

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

NATÁLIA SOARES GIRÃO

**DESENVOLVIMENTO DE PLACA SENSORA INSTRUMENTADA COM REDES
DE BRAGG EM FIBRAS ÓTICAS PARA AUTENTICAÇÃO BIOMÉTRICA**

CURITIBA

2024

NATÁLIA SOARES GIRÃO

**DESENVOLVIMENTO DE PLACA SENSORA INSTRUMENTADA COM REDES
DE BRAGG EM FIBRAS ÓTICAS PARA AUTENTICAÇÃO BIOMÉTRICA**

**Development of a fiber Bragg grating-based board for biometric
authentication**

Tese de doutorado apresentado como requisito para obtenção do título de PhD em Ciências do Curso de Pós Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná.

Orientador: Profa. Dra. Marcia Muller

Coorientador: Profa. Dra. Lúcia Valéria Ramos de Arruda

CURITIBA

2024



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

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



**Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Curitiba**



NATALIA SOARES GIRAO

DESENVOLVIMENTO DE PLACA SENSORA INSTRUMENTADA COM REDES DE BRAGG EM FIBRAS ÓTICAS PARA AUTENTICAÇÃO BIOMÉTRICA

Trabalho de pesquisa de doutorado apresentado como requisito para obtenção do título de Doutor Em Ciências da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Fotônica Em Engenharia.

Data de aprovação: 08 de Dezembro de 2023

Dra. Marcia Muller, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Alexandre Bessa Dos Santos, Doutorado - Universidade Federal de Juiz de Fora (Ufjf)

Dr. Andre Eugenio Lazzaretti, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Guilherme De Alencar Barreto, Doutorado - Universidade Federal do Ceará (Ufc)

Dr. Jose Luis Fabris, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 08/12/2023.

Dedico este trabalho a minha família e aos meus amigos por todo o suporte e apoio.

AGRADECIMENTOS

Agradeço primeiramente à minha família, que apesar da distância está sempre presente e é meu maior suporte. Meus pais, meus irmãos, meus tios, minhas avós, meus primos e meus cachorros, este trabalho é fruto também de vocês.

Agradeço também aos meus amigos de longa jornada e aos recentes, das várias fases da vida, por todo o apoio e por entenderem minha ausência por diversas vezes. Davi, Lays Almeida e Bia, que me acompanham desde a época do colégio; Lays Seixas, minha grande parceira de Lablaser, minha gêmea do olho verde, nem sei mensurar o quanto agradeço pela sua amizade; Franciele Mendes e Robinho, meus parceiros de laboratório que se tornaram meus grandes amigos. Hanna, Rafael, Drieli e Cleiner, bendita a hora em que começamos a treinar juntos. Minha grande sorte é ter todos vocês na minha vida.

Aos colegas de UTFPR, em especial aos de Lablaser, pela parceria e por tornarem o ambiente de trabalho um lugar produtivo, mas não competitivo.

À minha orientadora, professora Marcia, por todos os ensinamentos não só científicos, mas também éticos. A senhora e o professor José Luis Fabris, somados à professora Valéria, são meus grandes exemplos de como um pesquisador deve ser. Professora Lúcia Valéria, minha coorientadora e conterrânea, obrigada por me acolher desde a disciplina de Redes Neurais e me fazer enxergar uma nova habilidade. Sou grata por todo o incentivo.

Às instalações do Laboratório Multiusuário de Fotônica e do Lablaser, localizados na UTFPR - CT.

Por fim, o presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Escreva algo que vale a pena ser lido ou faça
algo que vale a pena ser escrito
(Franklin, Benjamin)

RESUMO

Este trabalho apresenta o projeto, desenvolvimento e resultados de uma placa sensora instrumentada com redes de Bragg em fibras óticas detalhando as etapas de fabricação e testes, com o objetivo de autenticação biométrica a partir dos padrões de pisada dos usuários. As redes de Bragg foram encapsuladas em silicone de cura acética e posicionadas em regiões da placa de forma a construir regiões de sensoriamento correspondentes ao tamanho de pés adultos, para a coleta em regime estático. A partir dos dados medidos, foi desenvolvido um modelo de resposta do sistema, bem como a representação gráfica por meio de mapas de pressão normalizados. Desenvolveu-se também dois modelos de reconhecimento de padrão baseados em aprendizado de máquina (*machine learning*) e aprendizado profundo (*deep learning*) gerando, respectivamente, um modelo de máquina de vetor de suporte e uma rede neural convolucional capazes de classificar diferentes pisadas humanas com fins de autenticação biométrica. A máquina de vetor de suporte treinada apresentou taxas de acerto superiores a 90% e 86% para treinamentos unilaterais e bilaterais, respectivamente. Já o modelo neural, treinado sempre com 10 épocas, foi capaz de acertar em mais de 77% das amostras para o treinamento unilateral, enquanto o treinamento bilateral apresentou acurácia superior a 96%.

Palavras-chave: redes de bragg; placa sensora; autenticação biométrica; rede neural convolucional; máquina de vetor de suporte.

ABSTRACT

This work presents the design, development, and results of a sensing board instrumented with fiber Bragg gratings, detailing the steps of fabrication and testing for the purpose of biometric authentication from the footstep patterns of users. The fiber Bragg gratings were encapsulated in acetic curing silicone and positioned in regions of the board to build sensing areas corresponding to the size of adult feet to allow data acquisition in a static regime. From the measured data, a system response model was developed, as well as a graphical representation through normalized pressure maps. Two pattern recognition models were also developed based on machine learning and deep learning techniques, generating a support vector machine model and a convolutional neural network capable of classifying different footstep patterns for biometric authentication purposes. The trained support vector machine achieved accuracy rates above 90% and 86% for unilateral and bilateral training, respectively. The neural model, always trained with 10 epochs, was able to get more than 77% of the samples correct for unilateral training, while bilateral training showed accuracy greater than 96%.

Keywords: fiber bragg grating; sensing board; biometric authentication; convolutional neural network; support vector machine.

LISTA DE FIGURAS

Figura 1 – Esquema de funcionamento de uma FBG.	23
Figura 2 – Mapa de dados e mapa de características.	27
Figura 3 – Rede neural convolucional com uma camada convolucional.	28
Figura 4 – Exemplo da operação de convolução.	29
Figura 5 – Classificação das redes quanto à conectividade.	30
Figura 6 – Exemplo da operação de <i>Max Pooling</i>	31
Figura 7 – Arquitetura da CNN Lenet-5.	33
Figura 8 – Representação da placa sensora com as localizações aproximadas de cada FBG.	38
Figura 9 – Foto da placa sensora após o término do processo de fabricação.	39
Figura 10 – Sistema de aquisição de dados da placa sensora.	39
Figura 11 – Representação do esquema para interrogação da placa sensora.	40
Figura 12 – Materiais acoplados ao pé de borracha para simular a pisada.	41
Figura 13 – Sistema com máxima aplicação de carga bilateral.	42
Figura 14 – Transformação do dado de comprimento de onda coletado em imagem.	45
Figura 15 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação de carga sobre a FBG 1.	47
Figura 16 – Curvas de resposta das FBGs para cargas aplicadas na FBG 1.	47
Figura 17 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação de carga sobre a FBG 8.	48
Figura 18 – Curvas de resposta das FBGs para cargas aplicadas na FBG 8.	48
Figura 19 – Espectros coletados para as FBGs da região do pé esquerdo em aplicação bilateral	51
Figura 20 – Espectros coletados para as FBGs da região do pé direito em aplicação bilateral	51
Figura 21 – Matriz de confusão dos dados de validação dos pés esquerdos - SVM.	53
Figura 22 – Matriz de confusão dos dados de validação dos pés direitos - SVM.	53
Figura 23 – Matriz de confusão dos dados de validação para a modelagem bilateral - SVM.	55

Figura 24 – Representação gráfica das respostas com aplicações unilaterais com os pés esquerdo 1 e direito 1.	57
Figura 25 – Representação gráfica das respostas para aplicações bilaterais com os pés esquerdo 1 e direito 1.	57
Figura 26 – Representação gráfica das respostas com aplicações unilaterais com os pés esquerdo 1 e direito 1 com baixa resposta acoplada nos lados em que não foram aplicadas cargas - dimensões $108 \times 108 \times 3$. Em (a), tem-se a aplicação apenas no pé esquerdo 1, e em (b), a aplicação apenas no pé direito 1.	58
Figura 27 – Matriz de confusão dos dados de validação do pé esquerdo - CNN.	59
Figura 28 – Matriz de confusão dos dados de validação do pé direito - CNN.	60
Figura 29 – Arquitetura de CNN <i>multi-input</i> para o caso bilateral.	61
Figura 30 – Matriz de confusão dos dados de validação do treinamento bilateral com CNN.	62
Figura 31 – Arquitetura de CNN <i>multi-input</i> para o caso bilateral após a técnica de ablação.	63
Figura 32 – Matriz de confusão dos dados de validação do treinamento bilateral com CNN - arquitetura após a técnica de ablação.	63
Figura 33 – Deslocamento de comprimento de onda no processo de aquecimento.	74
Figura 34 – Deslocamento de comprimento de onda no processo de resfriamento.	75
Figura 35 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 2.	77
Figura 36 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 3.	78
Figura 37 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 4.	79
Figura 38 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 5.	80
Figura 39 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 6.	81
Figura 40 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 7.	82

Figura 41 – Curvas de resposta das FBGs para cargas aplicadas na FBG 2.	83
Figura 42 – Curvas de resposta das FBGs para cargas aplicadas na FBG 3.	83
Figura 43 – Curvas de resposta das FBGs para cargas aplicadas na FBG 4.	84
Figura 44 – Curvas de resposta das FBGs para cargas aplicadas na FBG 5.	84
Figura 45 – Curvas de resposta das FBGs para cargas aplicadas na FBG 6.	85
Figura 46 – Curvas de resposta das FBGs para cargas aplicadas na FBG 7.	85
Figura 47 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 9.	86
Figura 48 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 10.	87
Figura 49 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 11.	88
Figura 50 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 12.	89
Figura 51 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 13.	90
Figura 52 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 14.	91
Figura 53 – Curvas de resposta das FBGs para cargas aplicadas na FBG 9.	92
Figura 54 – Curvas de resposta das FBGs para cargas aplicadas na FBG 10.	92
Figura 55 – Curvas de resposta das FBGs para cargas aplicadas na FBG 11.	93
Figura 56 – Curvas de resposta das FBGs para cargas aplicadas na FBG 12.	93
Figura 57 – Curvas de resposta das FBGs para cargas aplicadas na FBG 13.	94
Figura 58 – Curvas de resposta das FBGs para cargas aplicadas na FBG 14.	94

