comparação, as Figuras 30, 31 e 32 apresentam exemplos destes resultados, a primeira proveniente do modelo UNet com o *dataset 1*, a segunda do modelo UNet 3+ com o *dataset 1* alterado e a terceira do modelo UNet 3+ com o *dataset 2*.




Figura 30 – Resultados visuais do treino da UNet com o *dataset 1*: a) imagem original do pé; b) respetiva máscara de segmentação; c) previsão de segmentação do modelo

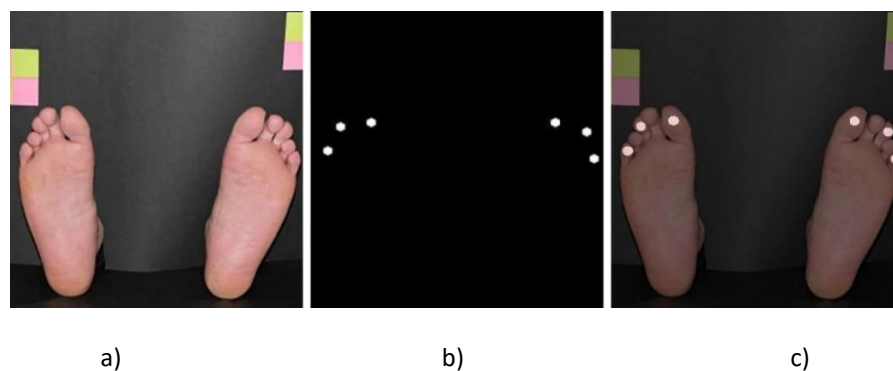


Figura 31 – Resultados visuais do treino da UNet 3+ com o *dataset 1* alterado: a) imagem original do pé; b) respetiva máscara da segmentação; c) previsão de segmentação do modelo

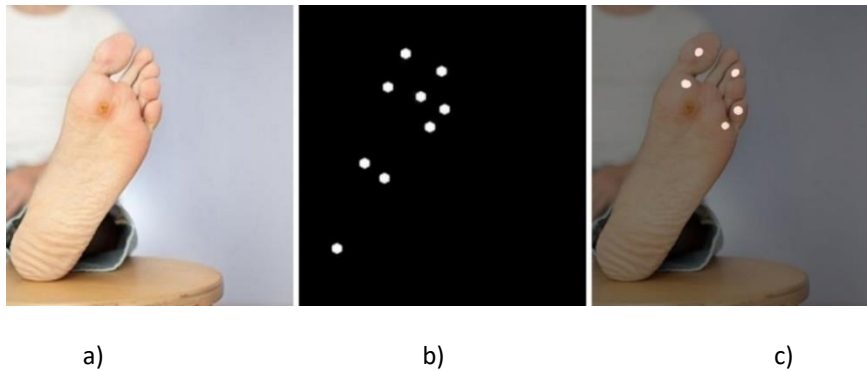


Figura 32 – Resultados visuais do treino da UNet 3+ com o *dataset 2*: a) imagem original do pé; b) respectiva máscara de segmentação; c) previsão de segmentação do modelo

Observando a Figura 30, a previsão de segmentação é muito idêntica à máscara original, apenas com algumas alterações na forma das marcas e tamanho, sendo de destacar a qualidade da imagem apresentada. O mesmo se passa na Figura 31, onde se pode ver semelhanças na máscara e previsão. No entanto, ao percorrer as restantes imagens geradas, as previsões de segmentação por parte do modelo UNet apresentam mais erros, quando comparadas com as previsões do modelo UNet 3+. Tais erros podem incluir ausência de pontos brancos ou presença de mais pontos do que é originalmente suposto. Na Figura 32, são apresentados os resultados visuais do treino da UNet 3+ com o *dataset 2*, com a principal diferença a residir nas máscaras, onde contêm os 9 pontos, ao invés de 3 pontos. No entanto, analisando este exemplo, vemos que a previsão não foi a desejada, devido à ausência de algumas zonas de interesse, com este padrão a repetir-se para as restantes previsões de segmentação.

A Figura 33 apresenta *boxplots* que permite a comparação dos valores das métricas de desempenho entre o treino da UNet com o *dataset 1* e UNet 3+ com o *dataset 1* alterado.

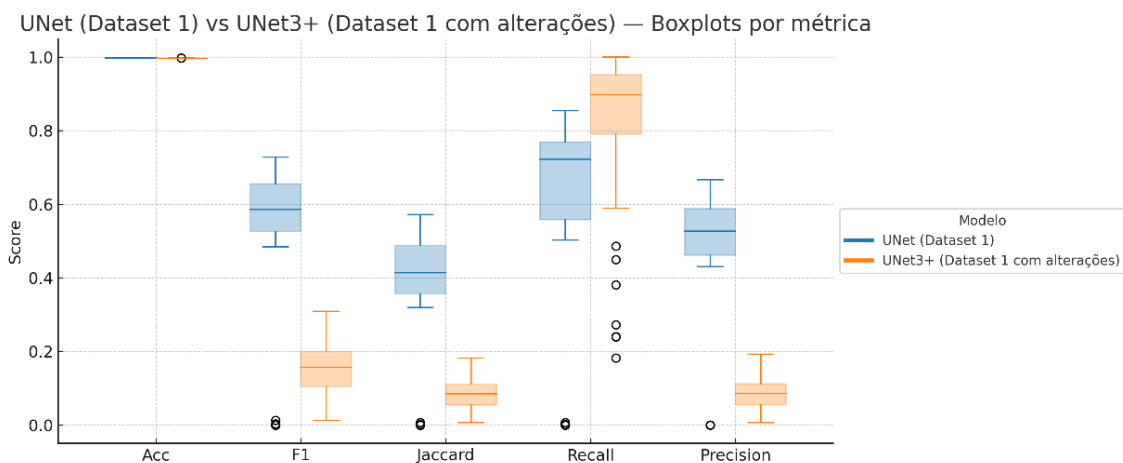


Figura 33 – Comparação de performance da UNet 3+ com o conjunto de teste do *dataset 1* alterado e *dataset 2*: *boxplots* das métricas de avaliação de desempenho

Analisando a Figura 33, observa-se que ambas apresentam valores de *accuracy* muito elevados e semelhantes, próximos de 1,0. No entanto, esta métrica não é muito informativa neste contexto, dado a desproporção entre o fundo e as regiões de interesse (pontos). Ao analisar as

métricas mais discriminativas, como F1-Score e o índice de Jaccard, verifica-se que a UNet alcança valores medianos bastante superiores aos da UNet 3+, evidenciando uma capacidade maior de segmentar as regiões pretendidas. Pelo contrário, a UNet 3+ apresenta um desempenho insuficiente nestas métricas, confirmado por algumas previsões não desejadas nos resultados gerados. No que à métrica *recall* diz respeito, a UNet 3+ apresenta resultados mais elevados, pelo que conseguiu identificar um número maior de regiões positivas. No entanto, este ganho traduz-se numa queda acentuada na métrica *precision*, dado que o modelo gera um número significativo de falsos positivos. A UNet, por sua vez, apresenta uma relação mais equilibrada, com valores de precisão mais elevados e um compromisso aceitável na métrica *recall*.

De um modo geral, a UNet apresenta um desempenho mais consistente e equilibrado, com métricas de sobreposição (F1-Score e Jaccard) superiores e uma melhor relação entre *precision* e *recall*. A UNet 3+, apesar de alcançar maior *recall*, revela-se menos fiável, provavelmente devido à redução nas dimensões das imagens que constituem o *dataset*, o que levou o algoritmo a segmentar excessivamente, caracterizada pela deteção de muitas regiões irrelevantes.

A Figura 34 apresenta *boxplots* que permitem a comparação dos valores das métricas de desempenho no treino da UNet 3+ com o *dataset 1* alterado e o *dataset 2*. Os *boxplots* azuis correspondem ao *dataset 1* alterado e os *boxplots* laranja ao *dataset 2*.

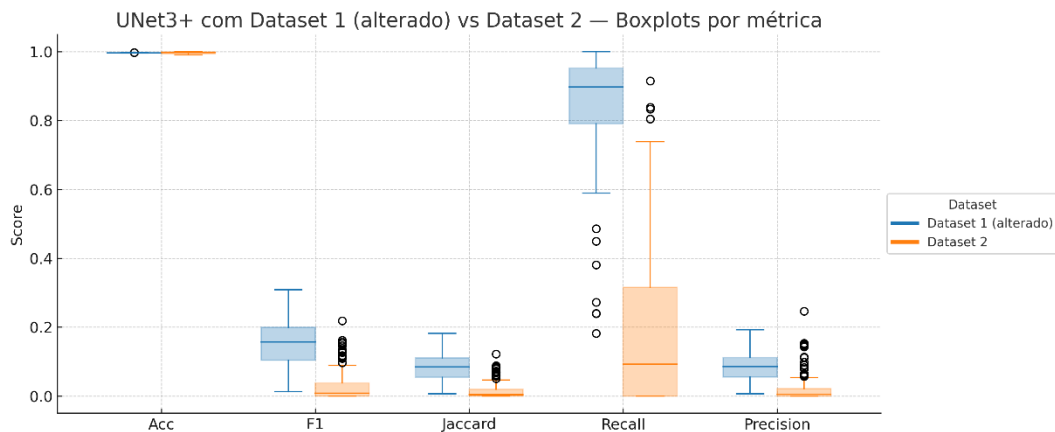


Figura 34 – Comparação da performance da UNet 3+ com o conjunto de teste do *dataset 1* alterado e *dataset 2*: *boxplots* das métricas de avaliação de desempenho

Analisando a Figura 34, a *accuracy* mantém-se elevada em ambos os casos, contudo, esta métrica não é importante numa tarefa desequilibrada como a segmentação, onde a maioria dos pixels corresponde ao fundo da imagem. O F1-Score e o índice de Jaccard, mais discriminativos, revelam diferenças: a UNet 3+ apresenta valores muito superiores relativamente ao *dataset 1*, enquanto no *dataset 2* os resultados são muito baixos e dispersos, o que indica uma sobreposição fraca entre as máscaras de referência e previsão.