LISTA DE TABELAS

Tabela 1 – Periodicidade das máscaras de fase utilizadas e λ_B das FBGs gravadas.	36
Tabela 2 – Comprimentos de onda de Bragg das FBGs encapsuladas na placa.	38
Tabela 3 – Resposta relativa das FBGs comparativamente ao máximo desvio em comprimento de onda para FBGs do pé esquerdo.	49
Tabela 4 – Resposta relativa das FBGs comparativamente ao máximo desvio em comprimento de onda para FBGs do pé direito.	50
Tabela 5 – Precisão, sensibilidade e F1-Scores para os pés esquerdos - SVM.	54
Tabela 6 – Precisão, sensibilidade e F1-Scores para os pés direitos - SVM.	54
Tabela 7 – Precisão, sensibilidade e F1-Scores para a modelagem bilateral - SVM.	55
Tabela 8 – Precisão, sensibilidade e F1-Scores para os pés esquerdos - CNN.	60
Tabela 9 – Precisão, sensibilidade e F1-Scores para os pés direitos - CNN.	61
Tabela 10 – Precisão, sensibilidade e F1-Scores do treinamento bilateral - CNN.	62
Tabela 11 – Precisão, sensibilidade e F1-Scores do treinamento bilateral com CNN - arquitetura após ablação.	64
Tabela 12 – Diferença entre os F1-Scores para os pés esquerdos - SVM e CNN.	65
Tabela 13 – F1-Scores para cada os pés direitos - SVM e CNN.	65
Tabela 14 – F1-Scores para cada o caso bilateral - SVM e CNN.	66
Tabela 15 – F1-Scores para cada o caso bilateral - SVM e CNN após a ablação.	66

LISTA DE ABREVIATURAS E SIGLAS

Siglas

ArF	<i>Argon Fluoride</i>
CNN	Rede Neural Convolucional, do inglês <i>Convolutional Neural Network</i>
COP	Centro de Pressão, do inglês <i>Center of Pressure</i>
DL	Aprendizado Profundo, do inglês <i>Deep Learning</i>
FBG	Rede de Bragg em fibra ótica, do inglês <i>Fiber Bragg Grating</i>
FN	Falso Negativo, do inglês <i>False Negative</i>
FNR	Taxa de Falso Negativo, do inglês <i>False Negative Rate</i>
FP	Falso Positivo, do inglês <i>False Positive</i>
FPR	Taxa de Falso Positivo, do inglês <i>False Positive Rate</i>
FPS	Quadros por Segundo, do inglês <i>Frames per Second</i>
GEI	Imagem de Energia de Marcha, do inglês <i>Gait Energy Images</i>
HMM	Cadeias Escondidas de Markov, do inglês <i>Hidden Markov Model</i>
MDF	<i>Medium-Density Fiberboard</i>
ML	Aprendizado de Máquina, do inglês <i>Machine Learning</i>
MLP	Perceptron Multicamadas, do inglês <i>Multilayer Perceptron</i>
PCA	Análise de Componentes Principais, do inglês <i>Principal Component Analysis</i>
PNG	<i>Portable Graphics Format</i>
PPR	Taxa Preditiva Positiva, do inglês <i>Positive Predictive Rate</i>
RBF	Função de Base Radial, do inglês <i>Radial Basis Function</i>
ReLU	<i>Rectified Linear Unit</i>
RGB	<i>Red, Green and Blue</i>
RP	Reconhecimento de Padrão
RNA	Rede Neural Artificial

SLR	<i>Single Lens Reflex</i>
SVM	Máquina de vetor de suporte, do inglês <i>Support Vector Machine</i>
TP	Verdadeiro Positivo, do inglês <i>True Positive</i>
TPR	Taxa de Verdadeiro Positivo, do inglês <i>True Positive Rate</i>
TN	Verdadeiro Negativo, do inglês <i>True Negative</i>

LISTA DE SÍMBOLOS

Letras Latinas

n_{eff}	Índice de refração efetivo do núcleo
K	Dimensão do filtro
O	Dimensão da saída
P	Dimensão do <i>padding</i>
S	Dimensão do <i>stride</i>
W	Dimensão de entrada
H	Hiperplano
w	Vetor normal ao hiperplano
r	Distâncias entre o hiperplano e os pontos do espaço

Letras Gregas

Λ	Periodicidade espacial da rede de Bragg
λ_B	Comprimento de onda de Bragg
Λ_{pm}	Periodicidade espacial da máscara de fase
Φ	Margem da SVM <i>kernel</i>

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivações	17
1.2	Estado da arte	19
1.3	Objetivos	21
1.4	Estrutura do trabalho	22
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Redes de Bragg em Fibras Óticas	23
2.1.1	Condição de Bragg e princípio de funcionamento	23
2.1.2	Redes de Bragg em fibras óticas como sensores	24
2.2	Máquinas de vetores de suporte	25
2.2.1	Funções de Kernel	26
<u>2.2.1.1</u>	<u>SVM Linear</u>	<u>27</u>
2.2.2	SVM de base radial	27
2.2.3	SVM Polinomial	28
2.3	Redes Neurais Convolucionais	28
2.3.1	Camada convolucional	29
2.3.2	Camada de <i>Pooling</i>	31
2.3.3	Camada plenamente conectada	32
2.3.4	LeNet-5	32
2.4	Sistemas de reconhecimento biométrico	33
2.4.1	Arquitetura e métricas de avaliação	33
2.4.2	A pegada humana como elemento de reconhecimento biométrico	35
3	METODOLOGIA	36
3.1	Gravação das Redes de Bragg	36
3.2	Placa: Fabricação e Caracterização	37
3.2.1	Fabricação da placa sensora	37
3.2.2	Esquema para interrogação da placa sensora	38
3.2.3	Caracterização da placa sensora	39
<u>3.2.3.1</u>	<u>Teste com cargas localizadas</u>	<u>40</u>
<u>3.2.3.2</u>	<u>Testes com modelos de pé</u>	<u>40</u>

3.3	Sistema de autenticação biométrica de pisadas baseado em SVM	42
3.3.1	Organização dos dados	42
3.3.2	Método de classificação baseado em SVM	43
3.4	Sistema de autenticação biométrica de pisadas baseado em CNN	44
3.4.1	Geração de imagens de pressão	44
3.4.2	Rede neural convolucional	45
4	RESULTADOS	46
4.1	Caracterização da placa sensora	46
4.1.1	Teste com cargas localizadas	46
4.1.2	Teste com modelos de pé	50
4.2	Resultados SVM	52
4.2.1	Resultado unilateral - SVM	52
4.2.2	Resultado bilateral - SVM	54
4.3	Resultados CNN	56
4.3.1	Representação gráfica do sistema - imagens de pressão	56
4.3.2	Resultado unilateral - CNN	59
4.3.3	Resultado bilateral - CNN	59
4.3.3.1	Primeira arquitetura	60
4.3.3.2	Segunda arquitetura	62
4.4	Comparativo dos resultados unilaterais	64
4.5	Comparativo dos resultados bilaterais	65
5	CONCLUSÃO	67
5.1	Considerações	67
5.1.1	Trabalhos futuros	68
	REFERÊNCIAS	69
	APÊNDICES	72
	APÊNDICE A – TESTES DE TEMPERATURA COM $\Delta T = 3 \text{ }^\circ\text{C}$ APÓS O	
	ENCAPSULAMENTO DAS FBGS	74

APÊNDICE B – DESLOCAMENTO NO COMPRIMENTO DE ONDA DE BRAGG DAS FBGS QUANDO DA APLICAÇÃO COM AUMENTO GRADUAL DE CARGA SOBRE AS FBGS 2 À 7 E 9 À 14	77
APÊNDICE C – PUBLICAÇÕES RESULTANTES DESTE TRABALHO . . .	96

1 INTRODUÇÃO

1.1 Motivações

A necessidade de sistemas de reconhecimento individual cada vez mais exatos se justifica no acelerado crescimento populacional (KHOKHER; SINGH, 2021). Métodos tradicionais de identificação, como senhas, chaves físicas ou cartões são facilmente transferíveis, clonados ou roubados. Desta forma, sistemas de reconhecimento biométrico se apresentam como alternativas automáticas, seguras e de interação amigável com o usuário (JAIN; HONG; PANKANTI, 2000) em comparação aos métodos tradicionais, por se basearem em informações fisiológicas ou comportamentais do próprio indivíduo como forma de identificá-lo (NAGWANSHI, 2019), diminuindo o risco de fraude. Reconhecimento facial, por impressão digital, pela geometria da mão ou varredura da íris são exemplos de técnicas amplamente difundidas que consideram características biométricas fisiológicas e são presentes em aplicações comerciais (KUMAR *et al.*, 2014). Já entre as comportamentais, pode-se citar os métodos baseados na análise grafológica, da voz ou da marcha (KHOKHER; SINGH, 2021).

As informações obtidas na pegada de uma pessoa também podem ser elencadas como características biométricas, de maneira tanto fisiológica quanto comportamental. A depender do método de coleta dos dados, é possível extrair as impressões digitais, a textura da pele, o desenho do formato do pé ou mesmo a distribuição de pressão no momento da pisada e as características dos ciclos de marcha (KUMAR *et al.*, 2014)(LIU, 2017)(DHIR *et al.*, 2010). Para tal, os sistemas de captura de informação biométrica existentes para pegadas podem ser categorizados em dois tipos: sola ou placa. No primeiro caso, os sensores são embutidos no calçado do usuário, o que pode tornar o sistema de reconhecimento ainda mais complexo no que diz respeito à coleta e ao processamento dos dados, além de ser considerado uma limitação pelos próprios usuários (JUNG; SATO; BIEN, 2004). Já no tipo placa, costuma-se utilizar plataformas comerciais instrumentadas com malhas de sensores resistivos ou capacitivos (NAKAJIMA *et al.*, 2000), que exigem alta densidade de sensores e ocasionam interferência eletromagnética e ruídos nos sinais coletados e posteriormente processados. Uma alternativa reside na utilização de fibras óticas como elementos sensores.

Inicialmente desenvolvidas e aperfeiçoadas para aplicações restritas ao ramo das telecomunicações, as fibras óticas foram apresentadas à comunidade científica também como elementos sensores em 1967, por Menadier (MENADIER; KISSINGER; ADKINS, 1967). Nos anos seguintes, expandiu-se a variedade de técnicas de produção de sensores, bem como os campos de aplicação destes. A rede de Bragg em fibra ótica (FBG, do inglês *Fiber Bragg Grating*) se destaca entre os transdutores existentes, por aliar as vantagens inerentes ao meio de propagação (baixas perdas durante a propagação da luz, baixo peso, imunidade eletromagnética e possibilidade de multiplexação) à sensibilidade a variações de temperatura e pressão longitudinal. Isto a habilita a ser utilizada, por exemplo, em medições de variáveis químicas

(SHIVANANJU *et al.*, 2013), físicas (SAHOTA; GUPTA; DHAWAN, 2020) e biomecânicas (AL-FAKIH; OSMAN; ADIKAN, 2012), além de sistemas biométricos que mapeiam pontos de pressão durante uma pisada como característica biométrica para autenticação ou identificação dos usuários (KHOKHER; SINGH, 2021).