O *recall* confirma esta tendência, sendo bastante elevado no *dataset 1* alterado, o que demonstra boa capacidade em identificar regiões positivas. Já com o *dataset 2*, apesar de alguns valores dispersos aceitáveis, a mediana é muito inferior, traduzindo-se em falhas frequentes na deteção correta das áreas de interesse. Na *precision*, o padrão repete-se: valores mais

consistentes com o primeiro *dataset* e um desempenho muito pobre no segundo, com elevada proporção de falsos positivos.

Esta comparação evidencia a forte dependência, neste contexto, de características ideais nos *datasets* de treino, visto que, no *dataset 2*, as máscaras de segmentação possuem 9 pontos ao invés de 3 pontos, o que aumenta a proporção de pixels positivos relativamente ao fundo, apresentando valores de *recall*, embora haja aumento dos falsos positivos, o que reduz a *precision* e diminua os valores de métricas como as mais equilibradas como o F1-Score e Jaccard. As imagens pós-*data augmentation* possivelmente influenciaram, devido a transformações menos corretas das imagens, o que pode levar à distorção da geometria dos pontos anotados.

Num contexto geral, conclui-se que a UNet demonstrou ser mais fiável e robusta no contexto do presente estudo, enquanto a UNet 3+ evidenciou maior sensibilidade à variação dos dados de treino. No entanto, é necessário efetuar outras análises, nomeadamente do desempenho da UNet 3+ utilizando outros *datasets*, como o *dataset 1* original, por exemplo.

5.2 Sistema *End-Effector*

O programa desenvolvido permite a interação através de uma série de comandos enviados via monitor. A série de comandos do Arduino estão agrupados numa lista, como demonstra a Figura 35. Para selecionar um comando, basta introduzir o número que se pretende e o comando é executado. O comando 1 permite a calibração do transdutor, com um peso conhecido, o comando 2 inicia as medições da força, temperatura ambiente e do pé do paciente. Estes resultados podem ser consultados no comando 3, na mesma janela de atividade, guardados na EEPROM selecionando o comando 4 e consultados com o comando 5 assim que se volta a utilizar o programa. Adicionalmente, é possível apagar os resultados guardados, com a opção 6 e, por último, o comando 7 executa a tara do sistema.

```
--- LISTA DE COMANDOS ---  
1-Calibrar o transdutor  
2-Teste SW  
3-Resultados  
4-Guardar resultados  
5-Carregar resultados  
6-Apagar resultados  
7-Tarar
```

Figura 35 – Lista de comandos do programa

O sensor MLX90614 mede a temperatura do pé do paciente, com consistência, a pouco mais de 5 cm (centímetros) de distância do mesmo. Estas medições não são as mais rigorosas, visto que o sensor de temperatura está muito em baixo, incidindo apenas na zona do calcanhar, pelo que, para melhores resultados, é necessário elevar a posição do mesmo, de modo a cobrir maior área da planta do pé. Adicionalmente, é fundamental assegurar o bom estado do monofilamento, pois qualquer danificação na estrutura do mesmo, como resultado de medições sucessivas, pode ser passível de deformações permanentes, colocando em causa o desempenho do sistema, como documentado na dissertação de [83].

A Figura 36 a) apresenta um teste completo com a medição da força, temperatura do pé e ambiente e a Figura 36 b) apresenta os resultados das medições numa tabela.

```

--- TESTE 9 PONTOS ---

>>> 1.Hálux - Aplique força
Força aos 2s: 0.621 N
Temp. objeto: 28.77 °C
Temp. ambiente: 26.57 °C

>>> 2.1*Met - Aplique força
Força aos 2s: -0.121 N
Temp. objeto: 28.69 °C
Temp. ambiente: 26.55 °C

>>> 3.3*Met - Aplique força
Força aos 2s: 0.121 N
Temp. objeto: 28.69 °C
Temp. ambiente: 26.57 °C

>>> 4.5*Met - Aplique força
Força aos 2s: -0.052 N
Temp. objeto: 28.69 °C
Temp. ambiente: 26.53 °C

>>> 5.MeiolLat - Aplique força
Força aos 2s: -0.604 N
Temp. objeto: 28.71 °C
Temp. ambiente: 26.55 °C

>>> 6.MeiolMed - Aplique força
Força aos 2s: 0.362 N
Temp. objeto: 28.69 °C
Temp. ambiente: 26.55 °C

>>> 7.CalcLat - Aplique força
Força aos 2s: -1.501 N
Temp. objeto: 28.99 °C
Temp. ambiente: 26.57 °C

>>> 8.CalcMed - Aplique força
Força aos 2s: 0.207 N
Temp. objeto: 28.85 °C
Temp. ambiente: 26.57 °C

>>> 9.Centro - Aplique força
Força aos 2s: 0.173 N
Temp. objeto: 27.25 °C
Temp. ambiente: 26.57 °C

Teste Concluído

```

a)

b)

```

--- RESULTADOS ---

```

P	F (N)	Obj (°C)	Amb (°C)	Dur	OK
1	0.621	28.77	26.57	2000	Y
2	0.121	28.69	26.55	2000	Y
3	0.121	28.69	26.57	2000	Y
4	0.052	28.69	26.53	2000	Y
5	0.604	28.71	26.55	2000	Y
6	0.362	28.69	26.55	2000	Y
7	1.501	28.99	26.57	2000	Y
8	0.207	28.85	26.57	2000	Y
9	0.173	27.25	26.57	2000	Y

Figura 36 – Teste completo: a) Valores da força, temperatura ambiente e do pé do paciente registadas pelo transdutor de força e sensor de temperatura, respetivamente, nos diferentes pontos; b) apresentação dos resultados agrupados numa tabela

5.2.1 Efeito da tara na recolha de valores de força pelo transdutor

Nesta secção são apresentados todos os valores da força registados pelo transdutor de força, em testes realizados com e sem tara do transdutor, em três voluntários saudáveis: uma mulher de 18 anos, uma mulher de 56 anos e um homem de 56 anos. Para cada participante, são apresentadas duas tabelas com os valores da força, em N, registados em cada um dos 9 pontos, em 3 testes, onde se calculou a média e desvio padrão respetivo a cada ponto. Com os valores das tabelas criou-se gráficos de barras agrupadas, onde as colunas contêm os valores das médias (barras de cor azul correspondem aos testes sem tara e as de cor verde aos testes com tara) e as barras de erro, dizem respeito ao desvio padrão. As Tabelas 2 e 3 apresentam os valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 18 anos, manualmente, sem e com tara antes de cada teste, respetivamente.

Tabela 2 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 18 anos, manualmente e sem tara efetuada antes de cada teste completo

Ponto	Força (N)					Sensação de toque
	1ª	2ª	3ª	Média	D. Pad.	
1	1,070	1,260	1,156	1,162	0,095	S
2	3,348	1,484	1,363	2,065	1,113	S
3	1,881	1,070	1,225	1,392	0,431	S
4	2,071	1,018	1,332	1,474	0,541	S
5	1,501	0,984	0,880	1,122	0,333	S
6	1,173	1,398	1,265	1,279	0,113	S
7	1,329	1,363	1,191	1,294	0,091	S
8	1,760	1,743	1,001	1,501	0,433	S
9	1,087	1,484	1,156	1,242	0,212	S

Tabela 3 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 18 anos, manualmente e com tara efetuada antes de cada teste completo

Ponto	Força (N)					Sensação de toque
	1ª	2ª	3ª	Média	D. Pad.	
1	0,397	0,638	0,311	0,499	0,170	S
2	1,967	0,569	0,311	0,949	0,891	S
3	0,518	0,035	0,828	0,460	0,400	S
4	0,155	0,173	0,414	0,247	0,145	S
5	0,190	0,242	0,362	0,265	0,088	S
6	0,259	0,069	0,535	0,288	0,234	S
7	0,552	0,259	0,535	0,449	0,164	S
8	0,345	0,069	0,656	0,357	0,294	S
9	0,725	0,811	0,846	0,794	0,062	S

O gráfico da Figura 37 permite comparar a força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a uma mulher de 18 anos.