Na autenticação biométrica ou modo de verificação de usuário, os dados dos usuários são coletados e armazenados, formando um modelo de referência. Os dados fornecidos são comparados aos contidos no modelo de referência, resultando na autenticação ou não do usuário em questão. O objetivo da autenticação é garantir que aquele usuário é quem ele ou ela diz ser, evitando que múltiplos usuários façam uso de uma única identidade (DHIR *et al.*, 2010). Esse conceito pode ser aplicado em sistemas de liberação a acessos de compartimentos, de informações bancárias ou de registros de presença de funcionários. Já a identificação biométrica ou modo de identificação consiste na determinação da identidade do usuário. Com um banco de dados bem mais amplo, esta tecnologia captura informações biométricas do usuário e as compara com as outras informações de todos os indivíduos cadastrados no sistema. O propósito da identificação biométrica, por sua vez, é apontar quem é o indivíduo e evitar que um único usuário assuma diversas identidades (DHIR *et al.*, 2010). Para exemplificar uma situação de utilização da identificação biométrica, pode-se citar o interesse de agências governamentais ou particulares na determinação da identidade de pessoas que circulam em espaços públicos ou privados.

Em todos esses casos, o problema se concentra fundamentalmente no reconhecimento de padrões a partir dos dados coletados. É indispensável, portanto, que haja eficiência e rapidez no processamento destes dados, e que as informações sejam extraídas com exatidão. Em alguns trabalhos anteriores, as técnicas empregadas ora pecam pela simplicidade do algoritmo, retornando taxas de acerto consideradas baixas para aplicações práticas (NAKAJIMA *et al.*, 2000), ora pelas limitações experimentais (JUNG; SATO; BIEN, 2004) e pela necessidade de etapas de pré-processamento para normalização e aperfeiçoamento das imagens geradas que descaracterizam a identificação (KUMAR *et al.*, 2014).

Neste contexto, propõe-se um sistema de autenticação biométrica por reconhecimento de pisada do tipo placa instrumentado com sensores óticos baseados em FBG que utilize poucos elementos sensores para simplificar a aquisição de dados e velocidade de resposta. Busca-se aliar as vantagens das FBGs como elementos sensores para a obtenção de informações biométricas - o padrão de pressão plantar coletado estaticamente em uma pisada - às técnicas de processamento eficazes baseadas em aprendizagem profunda (DL, do inglês *Deep Learning*) e aprendizagem de máquina (ML, do inglês *Machine Learning*), resultando em um método que utiliza respostas acopladas dos sensores multiplexados, exige baixo pré-processamento e que, ainda assim, retorna altas taxas de reconhecimento em um tempo compatível com a aplicação.

1.2 Estado da arte

O primeiro sistema de reconhecimento biométrico data de 1858, quando Sir William Herschel (HERSCHEL, 1916) coletou imagens das mãos e dos dedos de trabalhadores indianos nos versos dos contratos de trabalho, para que não fosse possível fraudar a identidade destes no dia do pagamento. Daí em diante, o desenvolvimento de sistemas de reconhecimento biométrico foi se aperfeiçoando e expandindo não apenas as finalidades, mas também os tipos de informações coletadas para os devidos fins. Na primeira metade do século XX, o oftalmologista Frank Burch propôs o uso da íris como elemento de reconhecimento de um indivíduo. Alguns anos depois, em 1960, Gunnar Fant modelou acusticamente as componentes da voz (FANT, 1960). Estes estudos foram cruciais para o posterior desenvolvimento de sistemas automatizados de reconhecimento de pessoas, em especial no processo de correspondência entre as amostras biométricas. Outro dado contendo potenciais elementos biométricos, a pegada humana foi utilizada em 1996 no estudo de Kennedy (KENNEDY, 1996), que coletou impressões à tinta e extraiu características geométricas dos pés capazes de diferenciar indivíduos adultos, como localização dos dedos dos pés, largura do calcanhar e distância entre o centro do calcanhar e a cabeça do metatarso.

Uhl e Wild, em 2008 (UHL; WILD, 2008), acrescentaram às informações geométricas dos pés a extração de características da textura da pele da sola do pé, além da coleta das minúcias presentes nas impressões digitais dos dedos. As imagens coletadas a partir de um dispositivo de digitalização (HP 3500c) foram binarizadas e alinhadas quanto à rotação. Para cada atributo a ser reconhecido, como formato do pé, tamanho dos dedos e ângulos entre eles, minúcias do primeiro metatarso e projeção de pegadas no espaço dos componentes mais significativos (*eigenfeet*) foram utilizados diferentes classificadores - baseados em distância entre coordenadas ou distância euclideana, por exemplo - e em seguida calculou-se a taxa de acerto para cada caso. Para além das possíveis combinações de atributos, analisando individualmente o desempenho dos classificadores, a menor taxa de erro foi alcançada com a aplicação de distância entre coordenadas na *eigenfeet* resultando em taxa de falso positivo de 2,52% e taxa de falso negativo de 2,18%.

No trabalho de Balameenkashi (BALAMEENAKSHI; SUMATHI, 2013), as impressões coletadas dos pés serviram como parâmetro de identificação de recém-nascidos, com o auxílio do MATLAB e de Labview para processamento e análise dos dados. A coleta foi feita com uma câmera digital SLR (do inglês *Single Lens Reflex*), da qual as imagens capturadas passaram por pre-processamentos, que vão desde a aplicação de filtros à segmentação em escala de cinza, para posterior extração de características empregadas em um algoritmo de correspondência de padrões. Das 200 amostras de teste, 130 foram corretamente classificadas conforme o *threshold* definido pelo modelo. Ainda que a taxa de acerto (65%) seja bem superior aos outros métodos citados no trabalho (de 1% a 20%), o desempenho do método foi prejudicado pela forma como os dados foram coletados e pelo baixo número de amostras.

Keatsamarn (KEATSAMARN *et al.*, 2021) e seus colaboradores projetaram uma plataforma para coleta de pressão plantar baseada em um sistema ótico composto por uma câmera digital, uma placa metálica, tiras de LED e papel branco brilhante. O sistema proposto é capaz de fornecer recursos dinâmicos e estáticos sobre a marcha humana e, a partir da combinação desses atributos, os autores calcularam a medida de similaridade, obtendo 98,515% de eficiência.

Partindo para o uso de plataformas comerciais instrumentadas com sensores de pressão, no começo dos anos 2000, Nakajima e seus colaboradores (NAKAJIMA *et al.*, 2000) fizeram uso da plataforma BIG-MAT (Niita Inc.), instrumentada com sensores resistivos, para obtenção de imagens de pegadas de 10 indivíduos. Uma vez pré-processadas e normalizadas, essas pegadas serviram como entrada de um método estatístico de reconhecimento que considerou dois parâmetros: a distância entre os centros de massa e o ângulo formado entre as imagens dos pés direito e esquerdo.

Posteriormente, estudos como o de Jung *et al.* (JUNG; SATO; BIEN, 2003) começaram a investir em técnicas mais elaboradas para o tratamento de dados. Neste caso, sensores de pressão resistivos embutidos em um sapato mediram a origem da força de reação do solo resultante do contato do pé com o solo, quando o indivíduo está ereto. A esta posição, dá-se o nome de centro de pressão (COP, do inglês *center of pressure*). Os dados coletados pelos sensores foram discretizados, passando por um processo de quantização, e em seguida uma técnica baseada em cadeias escondidas de Markov (HMM, do inglês *Hidden Markov Model*) foi capaz de identificar 5 indivíduos com 100% de exatidão. Contudo, o estudo aponta duas limitações preponderantes: primeiramente, os usuários relataram desconforto ao usar o calçado instrumentado com os sensores; além disso, todos os dados foram coletados em um único dia, implicando em alta correlação. No mesmo ano, Jung e seus colaboradores (JUNG *et al.*, 2003) também recorreram a HMM para identificar 8 indivíduos a partir da quantização do centro de pressão. Neste trabalho, os autores combinaram HMM com o método de aprendizagem Levenberg-Marquardt para melhorar o desempenho do sistema, mas a taxa de acerto de 64%, além de não ser alta o suficiente, não foi igualmente distribuída entre os indivíduos.

Já em 2004, o mesmo autor e sua equipe (JUNG; SATO; BIEN, 2004) novamente utilizaram HMM, mas desta vez aliada a uma rede neural, para identificar 11 indivíduos em regime dinâmico a partir da coleta da trajetória do centro de pressão dos usuários durante a marcha destes. A taxa de acerto de 80% ainda foi considerada insuficiente para aplicações práticas, além de, entre as arquiteturas testadas, a que resultou em maior taxa de acerto foi a mais complexa, que exigiu 5 estágios de HMM, para só então partir para a tomada de decisão final com a rede neural.

Para além das HMMs, as CNNs também têm sido aplicadas com a finalidade de auxiliar o reconhecimento biométrico a partir da pegada humana. No estudo de Takemura e seus colaboradores (TAKEMURA *et al.*, 2019) obtiveram a taxa de acerto de 91,9% ao empregarem a arquitetura de redes Siamesas, na qual duas redes compartilham pesos entre si e as saídas

são comparadas quanto à similaridade. O conjunto de dados *Multi-view Large Population*, pertencente ao banco de dados OU-ISIR (MAKIHARA *et al.*, 2012), é composto de imagens de energia de marcha (GEIs, do inglês *Gait Energy Images*), capturadas por 7 câmeras a 25 fps (*frames per second*) e com dimensões 1280×980 pixels.

Ainda do mesmo banco de dados, porém do conjunto de dados *Large Population*, cujas imagens de dimensões 640×480 pixels foram obtidas a partir de fotografias coletadas de duas câmeras fotográficas a 30 fps (*frames per second*), Shiraga e seus colaboradores (SHIRAGA *et al.*, 2016) propuseram o uso da rede neural convolucional GEINet. A estrutura dessa rede se assemelha à da LeNet-5 por também ser composta por duas sequências de camadas convolucionais e de *pooling*. A taxa de acerto obtida foi de 91,5%.

Neste contexto, o presente trabalho pretende contribuir para a área de autenticação biométrica de humanos através de medidas de pressão plantar utilizando redes de Bragg combinadas a métodos de aprendizagem de máquina, tais que máquina de vetor de suporte e rede neural convolucional.

1.3 Objetivos

O objetivo geral deste trabalho é o desenvolvimento de uma placa sensora instrumentada com redes de Bragg em fibras óticas que, por meio de uma coleta estática de dados, seja capaz de distinguir indivíduos a partir de mapas de pressão plantar obtidos. Para isto, foram traçados os seguintes objetivos específicos:

- Fabricar uma placa sensora instrumentada com FBGs;
- Caracterizar esta placa quanto a resposta a pressões conhecidas aplicadas sobre a sua superfície;
- Submeter a placa a distribuições distintas de pressão plantar correspondentes a pisadas de diferentes indivíduos;
- Modelar o problema para possibilitar a classificação de indivíduos a partir dos dados de pressão plantar coletados no sistema;
- Construir e treinar algoritmos baseados em *machine learning* e *deep learning* para a solução de um problema de classificação que objetiva autenticar indivíduos a partir de pressões plantares;
- Testar e validar o sistema desenvolvido.

1.4 Estrutura do trabalho

Este documento está dividido em quatro capítulos. O primeiro é dedicado à contextualização do trabalho, informando ao leitor as motivações, o estado da arte e os objetivos. No segundo capítulo, tem-se a fundamentação teórica necessária à compreensão do projeto em andamento. No terceiro capítulo, apresenta-se a metodologia de fabricação do sistema sensor, bem como os algoritmos e técnicas de coleta e tratamento dos dados. No quarto capítulo, os resultados obtidos e as discussões acerca destes. Por fim, o quinto e último capítulo discute as conclusões e os possíveis trabalhos futuros.

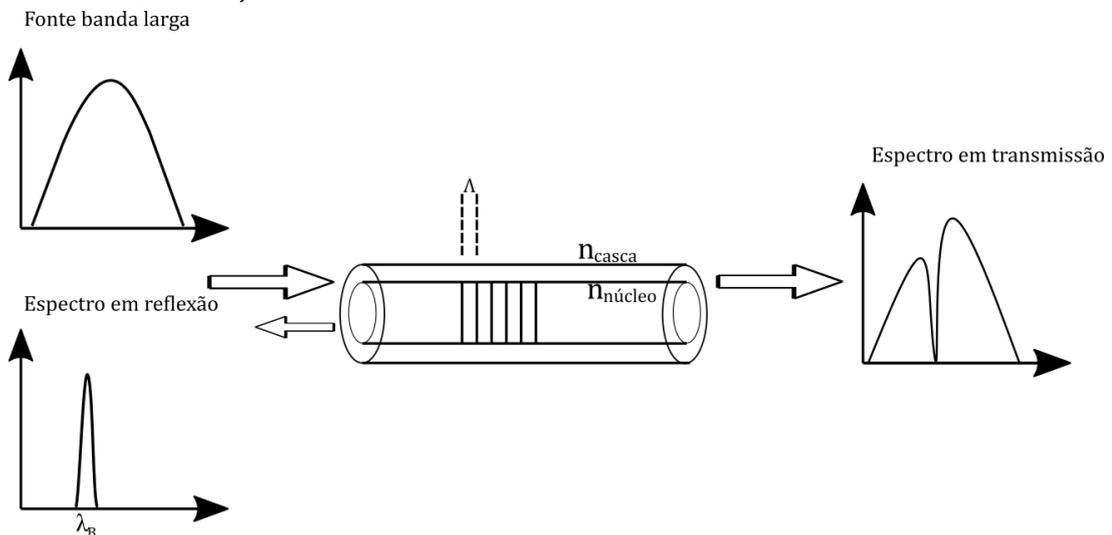
2 FUNDAMENTAÇÃO TEÓRICA

2.1 Redes de Bragg em Fibras Óticas

2.1.1 Condição de Bragg e princípio de funcionamento

As fibras óticas, graças à fotossensibilidade, permitem que redes de difração sejam fabricadas no interior da sua estrutura. Tais redes de difração são formadas por meio de uma alteração periódica no índice de refração do núcleo da fibra. Os comprimentos de onda refletidos nas interfaces entre as regiões com diferentes índices de refração, que satisfazem a condição de Bragg, interferem construtivamente resultando em bandas estreitas de reflexão. A condição de Bragg de primeira ordem, Eq. 1, fornece uma banda de reflexão centrada no comprimento de onda de Bragg (λ_B). Para as frequências que não satisfazem a Eq. 1, a luz é refletida fora de fase e, conseqüentemente, ocorre interferência destrutiva (OTHONOS; KALLI, 1999). Portanto, quando a luz de uma fonte de banda larga que se propaga na fibra encontra a FBG, esta atua como um filtro seletivo e uma faixa estreita de comprimentos de onda em torno de λ_B é refletida, e o restante é transmitido. A Figura 1 mostra o mecanismo de funcionamento de uma FBG.

Figura 1 – Esquema de funcionamento de uma FBG: a luz da fonte de banda larga propaga pela fibra e, no espectro de reflexão, observa-se o pico centrado em λ_B . No espectro de transmissão, a banda de entrada é decrescida da faixa refletida.



Fonte: Autoria própria.

Na equação da condição de Bragg de primeira ordem (Eq. 1), é possível observar que λ_B depende da periodicidade espacial da rede (Λ), também referenciada como *pitch*, e do índice de refração efetivo do núcleo para os modos propagante e contrapropagante (n_{eff}).

$$\lambda_B = 2\Lambda n_{eff} \quad (1)$$

Esta condição deriva das leis de conservação de energia e de momento da onda. Para a conservação de energia, é necessário que tanto a radiação incidente quanto a refletida tenham a mesma frequência. Já para a conservação do momento de onda, a soma dos vetores de onda das radiações incidente e da rede deve ser igual ao vetor da radiação difratada.

2.1.2 Redes de Bragg em fibras óticas como sensores

Tanto deformações mecânicas quanto variações de temperatura afetam diretamente os parâmetros n_{eff} e Λ de uma rede de Bragg, causando mudanças em λ_B (KERSEY, 1996). A sensibilidade a estes dois efeitos é identificada na Eq. 2:

$$\Delta\lambda_B = 2\left(\Lambda \frac{\partial n_{eff}}{\partial l} + n_{eff} \frac{\partial \Lambda}{\partial l}\right)\Delta l + \left(\Lambda \frac{\partial n_{eff}}{\partial T} + \frac{\partial \Lambda}{\partial T}\right)\Delta T \quad (2)$$

O primeiro termo identifica a sensibilidade à deformação mecânica longitudinal. Nele, observa-se que o índice de refração efetivo do núcleo varia com a distensão ($\frac{\partial n_{eff}}{\partial l}$) - o efeito elasto-ótico. O *pitch* também sofre mudanças, de acordo com $\frac{\partial \Lambda}{\partial l}$. O segundo termo indica a sensibilidade às variações da temperatura e é constituído pela soma de dois fatores: o efeito termo-ótico ($\frac{\partial n_{eff}}{\partial T}$) e o de expansão térmica ($\frac{\partial \Lambda}{\partial T}$).

Qualquer variação nestes parâmetros ocasiona a variação do comprimento de onda de Bragg. Sendo assim, redes de Bragg funcionam como sensores intrínsecos de temperatura e deformação. Portanto, perturbações mecânicas como curvaturas, deformações longitudinais ou tensões transversais podem ser detectadas e mensuradas quando associadas ao desvio do comprimento de onda de Bragg.

Da Eq. 2 também se observa que se as duas parcelas, referentes à deformação mecânica longitudinal e temperatura, são não-nulas e ocorrem simultaneamente, ocorre uma sensibilidade cruzada. Em aplicações de sensoriamento é interessante que esse efeito seja avaliado, caso contrário não é possível afirmar que a variação no comprimento de onda ($\Delta\lambda_B$) é decorrente de uma ou de outra parcela. Caso o sensoriamento seja relacionado a deslocamentos provenientes de deformações mecânicas, diversas técnicas já foram desenvolvidas para mensurar ou compensar os efeitos da temperatura, como a utilização de duas redes de Bragg idênticas sob as mesmas condições térmicas, sendo uma delas servindo como referência para a suposta variação de temperatura (PEREIRA, 2003). Outras opções residem no encapsulamento em polí-

meros que revelem as sensibilidades aos parâmetros individualmente (LU; MEN; CHEN, 2008), ou mesmo o controle de temperatura do ambiente.

Além de possuírem baixo peso e serem imunes à interferência eletromagnética, FBGs podem ser multiplexadas em divisão de comprimento de onda ou de tempo, por exemplo. Esta capacidade de multiplexação em série habilita as redes de Bragg para uso em monitoramentos *quasi*-distribuídos, onde é possível medir-se ao longo de uma linha em pontos pré-estabelecidos, expandindo o limite do número de sensores em um segmento contínuo de fibra. Ademais, há a necessidade de somente uma fonte para todas as FBGs contidas no fragmento de fibra, reduzindo os custos do sensoriamento.

Destacando ainda a aplicação como sensor de deformação, um fator adicional capaz de aumentar a gama de aplicações é o encapsulamento desses dispositivos. A depender do material encapsulante, pode-se, por exemplo, fornecer maior resistência mecânica às FBGs, bem como favorecer o acoplamento ou o isolamento da resposta à pressão exercida. Também é possível isolá-las termicamente, anulando o efeito da sensibilidade cruzada, ou alterar a sensibilidade às deformações (NEDOMA *et al.*, 2016).

2.2 Máquinas de vetores de suporte

Máquinas de vetores de suporte (SVM, do inglês *Support Vector Machine*) são algoritmos de aprendizagem de máquina supervisionado, que podem atuar em problemas de classificação ou regressão (ABE, 2005). Enquanto problemas de regressão buscam prever um valor numérico específico a partir de mapeamentos entrada-saída, os problemas de classificação buscam agrupar os dados de acordo com características em comum. Quando a aprendizagem é dita supervisionada, a modelagem fornece previamente as classes desejadas.

Problemas de classificação são resolvidos por SVM a partir da construção do hiperplano que melhor diferencia as classes, representadas por pontos no espaço n -dimensional, onde o vetor de suporte é a fronteira que melhor segrega as classes. Para defini-lo, resolve-se um problema de otimização por maximização de margem e de minimização de erros (SCHÖLKOPF; SMOLA, 2002).

Considerando o hiperplano H , os pontos que a ele pertencem satisfazem a equação $w \cdot x + b$, sendo w o vetor normal a H . Sendo r^+ e r^- as distâncias entre H e os pontos positivo e negativo mais próximos, define-se uma margem. O hiperplano ótimo H_0 a ser calculado pela SVM, portanto, é definido por w_0 e b_0 para a maior margem $\phi(w) = r^+ + r^-$. Para H_0 , r^+ e r^- são iguais a $\frac{1}{\|w\|}$, consequentemente a margem a ser maximizada é igual a $\frac{2}{\|w\|}$, o que equivale a minimizar $\frac{1}{2}w^t w$ sujeito à condição $y_i(w x_i + b) \geq 1$ para todo i , onde todos os padrões sejam corretamente classificados. Depara-se então com um problema de otimização quadrática, que pode ser resolvido com algoritmos complexos, ou com a introdução de um multiplicador de

Lagrange para cada condição, de forma que:

$$L(w,b,a) = \frac{1}{2}w^t w - \sum_{i=1}^N \alpha_i [y_i(w^t x_i + b) - 1] \quad (3)$$

Derivando $L(w,b,a)$ em função de W e de b , a função final de classificação é do formato $f(x) = \sum \alpha_i y_i x_i^T x + b$ e depende diretamente do cálculo do produto interno entre todos os pontos dos vetores de entrada.