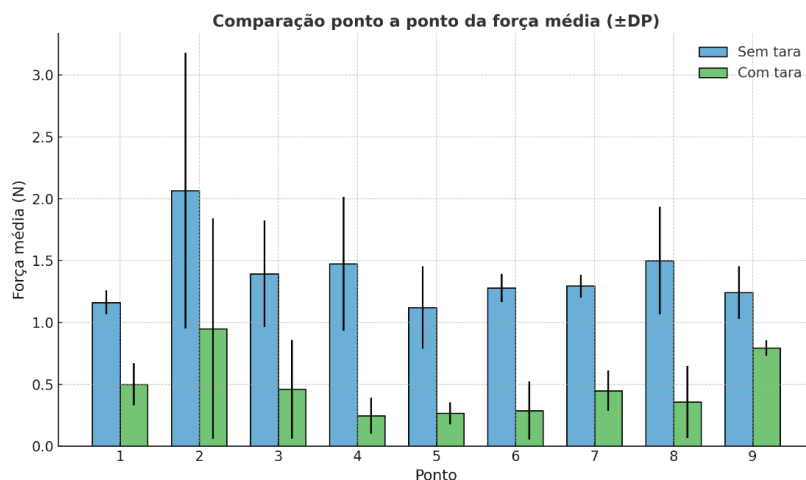


Figura 37 – Comparação da força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a uma mulher de 18 anos

O gráfico mostra que, em todos os pontos avaliados, os valores médios de força registados sem tara são superiores aos obtidos com tara. Esta diferença é mais evidente nos pontos 2, 3 e 4, correspondentes à região metatársica, onde as forças médias sem tara ultrapassam 1 N, atingindo no ponto 2 valores médios acima de 2 N. Pelo contrário, as medições com tara nestes mesmos pontos situam-se consistentemente abaixo de 1 N. Relativamente à variabilidade, observa-se que as barras de erro apresentam maior amplitude nos pontos 2, 3, 4 e 8 nos testes sem tara, indicando maior dispersão entre repetições nestas localizações. Nos pontos do mediopé (5 e 6) e do calcâneo (7), a variabilidade é menos acentuada, embora se repita a tendência do registo forças mais elevadas sem tara, por parte do transdutor. O ponto 9, correspondente à região central do calcanhar, segue o mesmo padrão, com valores mais consistentes quando se aplica a tara antes das medições.

As Tabelas 4 e 5 apresentam os valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 56 anos, manualmente, sem e com tara antes de cada teste, respetivamente.

Tabela 4 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 56 anos, manualmente e sem tara efetuada antes de cada teste completo

Ponto	Força (N)					Sensação de toque
	1ª	2ª	3ª	Média	D. Pad.	
1	1,294	0,949	0,587	0,943	0,354	S
2	1,346	1,726	0,794	1,289	0,469	S
3	1,070	0,742	1,070	0,961	0,189	S
4	0,971	0,863	0,846	0,893	0,068	S
5	1,501	1,191	0,449	1,047	0,541	S
6	1,536	0,846	1,450	1,277	0,376	S
7	1,327	0,880	1,087	1,098	0,224	S
8	1,051	1,329	0,949	1,110	0,197	S
9	1,277	1,191	1,225	1,231	0,043	S

Tabela 5 – Valores da força registados pelo transdutor de força, nos testes realizados a uma mulher de 56 anos, manualmente e com tara efetuada antes de cada teste completo

Ponto	Força (N)					Sensação de toque
	1ª	2ª	3ª	Média	D. Pad.	
1	0,932	0,431	0,518	0,627	0,268	S
2	0,259	1,053	0,173	0,495	0,485	S
3	0,086	0,276	0,052	0,138	0,121	S
4	0,397	1,104	0,535	0,679	0,375	S
5	0,086	0,017	0,328	0,144	0,163	S
6	0,328	0,276	0,466	0,357	0,098	S
7	0,242	0,414	0,138	0,265	0,139	S
8	0,155	0,587	0,431	0,391	0,219	S
9	0,777	0,207	0,552	0,512	0,287	S

O gráfico da Figura 38 permite comparar a força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a uma mulher de 56 anos.

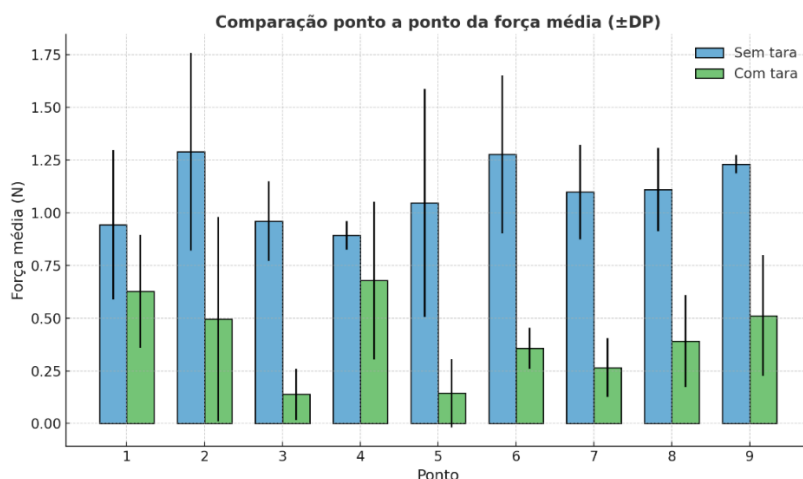


Figura 38 – Comparação da força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a uma mulher de 56 anos

Na Figura 38 observa-se novamente que os valores médios de força obtidos sem tara são consistentemente superiores aos registados com tara, em todos os nove pontos avaliados. Esta discrepância é evidente nos pontos 2, 5, 6 e 9, onde as diferenças entre condições ultrapassam os 0,5 N. No que respeita à variabilidade, as barras de erro revelam maior dispersão nos pontos 2, 5 e 6 no teste sem tara, sugerindo uma aplicação irregular da força nestas localizações. As medições sem tara apresentam desvios padrão mais reduzidos e homogêneos em 50% dos pontos. Em regiões como o ponto 1 e o ponto 4, nota-se que a diferença entre condições é menos marcante, no entanto, a força média sem tara mantém-se acima da obtida com tara. No geral, todos os pontos apresentam a mesma tendência, com valores mais baixos e mais consistentes quando a tara é aplicada.

As Tabelas 6 e 7 apresentam os valores da força registados pelo transdutor de força, nos testes realizados a um homem de 56 anos, manualmente, sem e com tara antes de cada teste, respetivamente.

Tabela 6 – Valores da força registados pelo transdutor de força, nos testes realizados a um homem de 56 anos, manualmente e sem tara efetuada antes de cada teste completo

Ponto	Força (N)					Sensação de toque
	1ª	2ª	3ª	Média	D. Pad.	
1	0,984	1,277	0,863	1,041	0,213	S
2	1,415	1,415	1,363	1,398	0,030	S
3	1,691	1,104	0,949	1,248	0,391	S
4	1,018	1,484	1,208	1,237	0,234	S
5	0,846	0,638	0,828	0,771	0,115	S
6	1,484	1,070	1,450	1,335	0,230	S
7	1,346	1,053	1,018	1,139	0,180	S
8	1,070	0,777	1,311	1,053	0,267	S
9	1,588	1,191	1,500	1,426	0,209	S

Tabela 7 – Valores da força registados pelo transdutor de força, nos testes realizados a um homem de 56 anos, manualmente e com tara efetuada antes de cada teste completo

Ponto	Força (N)					Sensação de toque
	1ª	2ª	3ª	Média	D. Pad.	
1	0,190	0,431	0,621	0,414	0,216	S
2	0,587	0,259	0,828	0,558	0,286	S
3	0,052	0,155	0,380	0,196	0,168	S
4	0,397	0,190	1,242	0,610	0,557	S
5	0,104	0,466	1,260	0,610	0,591	S
6	0,069	0,311	0,483	0,288	0,208	S
7	0,207	0,017	1,053	0,426	0,552	S
8	0,138	0,466	1,501	0,702	0,711	S
9	0,345	0,017	0,863	0,408	0,427	S

O gráfico da Figura 39 permite comparar a força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a um homem de 56 anos.




Figura 39 – Comparação da força média (N) aplicada em cada ponto do pé, com e sem tara, para os testes realizados a um homem de 56 anos

A partir da análise da Figura 39, observa-se que em todos os pontos, a força média medida sem tara é superior à registada com tara, mantendo-se o mesmo padrão observado nos estudos anteriores. Esta diferença é mais vincada nos pontos 2, 3, 4, 6 e 9, onde as forças sem tara atingem valores próximos ou acima de 1,2-1,3 N, enquanto as medições com tara permanecem abaixo de 0,6 N. No que respeita à variabilidade, destacam-se os pontos 2 e 6, com barras de erro mais alargadas na condição sem tara, no entanto, apresentaram desvios padrão mais reduzidos, quando comparados com as medições com tara. Nos pontos 3 e 6, as forças sem tara permanecem moderadas, mas a discrepância em relação às medições com tara é ainda significativa, refletindo o efeito do *offset* do transdutor, quando não é realizada a correção inicial. Nos pontos correspondentes à zona do calcâneo (7 e 8) e do calcanhar (9), a propensão mantém-se: valores mais elevados sem tara e medições mais consistentes com tara efetuada.

Comparando os resultados dos três indivíduos, as medições sem tara apresentaram valores médios de força superiores às medições com tara nos nove pontos avaliados, indicando um viés sistemático, compatível com o *offset* inicial do transdutor quando a tara não é aplicada. Em termos espaciais, o efeito foi mais evidente nas cabeças dos metatarsos - especialmente nos pontos 2 a 4 - e, em dois participantes (homem e mulher de 56 anos), também nos pontos 6 e 9, onde as diferenças ultrapassaram 0,5 N. O desvio padrão foi, no geral, maior no teste sem tara, sobretudo nos pontos 2 e 6, enquanto as medições com tara exibiram desvios padrão mais baixos, refletindo melhor repetibilidade. No entanto, no caso do último indivíduo, as medições com tara apresentaram desvios padrão superiores.

De forma global, os resultados reforçam a importância da utilização da tara antes de efetuar medições, de modo a minimizar o viés introduzido pelo *offset* inicial do transdutor, conduzindo a registos dos valores da força mais realistas e a uma maior reprodutibilidade entre repetições, especialmente nas zonas de maior variabilidade, como as cabeças dos metatarsos (pontos 4, 5 e 6) e a região central do calcanhar (ponto 9). Num cenário de teste em vários pacientes, pode ser importante a aplicação da tara sempre que se for medir um ponto, podendo reduzir algumas alterações não só pelos momentos iniciais, assim como pelo desgaste do sistema. O mesmo respondeu de forma positiva ao medir as forças de forma consistente, embora em algumas

situações houvesse algum atraso entre a aplicação da força e o registo da mesma. Como possíveis melhorias, surge a possibilidade de calibrar o transdutor com diferentes massas, de forma a chegar ao fator de escala ideal, melhorar o próprio manuseamento ou a plataforma mecânica para aquisição do sinal.

5.3 Teste do monofilamento SW automatizado com *end-effector* acoplado

Ao enviar as coordenadas e os “*moves*” para o robô, o mesmo interpreta o programa e executa o *URScript*, culminando no percurso do teste de Semmes-Weinstein, onde o operador é substituído pelo robô e o *end-effector* desenvolvido substitui o instrumento tradicional. De notar que, como explicado na metodologia, o sensor de temperatura não foi ligado ao Arduino. A Figura 40 apresenta todas as ligações do sistema robótico.



Figura 40 – Ligações entre o computador e caixa de controlo do robô e acoplamento do *end-effector* ao braço robótico

O percurso que o robô simula é lento, demorando aproximadamente dois minutos a fazer um teste completo. Contudo, a velocidade e aceleração foram definidos com valores mais baixos, por questões de segurança na utilização do UR3e, pelo que a realização de mais testes é fundamental para melhorar a eficiência do sistema.

No acoplamento do *end-effector* ao robô, a peça em alumínio apresenta alguma mobilidade pelo que, ao mudar a orientação do TCP, pode constituir uma boa solução para a versatilidade do sistema, ao permitir a adaptação a todas as formas de pés. No entanto, é necessário o desenho e fabrico de uma nova peça de suporte, de modo a otimizar este mecanismo.

Contudo, este trabalho apresenta algumas limitações, se for utilizado numa unidade de saúde, onde o volume e a diversidade de pacientes é maior, o que implicaria a definição de novas coordenadas sempre que se trocasse de paciente. A sincronização entre o *end-effector* e o robô não existe, pelo que não é possível recolher os dados de interesse de forma correta, enquanto o robô executa os movimentos definidos. Adicionalmente, o sensor de temperatura faz parte

do sistema de análise, pelo que, é necessário definir uma forma de incorporação do sensor para análises mais completas.

6 Conclusões

Nesta dissertação, um estudo relativo a todas as características do pé diabético foi conduzido, que culminou no desenvolvimento de um sistema de análise do pé como *end-effector* para robô. Para tal, explorou-se as redes neuronais convolucionais UNet e UNet 3+, para segmentar os pontos característicos do teste de sensibilidade com o monofilamento Semmes-Weinstein (SW), com conjuntos de dados com anotações destes mesmos pontos em fotografias reais de pés humanos e em imagens de pés criadas por IA. De seguida, desenvolveu-se um sistema capaz de medir valores das forças aplicadas por um operador durante a execução de um teste, utilizando um transdutor de força montado entre uma plataforma e um suporte em *nylon*, assim como registar as temperaturas do pé de um paciente e valores da temperatura ambiente, utilizando um sensor MLX90614. Os dados são registados e guardados num programa desenvolvido para Arduino, capaz de executar comandos para calibrar o transdutor, tarar e começar um teste, percorrendo os 9 pontos definidos. Por último, desenvolveu-se um programa na *Python*, para mover um robô UR3e e executar uma simulação de um teste com o monofilamento SW. O mesmo foi construído utilizando coordenadas previamente definidas na interface de *software* do robô, o *Polyscope*, utilizando o sistema *end-effector* acoplado ao braço robótico e um molde de um pé com os pontos marcados.

Os resultados referentes ao treino e teste da UNet e UNet 3+, mostraram que, a UNet apresentou um desempenho mais consistente e equilibrado, com métricas relativas à sobreposição – F1-Score e índice de Jaccard – superiores e melhor relação entre *precision* e *recall*. Embora a Unet 3+ tenha alcançado valores mais elevados na métrica *recall*, apresentou maior instabilidade, com excesso de falsos positivos e forte dependência das características do *dataset*. Estas limitações foram particularmente evidentes no *dataset 2*, onde a complexidade das máscaras e o impacto das técnicas de *data augmentation* comprometeram a *performance* do algoritmo.

Os testes realizados com o *end-effector* demonstraram que, as medições realizadas sem efetuar a tara do transdutor antes do teste apresentaram valores superiores aos obtidos no teste com tara efetuada, confirmando a influência de um offset inicial sistemático no transdutor quando a correção não é feita. A diferença foi mais evidente, sobretudo, nas cabeças dos metatarsos e em alguns pontos do calcâneo, acompanhado de maior variabilidade entre repetições. Conclui-se, portanto que a aplicação da tara é essencial para garantir medições mais consistentes, fiáveis e reproduzíveis, sendo uma etapa fundamental em futuras aplicações experimentais.

O sistema desenvolvido foi capaz de automatizar o teste com o monofilamento Semmes-Weinstein, substituindo o examinador humano pelo robô colaborativo UR3e e o instrumento tradicional – o monofilamento de 10 gf – pelo *end-effector* desenvolvido. Apesar da execução lenta, devido a questões de segurança, os resultados obtidos provam a viabilidade do método proposto. Contudo, o trabalho apresentou algumas limitações para futuras aplicações num contexto clínico, como a necessidade de definir coordenadas sempre que se troca de paciente, a ausência de sincronização do robô e o *end-effector* na recolha de dados, assim como a não integração do termómetro no movimento.

Em suma, este trabalho demonstra o potencial de aplicações de robôs colaborativos no contexto biomédico, ao automatizar processos e recolher mais dados de interesse, constituindo

análises mais profundas, através de sistemas de análise como os *end-effectors*. Assim, pode constituir um ponto de partida para o desenvolvimento de futuros trabalhos mais eficientes e adaptáveis aos contextos clínicos em evolução constante.

6.1 Trabalhos futuros

Como trabalhos futuros, a utilização de algoritmos de segmentação UNet e UNet 3+, podem ser melhorados e também incorporados na definição das coordenadas reais dos pontos do teste de sensibilidade com o monofilamento, juntando à utilização de uma câmera que permita o mapeamento em tempo real do pé de qualquer paciente.

A utilização do microcontrolador ESP32 facilitará a recolha dos dados, dando mais liberdade para o movimento do robô e simplificação de ligações. Para além disso, é necessário a sincronização do sistema *end-effector* com o movimento do robô, para registar os dados em tempo real e, por fim, futuros estudos para otimizar o movimento do sistema, evoluindo na adaptabilidade a todos os pacientes, assim como, melhorar o uso dos sensores de temperatura.