2.2.1 Funções de Kernel

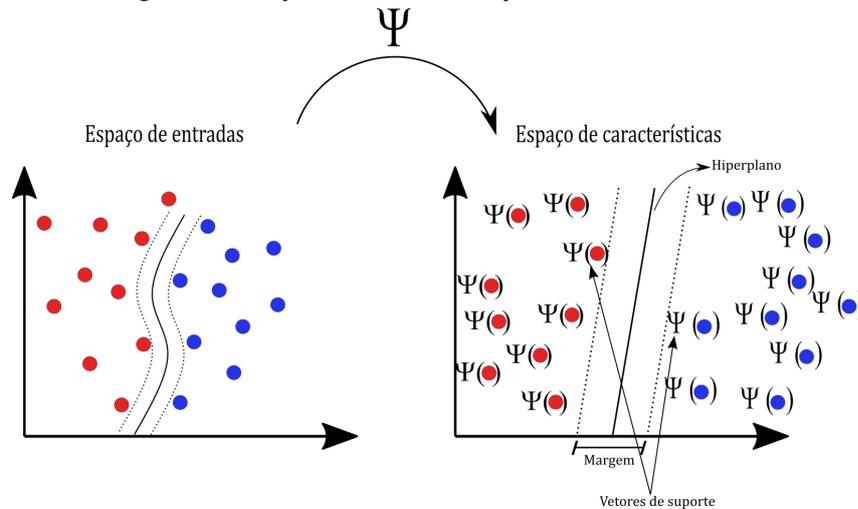
Para a maioria dos casos em que a modelagem do problema lida com dimensões maiores, não é possível traçar hiperplanos. Utilizam-se, então, funções que transformam o espaço dimensional dos dados para um espaço dimensional superior, convertendo o problema não-separável em um problema separável (ABE, 2005). Estas funções recebem o nome de funções de Kernel, que devem preencher alguns requisitos, dentre os quais:

- Satisfação à inequação de Cauchy-Scharwz: a condição matemática na qual o produto interno entre dois vetores deve ser menor ou igual ao produto entre as normas destes vetores ($|\langle u,v \rangle| \leq \|u\| \|v\|$) é relevante para evitar que pontos muito afastados ou com normas grandes influenciem na separação dos dados.
- Satisfação ao teorema de Mercer: o teorema aponta que a função de Kernel deve ser simétrica e positiva definida. A simetria indica que para quaisquer dois pontos, a ordem em que são fornecidos não deve influenciar no valor do kernel. Já a positividade definida diz que a matriz de similaridade deve ser semidefinida positiva. Com isso, garante-se a existência de uma solução única e ótima que melhor separa as classes, incluindo a possibilidade de funções de kernel não-lineares.

Funções de kernel podem ser obtidas a partir da combinação de outros kernels ou, ainda, a partir de características. As quantidades introduzidas para descrever os dados são geralmente chamadas de características, enquanto as quantidades originais são chamadas de atributos. A tarefa de escolher a representação mais adequada é conhecida como seleção de características (VAPNIK, 1995). O espaço X é referido como o espaço de entrada, enquanto $F = \Phi(x) : x \in X$ é chamado o espaço de características:

É possível classificar uma SVM a partir do tipo de função de kernel utilizada. Alguns exemplos de funções de kernel comumente utilizadas em SVM são: linear, RBF (do inglês *radial basis function*) ou polinomial.

Figura 2 – Mapa de dados e mapa de características.



Fonte: Autoria própria.

2.2.1.1 SVM Linear

Uma SVM linear utiliza funções lineares para separar os hiperplanos dos mapas de características (features). Aplica-se uma função linear aos dados que extrai deles as características que irão compor o mapa de características, conforme representado na Figura 2.

A equação que caracteriza um SVM linear é do tipo:

$$K(x_i, x_k) = \langle x_i, x_k \rangle \quad (4)$$

Sendo x_i, x_k os vetores de entrada e $\langle x_i, x_k \rangle$ o produto interno entre eles.

2.2.2 SVM de base radial

A função de kernel de base radial é definida como:

$$K(x_i, x_k) = e^{(-\gamma \|x_i - x_k\|^2)} \quad (5)$$

Onde $\|x_i - x_k\|^2$ é o quadrado da distância euclidiana entre os vetores de entrada, de forma que quanto maior for esse valor, mais a função radial decai. Já o parâmetro γ define a área de influência da função radial. Valores muito altos de γ levam ao *underfitting* por aproximarem o kernel a uma função constante. Contudo, valores muito baixos resultam em *overfitting* do modelo por aproximar o kernel a uma matriz identidade, onde cada entrada está associada a uma só saída (SHAWE-TAYLOR; CRISTIANINI, 2004).

2.2.3 SVM Polinomial

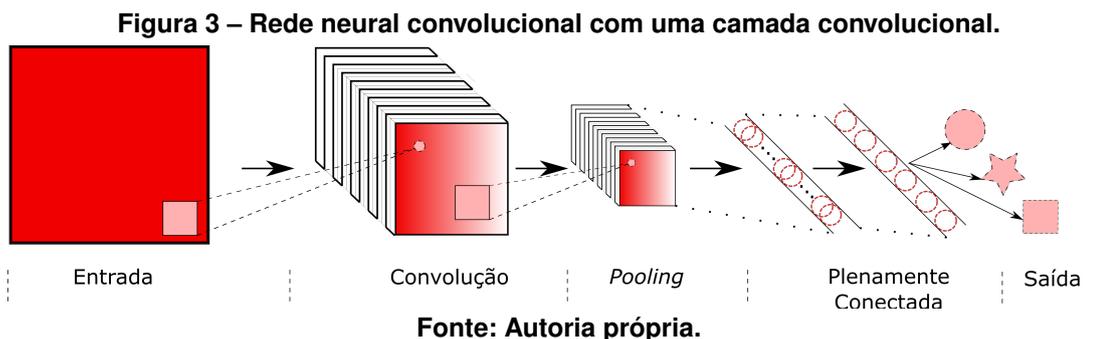
Para este tipo específico de SVM, o Kernel assume formato polinomial (Eq. 6):

$$K(x_i, x_k) = (1 + \langle x_i, x_k \rangle)^p \quad (6)$$

Onde p é a ordem do polinômio. Quanto maior o valor de p , mais complexa é a transformação não-linear, permitindo a criação de superfícies de separação mais flexíveis no espaço de características (*feature map*).

2.3 Redes Neurais Convolucionais

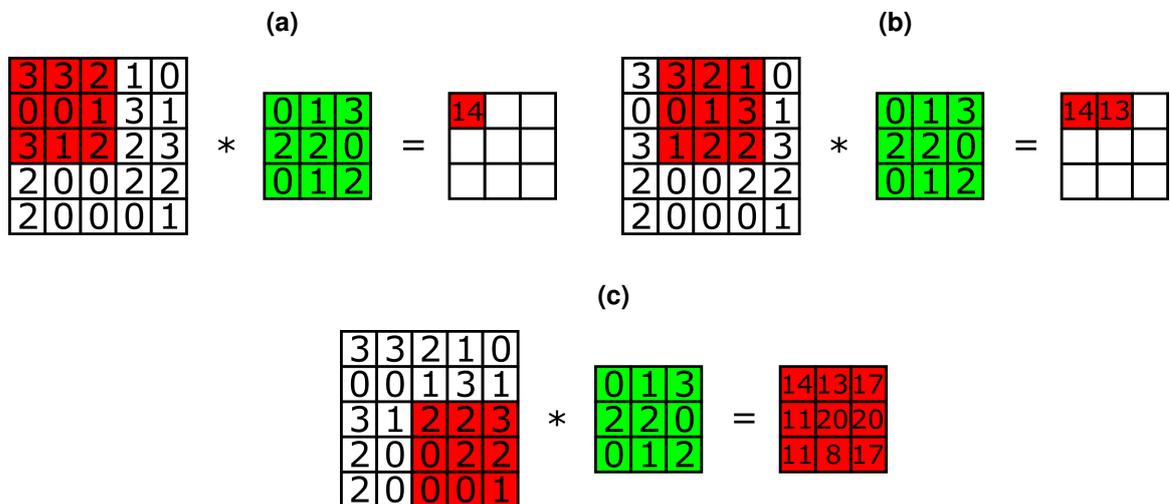
As redes neurais artificiais multicamadas se inspiram na organização do córtex visual, onde células são classificadas entre simples e complexas, a depender do estímulo recebido (HUBEL; WIESEL, 1962)(HUBEL; WIESEL; LEVAY, 1977). As respostas aos estímulos são combinadas para gerar a percepção visual. Redes neurais convolucionais (CNN, do inglês *convolutional neural network*) diferem das RNAs (redes neurais artificiais) tradicionais, como o Perceptron ou a MLP (do inglês *multilayer Perceptron*), por possuírem várias camadas cujos neurônios não estão plenamente conectados aos da camada adjacente. Além disso, enquanto nas redes neurais convolucionais, cada camada possui funções distintas entre si, em uma MLP todas as camadas executam a mesma função. A facilidade para o treinamento a partir de um grande número de amostras, a capacidade de extração de características a partir de operações matemáticas, bem como a necessidade de pouco pré-processamento dos dados de entrada, tornam as CNNs uma opção mais viável em relação a outros métodos de classificação existentes. Estruturalmente, a CNN é composta por camadas convolucionais, camadas de subamostragem com funções de ativação não-lineares, e camadas totalmente conectadas. Em linhas gerais, a camada convolucional extrai os mapas de características da imagem de entrada, que servem de entrada para as camadas de subamostragem (*Pooling*). A saída da camada de *Pooling*, por sua vez, serve como entrada da camada plenamente conectada cuja saída é o resultado da classificação. Cada camada será explicada em mais detalhes nos subtópicos a seguir.



2.3.1 Camada convolucional

Esta camada é responsável pela extração de características (*features*) da imagem de entrada a partir da aplicação de filtros, que correspondem a um subconjunto da entrada que desliza pela imagem a procura de um padrão específico. Os filtros aplicados são chamados de *kernel*. O termo, embora já mencionado anteriormente no contexto de SVMs, nesta aplicação se refere a uma operação e a uma aplicação de outra natureza. Calcula-se repetidamente o produto interno entre os filtros e os subconjuntos da imagem até que toda a extensão da imagem de entrada seja percorrida. Ao somatório destes produtos internos dá-se o nome de **convolução**. Esta operação é definida como a aplicação de um filtro linear a uma imagem de entrada, fornecendo como saída um mapa de características. Para uma mesma imagem de entrada, podem existir várias características detectadas a partir de sucessivas convoluções. O que difere as saídas das convoluções é, portanto, o filtro aplicado. Um exemplo da operação de convolução realizada em uma imagem 2D está ilustrado na Figura 4. As regiões destacadas em vermelho nas imagens de entrada são chamadas de campos receptivos locais, e cada subconjunto 3×3 obtido pelo deslocamento da janela alimenta um neurônio na camada de *pooling* seguinte.