Referências

- [1] P. Saeedi *et al.*, “Global and regional diabetes prevalence estimates for 2019 and projections for 2030 and 2045: Results from the International Diabetes Federation Diabetes Atlas, 9th edition,” *Diabetes Res Clin Pract*, vol. 157, Nov. 2019, doi: 10.1016/j.diabres.2019.107843.
- [2] International Diabetes Federation, “IDF Diabetes Atlas 10th edition,” 2021. [Online]. Available: www.diabetesatlas.org
- [3] S. Alam, M. K. Hasan, S. Neaz, N. Hussain, M. F. Hossain, and T. Rahman, “Diabetes Mellitus: Insights from Epidemiology, Biochemistry, Risk Factors, Diagnosis, Complications and Comprehensive Management,” Jun. 01, 2021, *MDPI*. doi: 10.3390/diabetology2020004.
- [4] S. Dewanjee *et al.*, “The emerging role of hdacs: Pathology and therapeutic targets in diabetes mellitus,” Jun. 01, 2021, *MDPI*. doi: 10.3390/cells10061340.
- [5] A. Ramachandran, “Know the signs and symptoms of diabetes,” *Indian J Med Res*, no. 140, pp. 579–581, Nov. 2014.
- [6] F. N. Iheagwam and O. T. Iheagwam, “Diabetes mellitus: The pathophysiology as a canvas for management elucidation and strategies,” Mar. 01, 2025, *Elsevier B.V.* doi: 10.1016/j.medntd.2025.100351.
- [7] A. S. Al-Goblan, M. A. Al-Alfi, and M. Z. Khan, “Mechanism linking diabetes mellitus and obesity,” *Diabetes, Metabolic Syndrome and Obesity*, vol. 7, pp. 587–591, Dec. 2014, doi: 10.2147/DMSO.S67400.
- [8] M. A. M. Y. Al-Hetar *et al.*, “Evaluating the Role of Vitamin D in Prediabetes Management, Insights from RCTs in the MENA Region: A Comprehensive Systematic Review,” *J Clin Med*, vol. 14, no. 4, p. 1239, Feb. 2025, doi: 10.3390/jcm14041239.
- [9] M. J. Hossain, M. Al-Mamun, and M. R. Islam, “Diabetes mellitus, the fastest growing global public health concern: Early detection should be focused,” Mar. 01, 2024, *John Wiley and Sons Inc.* doi: 10.1002/hsr2.2004.

- [10] A. S. Al-Goblan, M. A. Al-Alfi, and M. Z. Khan, "Mechanism linking diabetes mellitus and obesity," *Diabetes, Metabolic Syndrome and Obesity*, vol. 7, pp. 587–591, Dec. 2014, doi: 10.2147/DMSO.S67400.
- [11] S. A. Antar *et al.*, "Diabetes mellitus: Classification, mediators, and complications; A gate to identify potential targets for the development of new effective treatments," Dec. 01, 2023, *Elsevier Masson s.r.l.* doi: 10.1016/j.biopha.2023.115734.
- [12] I. W. Suryasa, M. Rodríguez-Gámez, and T. Koldoris, "Health and Treatment of Diabetes Mellitus," *Int J Health Sci (Qassim)*, vol. 5, no. 1, pp. I–V, 2021, doi: 10.53730/IJHS.V5N1.2864.
- [13] A. Sweeting *et al.*, "Epidemiology and management of gestational diabetes," Jul. 13, 2024, *Elsevier B.V.* doi: 10.1016/S0140-6736(24)00825-0.
- [14] A. Katsarou *et al.*, "Type 1 diabetes mellitus," *Nat Rev Dis Primers*, vol. 3, Mar. 2017, doi: 10.1038/nrdp.2017.16.
- [15] J. A. Vanderniet, A. J. Jenkins, and K. C. Donaghue, "Epidemiology of Type 1 Diabetes," Oct. 01, 2022, *Springer*. doi: 10.1007/s11886-022-01762-w.
- [16] A. Siddiqui *et al.*, "Mechanism, Pathophysiology and Management-A Review," 2013. [Online]. Available: <https://www.researchgate.net/publication/256328144>
- [17] S. Chatterjee, K. Khunti, and M. J. Davies, "Type 2 diabetes," Jun. 03, 2017, *Lancet Publishing Group*. doi: 10.1016/S0140-6736(17)30058-2.
- [18] S. Jain and S. Saraf, "Type 2 diabetes mellitus - Its global prevalence and therapeutic strategies," 2010, *Elsevier Ltd*. doi: 10.1016/j.dsx.2008.04.011.
- [19] M. J. Hossain, M. Al-Mamun, and M. R. Islam, "Diabetes mellitus, the fastest growing global public health concern: Early detection should be focused," Mar. 01, 2024, *John Wiley and Sons Inc*. doi: 10.1002/hsr2.2004.
- [20] M. Edmonds, C. Manu, and P. Vas, "The current burden of diabetic foot disease," *J Clin Orthop Trauma*, vol. 17, pp. 88–93, Jun. 2021, doi: 10.1016/j.jcot.2021.01.017.
- [21] J. Zenker, D. Ziegler, and R. Chrast, "Novel pathogenic pathways in diabetic neuropathy," Aug. 2013. doi: 10.1016/j.tins.2013.04.008.
- [22] D. Tomic, J. E. Shaw, and D. J. Magliano, "The burden and risks of emerging complications of diabetes mellitus," Sep. 01, 2022, *Nature Research*. doi: 10.1038/s41574-022-00690-7.
- [23] J. Zenker, D. Ziegler, and R. Chrast, "Novel pathogenic pathways in diabetic neuropathy," Aug. 2013. doi: 10.1016/j.tins.2013.04.008.
- [24] G. Sloan, D. Selvarajah, and S. Tesfaye, "Pathogenesis, diagnosis and clinical management of diabetic sensorimotor peripheral neuropathy," Jul. 01, 2021, *Nature Research*. doi: 10.1038/s41574-021-00496-z.
- [25] C. Beach, G. Cooper, A. Weightman, E. F. Hodson-Tole, N. D. Reeves, and A. J. Casson, "Monitoring of dynamic plantar foot temperatures in diabetes with personalised 3d-printed wearables," *Sensors*, vol. 21, no. 5, pp. 1–14, Mar. 2021, doi: 10.3390/s21051717.

- [26] X. Wang, C.-X. Yuan, B. Xu, and Z. Yu, "Diabetic foot ulcers: Classification, risk factors and management," *World J Diabetes*, vol. 13, no. 12, pp. 1049–1065, Dec. 2022, doi: 10.4239/wjd.v13.i12.1049.
- [27] N. Sharma, R. Sharma, and N. Jindal, "Machine Learning and Deep Learning Applications-A Vision," *Global Transitions Proceedings*, vol. 2, no. 1, pp. 24–28, Jun. 2021, doi: 10.1016/j.gltip.2021.01.004.
- [28] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Springer*, Apr. 2021, doi: 10.1007/s12525-021-00475-2/Published.
- [29] T. Diwan, G. Anirudh, and J. V. Tembhurne, "Object detection using YOLO: challenges, architectural successors, datasets and applications," *Multimed Tools Appl*, vol. 82, no. 6, pp. 9243–9275, Mar. 2023, doi: 10.1007/s11042-022-13644-y.
- [30] A. Al Qurri and M. Almekkawy, "Improved UNet with Attention for Medical Image Segmentation," *Sensors (Basel)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/s23208589.
- [31] M. Krithika alias AnbuDevi and K. Suganthi, "Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET," Dec. 01, 2022, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/diagnostics12123064.
- [32] H. Huang *et al.*, "UNET 3+: A FULL-SCALE CONNECTED UNET FOR MEDICAL IMAGE SEGMENTATION".
- [33] A. Wolniakowski, K. Miatliuk, J. J. Quintana, M. A. Ferrer, and M. Diaz, "Towards human-like kinematics in industrial robotic arms: a case study on a UR3 robot."
- [34] R. Sultanov, S. Sulaiman, H. Li, R. Meshcheryakov, and E. Magid, "A Review on Collaborative Robots in Industrial and Service Sectors," in *2022 International Siberian Conference on Control and Communications, SIBCON 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/SIBCON56144.2022.10003014.
- [35] F. Müller, C. Deuerlein, and M. Koch, "Cyber-physical-system for representing a robot end effector," in *Procedia CIRP*, Elsevier B.V., 2021, pp. 307–312. doi: 10.1016/j.procir.2021.05.071.
- [36] Y. Dai, C. Xiang, W. Qu, and Q. Zhang, "A Review of End-Effector Research Based on Compliance Control," Feb. 01, 2022, *MDPI*. doi: 10.3390/machines10020100.
- [37] S. Dube *et al.*, "Effectiveness of Semmes Weinstein 10 gm monofilament in diabetic peripheral neuropathy taking nerve conduction and autonomic function study as reference tests," *J Family Med Prim Care*, vol. 11, no. 10, pp. 6204–6208, Oct. 2022, doi: 10.4103/jfmpc.jfmpc_195_22.
- [38] C. Vitale Kyle, J. Robert L, and Z. Michael E, "Contact Mechanics Modeling of the Semmes-Weinstein Monofilament on the Plantar Surface of the Foot," *International Journal of Foot and Ankle*, vol. 5, no. 2, May 2021, doi: 10.23937/2643-3885/1710055.
- [39] N. C. Schaper, J. J. van Netten, J. Apelqvist, S. A. Bus, R. J. Hinchliffe, and B. A. Lipsky, "IWGDF Guidelines on the prevention and management of diabetic foot disease," 2019. [Online]. Available: www.iwgdfguidelines.org

- [40] A. Nather, W. K. Lin, Z. Aziz, C. H. J. Ong, B. M. C. Feng, and C. B. Lin, "Assessment of sensory neuropathy in patients with diabetic foot problems," *Diabet Foot Ankle*, vol. 2, pp. 1–5, 2011, doi: 10.3402/dfa.v2i0.6367.
- [41] P. Castro-Martins, L. Pinto-Coelho, and R. D. S. G. Campilho, "Calibration and Modeling of the Semmes–Weinstein Monofilament for Diabetic Foot Management," *Bioengineering*, vol. 11, no. 9, p. 886, Aug. 2024, doi: 10.3390/bioengineering11090886.
- [42] Y. Feng, F. J. Schlösser, and B. E. Sumpio, "The Semmes Weinstein monofilament examination is a significant predictor of the risk of foot ulceration and amputation in patients with diabetes mellitus," *J Vasc Surg*, vol. 53, no. 1, 2011, doi: 10.1016/j.jvs.2010.06.100.
- [43] V. Aithal and S. Bhat, "Semmes Weinstein monofilament test for detection of diabetic peripheral neuropathy: sensitivity and specificity," *Egyptian Journal of Neurology, Psychiatry and Neurosurgery*, vol. 60, no. 1, Dec. 2024, doi: 10.1186/s41983-023-00785-6.
- [44] B. A. Perkins, A. Orszag, M. Ngo, E. Ng, P. New, and V. Bril, "Prediction of incident diabetic neuropathy using the monofilament examination: A 4-year prospective study," *Diabetes Care*, vol. 33, no. 7, pp. 1549–1554, Jul. 2010, doi: 10.2337/dc09-1835.
- [45] M. H. Haloua, I. Sierevelt, and W. J. Theuvenet, "Semmes-weinstein monofilaments: Influence of temperature, humidity, and age," *Journal of Hand Surgery*, vol. 36, no. 7, pp. 1191–1196, Jul. 2011, doi: 10.1016/j.jhsa.2011.04.009.
- [46] B. Raymond, J. Steriovski, K. N. Gillyard, C. Yang, S. C. Wu, and R. T. Crews, "Choosing a Vibratory Test to Pair With Semmes Weinstein Monofilament Testing for Evaluating Lower Extremity Sensation in Patients With Diabetes: A Comparison of Three Vibratory Methodologies," *J Diabetes Sci Technol*, vol. 14, no. 1, pp. 8–15, Jan. 2020, doi: 10.1177/1932296819849478.
- [47] N. Khumchum, N. Koonalinthip, and S. Janchai, "Accuracy and reliability of the Ipswich touch test in identifying loss of protective sensation among diabetic patients," *Foot*, vol. 61, Dec. 2024, doi: 10.1016/j.foot.2024.102132.
- [48] Sri Sakinah, Muhammad Tahir, Wahyuni, Nurun Salaman Alhidayat, and Wahyuni, "Effectiveness of the Monofilament Test and Ipswich Touch Test (IpTT) in the Early Detection of Neuropathy Complications in Patients with Type 2 Diabetes Mellitus," *Journal Of Nursing Practice*, vol. 8, no. 1, pp. 15–22, Oct. 2024, doi: 10.30994/jnp.v8i1.628.
- [49] L. M. A. Dutra *et al.*, "Is it possible to substitute the monofilament test for the Ipswich Touch Test in screening for peripheral diabetic neuropathy?," *Diabetol Metab Syndr*, vol. 12, no. 1, Mar. 2020, doi: 10.1186/s13098-020-00534-2.
- [50] K. Azzopardi, A. Gatt, N. Chockalingam, and C. Formosa, "Hidden dangers revealed by misdiagnosed diabetic neuropathy: A comparison of simple clinical tests for the screening of vibration perception threshold at primary care level," *Prim Care Diabetes*, vol. 12, no. 2, pp. 111–115, Apr. 2018, doi: 10.1016/j.pcd.2017.09.004.
- [51] F. M. Sebastianes, P. H. Zanoni, A. C. R. Feitosa, M. Nery, and M. C. Parisi, "Comparação entre o Teste de Senso de Posição Articular (TSPA), Teste do Diapasão (TD), Exame do Monofilamento de Semmes-Weinstein (EMSW) e Instrumento de Rastreo de Neuropatia de Michigan (QMNSI)

- na sensibilidade do diagnóstico da polineuropatia diabética,” *Rev Med (Rio J)*, vol. 100, no. 3, pp. 246–253, Jul. 2021, doi: 10.11606/issn.1679-9836.v100i3p246-253.
- [52] M. Lasca, A. L. Tăut, and I. A. Vereșiu, “Comparative evaluation of several simple screening tests for risk of neuropathic ulcerations of feet in patients with diabetes mellitus,” *Rom J Diabetes Nutr Metab Dis*, vol. 23, no. 1, pp. 67–72, Mar. 2016, doi: 10.1515/rjdnmd-2016-0008.
- [53] R. Johnson, A. Osbourne, J. Rispoli, and C. Verdin, “The Diabetic Foot Assessment,” *Orthopaedic Nursing*, vol. 37, no. 1, pp. 13–21, 2018, doi: 10.1097/NOR.0000000000000414.
- [54] C. Ghosh, B. Sinha, and U. Dutta, “Perception of vibration threshold potential with tuning fork and pure tone audiometry assessment for early detection of diabetic polyneuropathy,” *Natl J Physiol Pharm Pharmacol*, vol. 14, no. 9, p. 1, 2024, doi: 10.5455/njppp.2024.14.06259202424072024.
- [55] Y. Yoshikawa *et al.*, “Prediction of callus and ulcer development in patients with diabetic peripheral neuropathy by isosceles triangle-forming tuning fork,” *SAGE Open Med*, vol. 10, Mar. 2022, doi: 10.1177/20503121221085097.
- [56] S. Chattopadhyay, S. Goswami, N. Sengupta, and A. Baidya, “Can the 128-Hz tuning fork be an alternative to the biothesiometer for diabetic peripheral neuropathy screening? A cross-sectional study in a tertiary hospital in East India,” *BMJ Open*, vol. 14, no. 6, Jun. 2024, doi: 10.1136/bmjopen-2023-082193.
- [57] A. Tentolouris, A. Stergioti, I. Eleftheriadou, C. Siafarikas, and D. Tsilingiris, “Screening tools for diabetic foot ulcers: a narrative review,” 2024, *Springer Science and Business Media Deutschland GmbH*. doi: 10.1007/s42000-024-00598-z.
- [58] S. Dash and A. K. Thakur, “Perception of vibration threshold is a marker of diabetic neuropathy,” *Natl J Physiol Pharm Pharmacol*, vol. 7, no. 9, pp. 1003–1006, 2017, doi: 10.5455/njppp.2017.7.0518326052017.
- [59] I. Willits *et al.*, “VibraTip™ for Testing Vibration Perception to Detect Diabetic Peripheral Neuropathy: A NICE Medical Technology Guidance,” Aug. 03, 2015, *Springer International Publishing*. doi: 10.1007/s40258-015-0181-6.
- [60] A. Tentolouris, N. Tentolouris, I. Eleftheriadou, and E. B. Jude, “The Performance and Interrater Agreement of Vibration Perception for the Diagnosis of Loss of Protective Sensation in People With Diabetes Mellitus,” *International Journal of Lower Extremity Wounds*, vol. 22, no. 1, pp. 72–76, Mar. 2023, doi: 10.1177/1534734621994058.
- [61] H. Nizar, N. Munro, P. Nightingale, and M. D. Feher, “Diagnostic accuracy of the VibraTip in detection of diabetic peripheral neuropathy,” *British Journal of Diabetes and Vascular Disease*, vol. 14, no. 1, pp. 26–29, 2014, doi: 10.15277/bjdvd.2014.005.
- [62] M. Faus Camarena, M. Izquierdo-Renau, I. Julian-Rochina, M. Arrébola, and M. Miralles, “Update on the Use of Infrared Thermography in the Early Detection of Diabetic Foot Complications: A Bibliographic Review,” Jan. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/s24010252.