Figura 4 – Operação de convolução em uma imagem de entrada 5×5 , com um filtro 3×3 e *stride* igual a 1. As operações em cada campo receptivo local alimentam um neurônio na camada escondida. Em (a), (b) e (c), é visualizam-se o primeiro, segundo e último campos receptivos locais, respectivamente.



Fonte: Autoria própria.

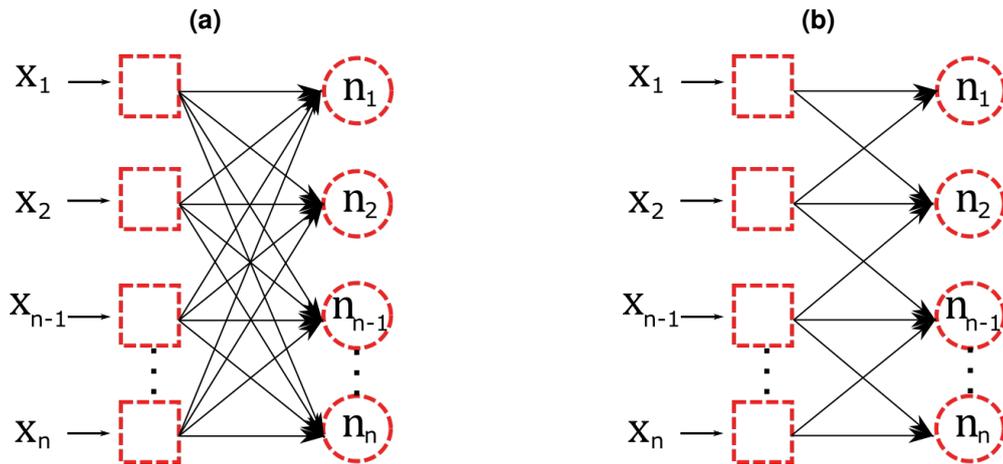
O cálculo para chegar ao valor da matriz resultante na Figura 4a foi: $(3 \times 0) + (3 \times 1) + (2 \times 3) + (0 \times 2) + (0 \times 2) + (1 \times 0) + (3 \times 0) + (1 \times 1) + (2 \times 2) = 14$.

Já para a Figura 4b, efetuou-se: $(3 \times 0) + (2 \times 1) + (1 \times 3) + (0 \times 2) + (1 \times 2) + (3 \times 0) + (1 \times 0) + (1 \times 2) + (2 \times 2) = 13$.

De modo que, ao término da 9ª operação, a operação de convolução se completa e a matriz resultante é mostrada na Figura 4c.

Como um neurônio se conecta apenas a uma região da camada de entrada, diz-se que há conectividade local. Na conectividade global, observada em redes MLP, um único parâmetro da camada em questão se relaciona com todos os outros da camada subsequente (Figura 5).

Figura 5 – Classificação das redes quanto à conectividade. Em (a) tem-se a conectividade global, observada em redes MLP, na qual os neurônios de uma camada se relacionam com todos os outros neurônios da camada seguinte. Em (b) tem-se a conectividade local, observada em redes neurais convolucionais, cujos neurônios de uma camada se relacionam apenas com alguns neurônios da camada seguinte.



Fonte: Autoria própria.

A conectividade local dos neurônios leva a outra característica importante na camada convolucional: o compartilhamento dos pesos e dos *bias*. Ao deslizar por toda a imagem, o filtro aplicado detecta a mesma característica em partes diferentes da imagem. Um detector de bordas ou de manchas de cores, por exemplo, será aplicado na imagem inteira em forma de filtro, com um passo de deslizamento (também chamado de *stride*) determinado pelo projetista da rede. A saída desse processo será um mapa de atributos com pesos (um para cada neurônio) e *bias* (um para cada mapa de atributos) compartilhados. Conseqüentemente, a atualização desses parâmetros com o algoritmo de *backpropagation* ocorre de maneira mais rápida, se comparada a uma rede com todas as camadas plenamente conectadas.

As dimensões dos filtros são ajustadas automaticamente durante o treinamento da rede, para que eles sejam capazes de detectar características discriminadoras das imagens. Sendo assim, se um filtro possui inicialmente dimensões muito grandes e ignora as características da imagem, classificando-a erroneamente, na próxima iteração o algoritmo diminui suas dimensões e o torna mais preciso quanto à identificação dessas características (*features*). As dimensões dos mapas de atributos (profundidade, largura e altura) dependem de 3 fatores: largura e altura dependem do *stride*, já citado anteriormente, e do *zero padding* - técnica que completa a imagem convoluída com zeros nas bordas, até que a dimensão seja igual à da imagem de entrada. Já a profundidade depende da quantidade de *features* observadas, sendo equivalente ao número de filtros. Como cada imagem geralmente possui mais de uma característica que

permite identificá-la, uma única camada convolucional geralmente resulta em mais de um mapa de atributos. A largura e a altura dos mapas de atributos são calculadas segundo a Eq. 7:

$$O_{conv} = \frac{W_{conv} - K_{conv} + 2P_{conv}}{S_{conv}} + 1 \quad (7)$$

Onde O_{conv} é a dimensão da saída (largura ou altura), W_{conv} é o tamanho da entrada, K_{conv} é o tamanho do filtro, P_{conv} é o *padding* e S_{conv} o *stride*.

A última etapa de processamento da camada convolucional consiste em submeter o mapa de características obtido a uma função de ativação, normalmente a ReLU (do inglês *Rectified Linear Unit*):

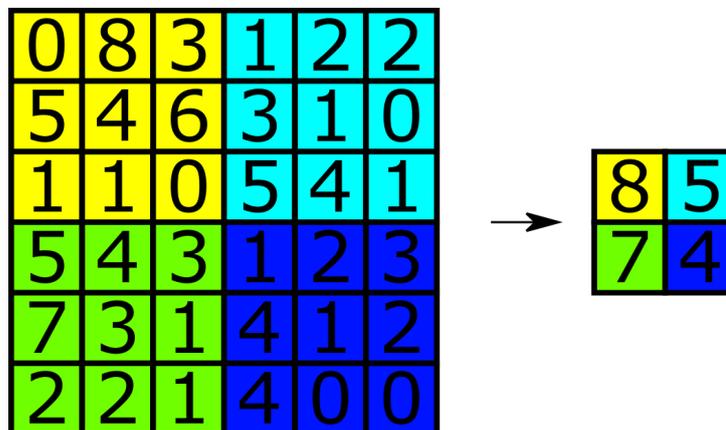
$$\varphi(x) = \max(x, 0) \quad (8)$$

Essa função não-linear retorna valor nulo para os casos em que o neurônio permanece inativo, e mantém os valores positivos sem modificá-los, para qualquer entrada diferente de zero.

2.3.2 Camada de *Pooling*

A tarefa da etapa seguinte consiste na redução do tamanho das imagens de entrada por meio de subamostragem. Este processo, denominado de *pooling*, além de diminuir o custo computacional do processamento e evitar o sobre-treinamento (GOODFELLOW; BENGIO; COURVILLE, 2016), reduz a sensibilidade a variações que distorçam a imagem: rotação, translação e deslocamentos (*shifting*). Assim, um mesmo atributo pode ser reconhecido em qualquer posição da imagem. Dentre os tipos de *pooling*, o mais utilizado é o *max-pooling* (GOODFELLOW; BENGIO; COURVILLE, 2016), no qual, para uma janela seleciona-se o maior valor, conforme a Figura 6:

Figura 6 – Operação de *Max Pooling*, com entrada de dimensões 6×6 , *kernel* de 3×3 e *stride* igual a 3.



Fonte: Autoria própria.

A imagem de saída da camada de *pooling* terá dimensões:

$$O_{pool} = \frac{W_{pool} - K_{pool}}{S_{pool}} + 1 \quad (9)$$

Analogamente aos termos da Eq. 7, O_{pool} corresponde às dimensões da imagem resultante, W_{pool} representa as dimensões da imagem de entrada, K_{pool} e S_{pool} são os tamanhos do filtro e do *stride*, respectivamente. No exemplo representado na Figura 6, $W_{pool} = 6$, $K_{pool} = 3$ e $stride = 3$, resultando em $O_{pool} = 2$.

2.3.3 Camada plenamente conectada

Ao fim do processamento ocorrido na camada de *Pooling*, as características da imagem estão disponíveis para a separação em classes pré-determinadas. Uma CNN pode apresentar vários blocos de camadas convolucionais seguidas por camadas de pooling, até que se chegue às camadas plenamente conectadas que realizam a classificação propriamente dita da entrada. Nesta fase final, a estrutura é semelhante a uma MLP, onde todos os neurônios de uma camada se conectam aos da camada posterior. O número de neurônios da última camada plenamente conectada indica o número de classes do modelo, e a função de ativação desta camada é uma *softmax*, uma generalização da função sigmoide que produz valores no intervalo entre 0 e 1 onde a soma é igual a 1, e cada valor representa a probabilidade de cada elemento pertencer a uma das classes.

Conhecidas a visão geral da estrutura de uma CNN e as particularidades das suas componentes, será apresentada agora a arquitetura que serviu de base para este trabalho: a LeNet-5.

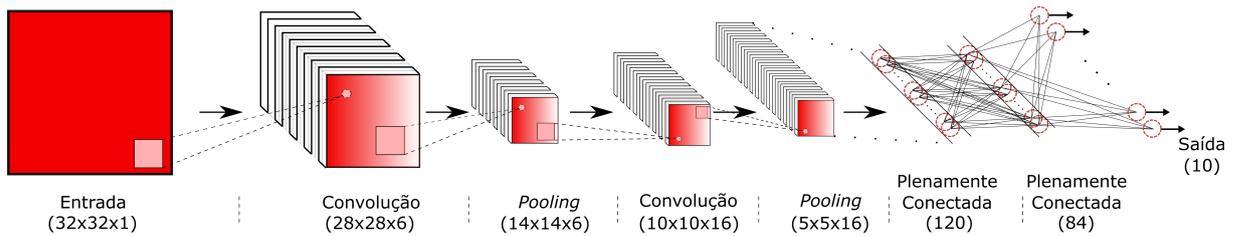
2.3.4 LeNet-5

A LeNet-5 é um dos modelos pioneiros de redes neurais convolucionais. A arquitetura original é composta por 7 camadas, sendo 3 delas convolucionais, 2 de *Pooling* e 2 plenamente conectadas, como mostra a Figura 7. A imagem de entrada é previamente normalizada, e a saída é a probabilidade desta imagem pertencer a uma das classes previamente fornecidas. Desenvolvida por Lecun *et al.* (1998), inicialmente para reconhecer caracteres numéricos, ainda é vastamente empregada para reconhecimento e classificação de padrões em diversas áreas, como na arquitetura (CAI; LI, 2021) e no reconhecimento de emoções pelas expressões faciais (LIN *et al.*, 2019), mudando-se alguns parâmetros como dimensões dos filtros ou a função de ativação da camada plenamente conectada.