- [63] S. González-Pérez *et al.*, “Assessment of registration methods for thermal infrared and visible images for diabetic foot monitoring,” *Sensors*, vol. 21, no. 7, Apr. 2021, doi: 10.3390/s21072264.
- [64] J. T. González, B. Gómez-Martín, A. H. Encinas, J. Martín-Vaquero, A. Queiruga-Dios, and A. Martínez-Nova, “The use of infrared thermography to develop and assess a wearable sock and monitor foot temperature in diabetic subjects,” *Sensors*, vol. 21, no. 5, pp. 1–20, Mar. 2021, doi: 10.3390/s21051821.
- [65] P. Kumar *et al.*, “Applications of thermal imaging with infrared thermography in Orthopaedics,” *J Clin Orthop Trauma*, vol. 24, Jan. 2022, doi: 10.1016/j.jcot.2021.101722.
- [66] I. Khosa, A. Raza, M. Anjum, W. Ahmad, and S. Shahab, “Automatic Diabetic Foot Ulcer Recognition Using Multi-Level Thermographic Image Data,” *Diagnostics*, vol. 13, no. 16, Aug. 2023, doi: 10.3390/diagnostics13162637.
- [67] P. N. Thotad, G. R. Bharamagoudar, and B. S. Anami, “Diabetic foot ulcer detection using deep learning approaches,” *Sensors International*, vol. 4, Jan. 2023, doi: 10.1016/j.sintl.2022.100210.
- [68] M. Goyal, N. D. Reeves, S. Rajbhandari, and M. H. Yap, “Robust Methods for Real-Time Diabetic Foot Ulcer Detection and Localization on Mobile Devices,” *IEEE J Biomed Health Inform*, vol. 23, no. 4, pp. 1730–1741, Jul. 2019, doi: 10.1109/JBHI.2018.2868656.
- [69] T. Costa, L. Coelho, and M. F. Silva, “Automatic Segmentation of Monofilament Testing Sites in Plantar Images for Diabetic Foot Management,” *Bioengineering*, vol. 9, no. 3, Mar. 2022, doi: 10.3390/bioengineering9030086.
- [70] K. Moulaei, M. Malek, and A. Sheikhtaheri, “A smart wearable device for monitoring and self-management of diabetic foot: A proof of concept study,” *Int J Med Inform*, vol. 146, Feb. 2021, doi: 10.1016/j.ijmedinf.2020.104343.
- [71] K. E. Chatwin *et al.*, “An intelligent insole system with personalised digital feedback reduces foot pressures during daily life: An 18-month randomised controlled trial,” *Diabetes Res Clin Pract*, vol. 181, Nov. 2021, doi: 10.1016/j.diabres.2021.109091.
- [72] C. Wilasrusmee *et al.*, “A Novel Robotic Monofilament Test for Diabetic Neuropathy,” 2010.
- [73] W. Choi and B. Ahn, “Monitoring System for Diabetic Foot Ulceration Patients Using Robotic Palpation,” *Int J Control Autom Syst*, vol. 18, no. 1, pp. 46–52, Jan. 2020, doi: 10.1007/s12555-019-0242-y.
- [74] V. K. Castellano *et al.*, “Plantar threshold sensitivity assessment using an automated tool—Clinical assessment comparison between a control population without type 2 diabetes mellitus, and populations with type 2 diabetes mellitus, with and without neuropathy symptoms,” *PLoS One*, vol. 18, no. 7 July, Jul. 2023, doi: 10.1371/journal.pone.0286559.
- [75] N. Tomar (nikhilroxtomar), “Polyp-Segmentation-using-UNet-3-Plus-in-TensorFlow,” GitHub. Accessed: May 20, 2025. [Online]. Available: <https://github.com/nikhilroxtomar/Polyp-Segmentation-using-UNet-3-Plus-in-TensorFlow/blob/main/model.py>

- [76] J. W. Simatupang and A. Aziz Ar-Rafif, "Prototype of A Smart Trash Bin for Trash Composting Based on Load Cell HX711 and Ultrasonic Sensors," vol. IX, no. 1, 2024.
- [77] A. Galadima, "Arduino as a learning tool," IEEE, Abuja, 2014.
- [78] I. Varshitha, "ARDUINO WEIGHING MACHINE USING LOADCELL AND HX711 MODULE," Warangal, 2021.
- [79] A. E. Kumar, H. R. K, and K. G. Raj, "Load Cell based Fuel Level Measurement using Arduino Uno Microcontroller," 2018. [Online]. Available: www.IJARND.com
- [80] A. Sudioanto, Z. Jamaludin, A. A. Abdul Rahman, S. Novianto, and F. Muharrom, "Smart Temperature Measurement System for Milling Process Application Based on MLX90614 Infrared Thermometer Sensor with Arduino," *Journal of Advanced Research in Applied Mechanics*, vol. 72, no. 1, pp. 10–24, Aug. 2020, doi: 10.37934/aram.72.1.1024.
- [81] F. Dai, H. Wen, J. Zhao, H. Hao, and Q. Zhang, "Design of an instrument for measuring heart rate and blood oxygen based on Arduino," *Journal of Robotics, Networking and Artificial Life*, vol. 7, no. 4, pp. 275–278, Mar. 2021, doi: 10.2991/jrnal.k.201215.014.
- [82] Joy-IT by SIMAC Electronics, "INFRARED THERMOMETER datasheet," Jul. 15, 2022.
- [83] P. M. de Castro Martins, "Análise Objetiva ao Desempenho do Monofilamento de Semmes-Weinstein de 10 gf para Avaliação da Sensibilidade Cutânea Protetora no Pé Diabético," Instituto Superior de Engenharia do Porto, Porto, 2020.

Anexos

Anexo A – Ficha técnica do transdutor de força

Ficha de especificações e características técnicas do transdutor de força.

TAL220


PARALLEL BEAM LOAD CELL



- Features:
- ◆ Capacity : 0.5~200kg
 - ◆ Material: aluminum-alloy or alloy steel
 - ◆ Type: Parallel beam type
 - ◆ Defend grade: IP65
 - ◆ Application : kitchen scale, electronic balance, electronic platform scale and other electronic weighing devices.

WWW.HTC-SENSOR.COM

Electrical connection and Dimensions:(dimension unit: mm)




Specifications:		
capacity	kg	3, 5,10,20, 30, 50, 80, 100,200
safe overload	%FS	120
ultimate overload	%FS	150
rated output	mV/V	1.0 ± 0.1
excitation voltage	Vdc	5 ~ 12
combined error	%FS	± 0.05
zero unbalance	%FS	± 0.1
non-linearity	%FS	± 0.05
hysteresis	%FS	± 0.05
repeatability	%FS	± 0.03
creep	%FS/30min	± 0.05
input resistance	Ω	1090 ± 50
output resistance	Ω	1000 ± 10
insulation resistance	M Ω	≥ 3000 @ 50 Vdc
operating temperature range	°C	-20 ~ +55
compensated temperature range	°C	-10 ~ +40
temperature coefficient of SPAN	%FS/10°C	± 0.05
temperature coefficient of ZERO	%FS/10°C	± 0.05
Electrical connection	cable	4 color wire or 4 sheilded PVC cable, Ø0.8 × 250 mm

※Ordering code: model-capacity- rated output-accuracy-defend grade- the length of cable

Anexo B – Ligações do módulo HX711

Ligações do módulo amplificador HX711 com a célula de carga e com o microcontrolador.

HX711 Pinout



Anexo C – Ficha técnica do termómetro infravermelho MLX90614

Ficha de especificações e características técnicas do termómetro infravermelho MLX90614.



This infrared sensor module uses the MLX90614 sensor and enables non-contact temperature measurements. The control is particularly simple via the I2C interface and is thus possible with a wide variety of microcontrollers and single-board computers.

MAIN FEATURES	
Operating voltage	3.3 - 5 V
Sensor	MLX90614
Interface	I2C
Weight	2 g
Dimensions	24 x 12 x 8 mm
Items delivered	Infrared thermometer
SPECIFICATIONS	
Current consumption	1.0 - 2.5 mA
Measuring range (environment)	-40 °C to 125 °C
Measuring range (object)	-70 °C to 380 °C
Accuracy	0.5 °C (0 °C to 50 °C)
ADDITIONAL INFORMATION	
Article no.	SEN-IR-TEMP
EAN	4250236823720
Customs Tariff No.	90268020

Anexo D - Código Arduino para recolha de dados

Código Arduino relativo à calibração e registo dos valores do transdutor de força e do sensor de temperatura.

```
#include <HX711.h>
#include <EEPROM.h>
#include <Wire.h>
#include <Adafruit_MLX90614.h>

#define DOUT_PIN 4
#define SCK_PIN 5
#define CAL_ADDR 0
#define OFF_ADDR 4
#define DATA_ADDR 20
#define THRESHOLD 0.3

HX711 scale;
Adafruit_MLX90614 mlx = Adafruit_MLX90614();

float calFactor = 1.0;
long offset = 0;
bool calibrated = false;

struct Point {
  float maxF;
  float avgF;
  int dur;
  bool tested;
  float tempObj;
  float tempAmb;
};

Point test[9];
int currentP = 0;

void setup() {
  Serial.begin(115200);
  Serial.println(F("--- SEMMES-WEINSTEIN ---"));

  scale.begin(DOUT_PIN, SCK_PIN);
  delay(1000);

  if (!mlx.begin()) {
    Serial.println(F("Erro no sensor MLX90614"));
  } else {
    Serial.println(F("Sensor MLX90614 OK"));
  }

  loadCal();
  resetTest();
  showMenu();
}

void loop() {
  if (Serial.available()) {
    char cmd = Serial.read();
```

```

while (Serial.available()) Serial.read();

switch (cmd) {
  case '1': calibrate(); break;
  case '2': fullTest(); break;
  case '3': showResults(); break;
  case '4': saveTest(); break;
  case '5': loadTest(); break;
  case '6': resetTest(); Serial.println(F("Reset OK")); break;
  case '7': tareNow(); break;
  case 'm': showMenu(); break;
  default: Serial.println(F("Inválido"));
}
}
}

void showMenu() {
  Serial.println(F("\n--- MENU ---"));
  Serial.println(F("1-Calibrar o transdutor"));
  Serial.println(F("2-Teste do monofilamento SW"));
  Serial.println(F("3-Resultados"));
  Serial.println(F("4-Guardar resultados"));
  Serial.println(F("5-Carregar resultados"));
  Serial.println(F("6-Apagar resultados"));
  Serial.println(F("7-Tarar"));
  Serial.print(F("Status: "));
  Serial.println(calibrated ? F("OK") : F("Calibrar!"));
  Serial.print(F("Comando: "));
}

void calibrate() {
  Serial.println(F("\n--- CALIBRAÇÃO ---"));
  Serial.println(F("Remova peso e clique Enter"));
  waitEnter();

  scale.tare(20);
  offset = scale.get_offset();
  Serial.println(F("Tara OK"));

  Serial.print(F("Peso conhecido (g): "));
  float peso = readFloat();
  if (peso <= 0) return;

  Serial.println(F("Coloque peso e clique Enter"));
  waitEnter();

  long reading = scale.get_units(20);
  calFactor = (float)reading / peso;
  scale.set_scale(calFactor);

  saveCal();
  calibrated = true;
  Serial.println(F("Calibrado!"));
}

void tareNow() {
  Serial.println(F("\n--- TARA ---"));
  Serial.println(F("Remova qualquer peso"));
  delay(2000);
  scale.tare(20);
}

```

```

    offset = scale.get_offset();
    saveCal();
    Serial.println(F("Tara concluída"));
}

void fullTest() {
    if (!calibrated) {
        Serial.println(F("Calibre primeiro"));
        return;
    }

    Serial.println(F("\n--- TESTE 9 PONTOS ---"));
    resetTest();

    const char* pontos[] = {
        "1.Hálux", "2.1ºMet", "3.3ºMet", "4.5ºMet",
        "5.MeioLat", "6.MeioMed", "7.CalcLat", "8.CalcMed", "9.Centro"
    };

    for (int i = 0; i < 9; i++) {
        Serial.print(F("\n>>> "));
        Serial.print(pontos[i]);
        Serial.println(F(" - Aplique força"));

        bool measuring = false;
        unsigned long start = 0;

        while (true) {
            if (Serial.available()) {
                if (Serial.read() == 's') {
                    Serial.println(F("Ponto avançado"));
                    break;
                }
            }
        }

        float f = scale.get_units(10);

        if (f > THRESHOLD && !measuring) {
            measuring = true;
            start = millis();
        }

        if (measuring && millis() - start >= 2000) {
            float forceNow = abs(scale.get_units(10));
            float tempObj = mlx.readObjectTempC();
            float tempAmb = mlx.readAmbientTempC();

            test[i].maxF = forceNow;
            test[i].avgF = forceNow;
            test[i].dur = 2000;
            test[i].tested = true;
            test[i].tempObj = tempObj;
            test[i].tempAmb = tempAmb;

            Serial.print(F("Força aos 2s: "));
            Serial.print(forceNow * 0.00980665, 3);
            Serial.println(F(" N"));

            Serial.print(F("Temp. Obj: "));

```

```

        Serial.print(tempObj, 2);
        Serial.println(F(" °C"));

        Serial.print(F("Temp. ambiente: "));
        Serial.print(tempAmb, 2);
        Serial.println(F(" °C"));
        break;
    }

    delay(50);
}
}

Serial.println(F("\nTeste Concluído"));
showResults();
}

void showResults() {
    Serial.println(F("\n--- RESULTADOS ---"));
    Serial.println(F("P | F (N) | Obj(°C) | Amb(°C) | Dur | OK"));
    Serial.println(F("---|-----|-----|-----|-----|----"));

    for (int i = 0; i < 9; i++) {
        Serial.print(i + 1);
        Serial.print(F(" | "));

        if (test[i].tested) {
            Serial.print(abs(test[i].maxF * 0.00980665, 3));
            Serial.print(F(" | "));
            Serial.print(test[i].tempObj, 2);
            Serial.print(F(" | "));
            Serial.print(test[i].tempAmb, 2);
            Serial.print(F(" | "));
            Serial.print(test[i].dur);
            Serial.println(F(" | Y"));
        } else {
            Serial.println(F(" - | - | - | - | N"));
        }
    }
}

void saveTest() {
    for (int i = 0; i < 9; i++) {
        EEPROM.put(DATA_ADDR + i * sizeof(Point), test[i]);
    }
    Serial.println(F("Guardado"));
}

void loadTest() {
    for (int i = 0; i < 9; i++) {
        EEPROM.get(DATA_ADDR + i * sizeof(Point), test[i]);
    }
    Serial.println(F("Carregado"));
    showResults();
}

void resetTest() {
    for (int i = 0; i < 9; i++) {
        test[i].maxF = 0;
        test[i].avgF = 0;
    }
}

```

```

        test[i].dur = 0;
        test[i].tested = false;
        test[i].tempObj = 0;
        test[i].tempAmb = 0;
    }
}

void saveCal() {
    EEPROM.put(CAL_ADDR, calFactor);
    EEPROM.put(OFF_ADDR, offset);
}

void loadCal() {
    EEPROM.get(CAL_ADDR, calFactor);
    EEPROM.get(OFF_ADDR, offset);

    if (calFactor > 0.001 && calFactor < 10000) {
        scale.set_scale(calFactor);
        scale.set_offset(offset);
        calibrated = true;
        Serial.println(F("Calibração OK"));
    } else {
        calibrated = false;
    }
}


void waitEnter() {
    while (Serial.read() != '\n') {
        if (Serial.available()) Serial.read();
    }
}

float readFloat() {
    String s = "";
    while (true) {
        if (Serial.available()) {
            char c = Serial.read();
            if (c == '\n') break;
            s += c;
        }
    }
    return s.toFloat();
}

```

Anexo E – Especificações técnicas do robô UR3e

Informações e especificações técnicas do robô UR3e da *Universal Robots*.



Anexo F – Código para o controle do robô

Programa em *Python* que simula o percurso de um teste do monofilamento Semmes-Weinstein.

```
import socket

HOST, PORT = "169.254.192.229", 30002

orient = (2.583, -1.788, 0.072)

#Coordenadas dos 9 pontos (em metros)
p1_apr, p1_sw, p1_ret = (0.45900, -0.18638, 0.16857), (0.46433, -0.18639,
0.14100), (0.46410, -0.18638, 0.16857)
p2_apr, p2_sw, p2_ret = (0.46092, -0.15800, 0.16857), (0.46092, -0.15799,
0.14100), (0.46092, -0.15800, 0.16857)
p3_apr, p3_sw, p3_ret = (0.44156, -0.13907, 0.16857), (0.44156, -0.13907,
0.14100), (0.44156, -0.13907, 0.16857)
p4_apr, p4_sw, p4_ret = (0.43245, -0.18126, 0.16857), (0.43245, -0.18125,
0.14100), (0.43245, -0.18126, 0.16857)
p5_apr, p5_sw, p5_ret = (0.43640, -0.16076, 0.16857), (0.43640, -0.16076,
0.14100), (0.43640, -0.16076, 0.16857)
p6_apr, p6_sw, p6_ret = (0.42371, -0.14353, 0.16857), (0.42371, -0.14353,
0.14100), (0.42371, -0.14353, 0.16857)
p7_apr, p7_sw, p7_ret = (0.36575, -0.15024, 0.16857), (0.36575, -0.15024,
0.14100), (0.36575, -0.15024, 0.16857)
p8_apr, p8_sw, p8_ret = (0.36576, -0.16941, 0.16857), (0.36576, -0.16941,
0.14100), (0.36576, -0.16941, 0.16857)
p9_apr, p9_sw, p9_ret = (0.31439, -0.15834, 0.16857), (0.31439, -0.15834,
0.14100), (0.31439, -0.15834, 0.16857)

# Parâmetros
v_apr, a_apr      = 0.03, 0.1
v_teste, a_teste = 0.008, 0.05
dwell = 1

# URScript
lines = ["def sw_all():"]

for i in range(1, 10):
    apr = globals()[f"p{i}_apr"]
    sw  = globals()[f"p{i}_sw"]
```

```

ret = globals()[f"p{i}_ret"]

lines += [
    f" # ---- P{i} ----",
    f" movep(p[{apr[0]}, {apr[1]}, {apr[2]}, {orient[0]}, {orient[1]},
{orient[2]}], a={a_apr}, v={v_apr})",
    f" movel(p[{sw[0]}, {sw[1]}, {sw[2]}, {orient[0]}, {orient[1]},
{orient[2]}], a={a_teste}, v={v_teste})",
    f" sleep({dwell})",
    f" movep(p[{ret[0]}, {ret[1]}, {ret[2]}, {orient[0]}, {orient[1]},
{orient[2]}], a={a_apr}, v={v_apr})",
    ]

lines.append("end")
lines.append("sw_all()")

program = "\n".join(lines) + "\n"

with socket.socket(socket.AF_INET, socket.SOCK_STREAM) as s:
    s.connect((HOST, PORT))
    s.sendall(program.encode("utf-8"))

print("Programa enviado")

```