No modelo original desenvolvido por Lecun e colaboradores, as imagens de entrada possuíam dimensões $32 \times 32 \times 1$, a primeira camada convolucional gerava 6 *feature maps* de dimensões 28×28 , seguida pela primeira camada de subamostragem, que reduzia as dimen-

sões para 14×14 . A segunda camada convolucional gera 16 mapas de características com dimensões 10×10 , sucedida pela segunda camada de *Pooling* com 16 matrizes 5×5 . A última camada convolucional possui como saída 120 *feature maps*, que são conectados a duas camadas plenamente conectadas: a primeira com 84 neurônios, e a segunda com 10 neurônios, correspondentes às 10 classes do modelo - os algoritmos de 0 a 9.

Figura 7 – Arquitetura da CNN Lenet-5, desenvolvida por Lecun et al.(LECUN *et al.*, 1998), e que serviu de modelo para este trabalho.



Fonte: Autoria própria.

No problema modelado neste trabalho, a estrutura com as camadas convolucionais e de subamostragem permanecem iguais, variando apenas as dimensões das imagens de entrada e dos mapas de características. Ademais, a última camada plenamente conectada possui 12 neurônios, correspondente aos 12 modelos de pé disponíveis para cada lado. Os 12 pés se diferenciam quanto à distribuição de pressão normalizada nas regiões de sensoriamento pré-determinadas na placa. A modelagem do problema será explicada com mais detalhes na Seção 3.4.

2.4 Sistemas de reconhecimento biométrico

2.4.1 Arquitetura e métricas de avaliação

Sistemas de reconhecimento biométrico, por definição, utilizam características comportamentais ou físicas próprias de um indivíduo a fim de identificá-lo univocamente (KHOKHER; SINGH, 2021). Idealmente, essas características pessoais devem ser universais, únicas, permanentes, de fácil coleta e de fácil aceitação pelos usuários (EL-ABED; CHARRIER; ROSENBERGER, 2012).

A despeito da finalidade - se verificação ou identificação - sistemas de reconhecimento biométrico podem ser construídos em 3 fases: formação do banco de dados, através da aquisição dos dados do usuário (etapa de registro); extração de características das informações coletadas; e comparação das características coletadas às registradas do banco de dados (etapa de verificação ou identificação).

Nas 3 fases, tal qual um sistema baseado em reconhecimento de padrão (RP), 4 módulos compõem a arquitetura desse tipo de sistema e são essenciais (DHIR *et al.*, 2010):

- Módulo sensor: responsável pela aquisição dos dados, varia com o tipo de dado que o projetista do sistema deseja coletar (íris do olho, voz, impressão digital ou distribuição de pressão, por exemplo) e representa a interface direta com o usuário;
- Módulo de extração de características: encarregado do processamento dos dados coletados no módulo sensor. Nesta etapa, caracterizam-se os dados para que seja possível diferenciá-los a partir dos atributos extraídos;
- Módulo de base de dados: onde os indivíduos têm suas informações devidamente registradas, após serem coletadas no módulo sensor e passarem por etapas de checagem de qualidade e extração de características dos dados na etapa de registro dos usuários;
- Módulo de correspondência: os atributos do módulo de extração são comparados aos armazenados no banco de dados. Uma métrica de pontuação deve ser utilizada para considerar se o usuário foi devidamente reconhecido ou autenticado, determinando o grau de similaridade entre os dados.

No que se refere às métricas de avaliação de desempenho dos sistemas de identificação, entre as presentes na literatura, as taxas de precisão (PPR, do inglês *positive predictive rate*) e de sensibilidade (TPR, do inglês *true positive rate*) são amplamente utilizadas. A precisão indica a proporção de classificações positivas corretas, dentre todas as que o modelo fez. A sensibilidade, por sua vez, informa a parcela de classificações positivas corretas entre aquelas que possuem o resultado positivo como valor esperado (EL-ABED; CHARRIER; ROSENBERGER, 2012). Essas métricas são calculadas segundo as Equações 10 e 11, respectivamente, onde são consideradas as taxas de TP (positivo verdadeiro, do inglês *true positive*), FP (falso positivo) e FN (falso negativo).

$$PPR = \frac{TP}{(TP + FP)} \quad (10)$$

$$TPR = \frac{TP}{(TP + FN)} \quad (11)$$

É possível obter também uma média ponderada da precisão e da sensibilidade, chamada de F1-Score, calculada conforme mostra a Eq. 12:

$$F1 - Score = 2 \times \frac{PPR \times TPR}{(PPR + TPR)} \quad (12)$$

Neste trabalho, o sensor é uma placa instrumentada com FBGs; o pré-processamento consiste na normalização dos dados e subsequente geração das imagens de pressão plantar

adaptadas ao sistema; os atributos relevantes são a localização dos pontos e os respectivos valores relativos de pressão que eles representam; e os algoritmos de classificação são baseados em máquinas de vetores de suporte e rede neural convolucional, cujas classes correspondem aos modelos de pés ou aos pares de pés disponíveis.

2.4.2 A pegada humana como elemento de reconhecimento biométrico

A identificação do indivíduo via reconhecimento biométrico pode ser obtida a partir de atributos como digital da palma, digital dos dedos, voz, retina, ou até mesmo pelo reconhecimento facial, presente em alguns *smartphones* como alternativa às tradicionais senhas alfanuméricas ou de padrões gráficos. Outra alternativa reside na utilização das informações da pegada como método para reconhecimento do usuário.

As características morfológicas da pegada humana são comprovadamente únicas para cada indivíduo, o que possibilita a classificação de acordo com as distribuições de pressão de cada pegada (KENNEDY, 1996). Informações contidas em uma pegada, como formato, tamanho e distribuição da pressão plantar fornecem características únicas sobre cada indivíduo. Tanto estática quanto dinamicamente, a morfologia de uma pegada é o resultado de agentes do meio e da própria formação hereditária (KRISHAN; KANCHAN, 2016). Além disso, a conjunção dos ossos do pé com os tendões e demais tecidos da região é diferente até ao comparar os lados esquerdo e direito do mesmo indivíduo (ROBBINS, 1985). É possível concluir, portanto, que não existem duas pessoas com o mesmo padrão morfológico de pegada e para cada usuário há exclusivamente uma pegada correspondente.

Os atributos para diferenciação entre pegadas variam a depender dos métodos de coleta e processamento dos dados. Entre eles, na coleta estática, pode-se citar o tamanho e o formato do pé, a amplitude dos valores de pressão (FENG; GE; SONG, 2011). Para situações de coleta dinâmica, consideram-se também tanto o centro de pressão, que compreende a análise postural do indivíduo, quanto a direção da pegada obtida (HERNANDEZ *et al.*, 2016). Outros atributos já utilizados em estudos com coleta tanto estática quanto dinâmica compreendem: distribuição de pressão (TAKEDA *et al.*, 2009), pico de pressão plantar, força máxima de contato, área de contato e integrais de pressão-tempo e força-tempo (BULDT *et al.*, 2018).

O método proposto neste trabalho é uma coleta estática para posterior identificação biométrica de indivíduos a partir da distribuição da pressão plantar.

3 METODOLOGIA

3.1 Gravação das Redes de Bragg

As FBGs para a fabricação da placa sensora foram gravadas em dois segmentos de fibra padrão de telecomunicações (G-652, DRAKTEL). Cada segmento mede em torno 80 cm com as redes distantes aproximadamente 5 cm uma da outra, com comprimentos de onda de Bragg separados espectralmente por no mínimo 3 nm. O processo de gravação ocorreu no Laboratório Multiusuário de Fotônica da UTFPR-CT, e se baseia na incidência de um feixe de luz ultravioleta em um dispositivo difrator (máscara de fase), com periodicidade Λ_{pm} , para geração de padrões de interferência no núcleo da fibra. Utilizou-se *laser* de excímero ArF (Coherent Xantos XS) operando em 193 nm, com energia de pulso do laser variando entre 3,5 e 5,0 mJ, taxa de repetição de 250 Hz e tempo de exposição médio de 1 minuto, além de 7 máscaras de fase (IBSEN PHOTONICS). Todo o processo ocorreu sob temperatura controlada de $(22,0 \pm 0,5)^\circ\text{C}$ e gerou, no total, 14 FBGs com refletividades inferiores a 5%. A Tabela 1 mostra as informações de comprimento de onda de Bragg após a gravação, bem como da periodicidade das máscaras de fase.

Tabela 1 – Periodicidade das máscaras de fase utilizadas e λ_B das FBGs gravadas à temperatura de $(22,0 \pm 0,5)^\circ\text{C}$.

FBG	λ_B (nm)	Λ_{PM} (nm)
1	1526,96	1056,00
8	1526,58	
2	1531,16	1058,90
9	1532,15	
3	1553,86	1073,50
10	1553,34	
4	1536,23	1062,50
11	1536,78	
5	1539,85	1064,90
12	1538,98	
6	1542,86	1065,50
13	1542,51	
7	1549,22	1070,50
14	1549,87	

Fonte: Autoria própria.

Concluído o processo de gravação, a etapa seguinte consistiu no encapsulamento dos transdutores para fabricação do sistema de sensoriamento proposto. Uma característica tão relevante quanto o valor da sensibilidade de um sensor é a sua faixa dinâmica de operação, que indica como o sensor encapsulado naquele material responde à aplicação de cargas no intervalo compreendido da aplicação proposta. Para este trabalho, a caracterização do material encapsulante que o qualifica como adequado à aplicação proposta se encontra em (GIRAO, 2019). No trabalho de Girao (GIRAO, 2019), FBGs gravadas sob as mesmas condições foram

encapsuladas em 3 elastômeros diferentes, porém de mesmo formato, e submetidas a cargas de 1,0 a 10,0 kgf. As sensibilidades encontradas variaram de $(3061 \pm 188) \text{ pm}/(\text{kgf}/\text{cm}^2)$ a $(6306 \pm 104) \text{ pm}/(\text{kgf}/\text{cm}^2)$.

Também foi realizado um estudo quanto à deformação em comprimento de onda para uma variação de temperatura de 3°C. Para uma janela de 90 s, o aquecimento resultou em um deslocamento de 10 pm, enquanto para o resfriamento, $\Delta\lambda$ foi de aproximadamente 1 pm. Os gráficos se encontram disponíveis no Anexo A Considerando as sensibilidades e os valores obtidos para os deslocamentos quando da aplicação de cargas, considerou-se que para além da faixa de operação, e proteção mecânica da fibra, o material encapsulante também foi capaz de isolar termicamente as FBGs.

3.2 Placa: Fabricação e Caracterização

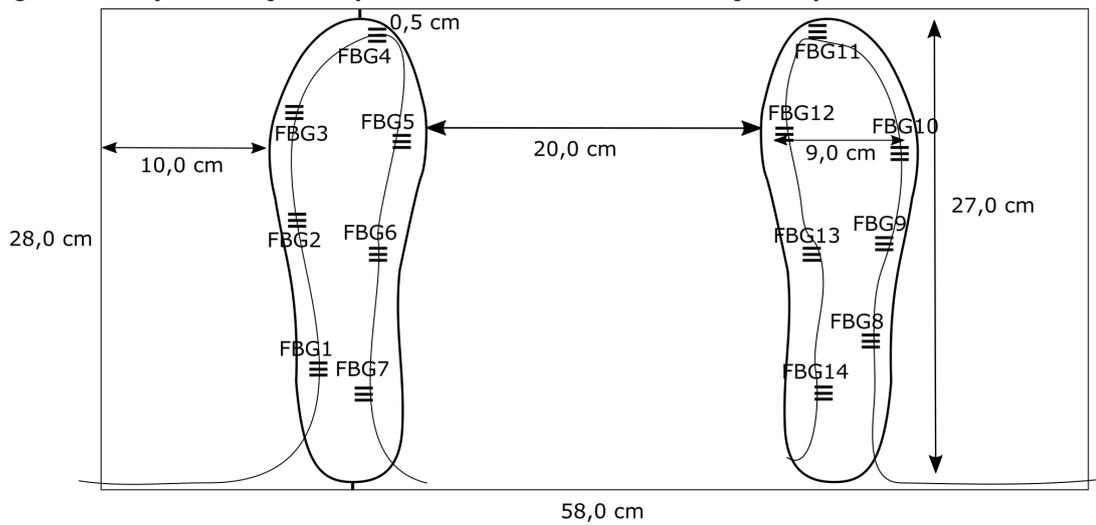
3.2.1 Fabricação da placa sensora

A placa foi fabricada utilizando-se um molde de base retangular de acrílico, com dimensões $(28,0 \times 58,0)$ cm e altura de 5,0 cm. Inicialmente, preencheu-se o molde com silicone de cura acética (Selabond), resultando em uma camada de silicone com altura aproximada de 0,5 cm. Após 72 horas, cada segmento de fibra contendo as 7 FBGs em série foi adequadamente posicionado sobre a camada de silicone e fixado com fita adesiva de forma a manter uma distância livre de aproximadamente 20,0 cm entre as duas regiões contendo as fibras. Em seguida, foi depositada uma segunda camada de silicone, encapsulando os transdutores. Passadas mais 72 horas, a placa resultante com espessura de cerca de 1 cm estava apta para o início dos testes.

No posicionamento de cada segmento de fibra, a distribuição das 7 FBGs procurou contemplar as regiões do pé correspondentes ao antepé, mediopé e retropé para pés com comprimentos variando entre 23,0 e 27,0 cm, de forma que cada região do pé fosse sensorizada por pelo menos duas FBGs, sendo uma para a porção medial e outra para a porção lateral. Para a região do antepé, sensorizada por 3 FBGs, procurou-se também sensoriar a região dos metatarsos. Desta forma, foram definidas na placa duas regiões de sensoriamento: a do pé direito e a do pé esquerdo. A Figura 8 ilustra a localização aproximada dos sensores, uma vez que estes podem ter sofrido pequenos deslocamentos durante o processo de cura da segunda camada de silicone.

A Tabela 2 lista os comprimentos de onda de Bragg das FBGs encapsuladas na placa que foram medidos à temperatura de $(25,0 \pm 0,5)^\circ\text{C}$.

Figura 8 – Representação da placa sensora com as localizações aproximadas de cada FBG.



Fonte: Autoria própria.

Tabela 2 – Comprimentos de onda de Bragg das FBGs encapsuladas na placa, medidos à temperatura de $(25,0 \pm 0,5)$ °C.

FBG	λ_B (nm)
1	1527,87
2	1532,22
3	1535,94
4	1539,56
5	1544,46
6	1551,37
7	1554,03
8	1527,40
9	1532,81
10	1535,59
11	1539,03
12	1543,46
13	1550,44
14	1553,63

Fonte: Autoria própria.

Ao término da fabricação da placa, que pode ser visualizada na Figura 9, organizou-se o sistema para que fosse possível interrogar a placa e, então, caracterizá-la.

3.2.2 Esquema para interrogação da placa sensora

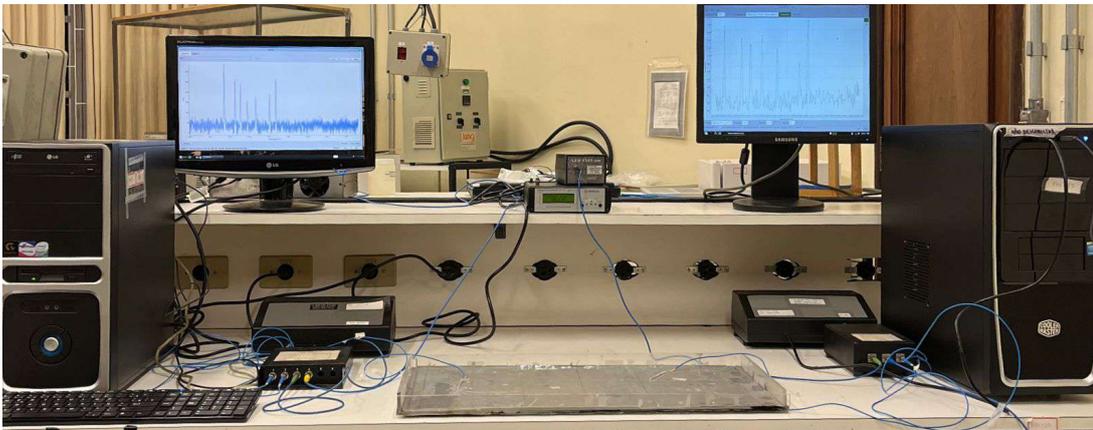
Para configurar o esquema de interrogação do sistema, cada segmento de fibra foi conectado a uma fonte ótica e a um interrogador via um circulador ótico. O interrogador foi conectado a um computador para leitura e armazenamento dos dados, conforme a Figura 11. Uma foto do sistema real é mostrada na Figura 10.

Figura 9 – Foto da placa sensora após o término do processo de fabricação.



Fonte: Autoria própria.

Figura 10 – Sistema de aquisição de dados da placa sensora.



Fonte: Autoria própria.

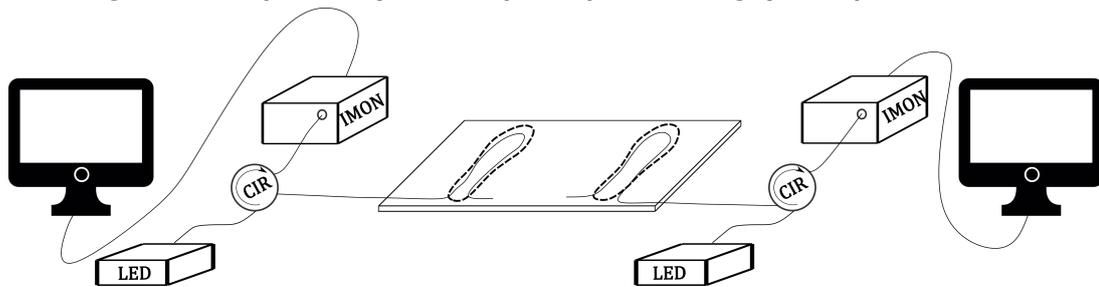
Os interrogadores utilizados foram os I-MON 256 e I-MON 512-E, da fabricante Ibsen Photonics, ambos com resolução de 0,5 pm. As fontes óticas são LEDs infravermelhos: Superlum LED PILOT-2, com comprimento de onda central de 1558,3 nm e largura de banda a meia altura de 73,8 nm; e Superlum LED PILOT-4, com comprimento de onda central de 1558,3 nm e largura de banda a meia altura de 73,8 nm.

3.2.3 Caracterização da placa sensora

A caracterização da placa sensora ocorreu em duas etapas. Em um primeiro momento, foram aplicadas sobre a superfície da placa e nas posições aproximadas das FBGs, cargas de

magnitude conhecida. Em um segundo momento, a fim de simular pisadas humanas variadas, foram usados 12 pares de moldes de pés diversos posicionados diretamente sobre a placa. Nestes testes, as cargas conhecidas ou os moldes de pés atuaram sobre a placa somente na região do pé direito ou na região do pé esquerdo, e simultaneamente nas duas regiões.

Figura 11 – Representação do esquema para interrogação da placa sensora.



Fonte: Autoria própria.

3.2.3.1 Teste com cargas localizadas

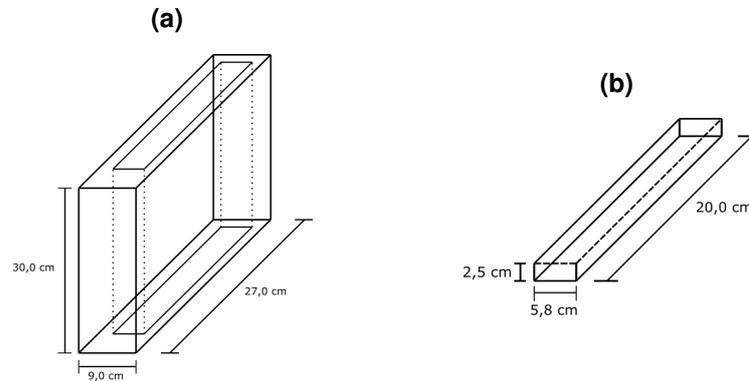
Este teste consistiu no empilhamento de cargas de aço (peso específico $7,8 \text{ g/cm}^3$), com formato cilíndrico de 50,0 mm de altura e 30,0 mm de diâmetro, e massa de $(1,0 \pm 0,1)$ kg, sobre a localização aproximada de cada uma das FBGs. Aplicou-se de 1,0 a 10,0 kg com variação de 1,0 kg e mediu-se simultaneamente a resposta de todas as 14 FBGs (em $\Delta\lambda_B$) do sistema. Repetiu-se esse teste em 5 ocasiões diferentes e, em cada ocasião, repetiu-se 5 vezes.

Os dados coletados auxiliaram na análise da resposta acoplada do sistema e do comportamento das FBGs para o incremento de cargas.

3.2.3.2 Testes com modelos de pé

Nesta etapa, foram simuladas pisadas diversas utilizando 24 modelos de pés diferentes fabricados com borracha líquida de silicone (Dow Corning BX3-8001), sendo 12 pés esquerdos e 12 pés direitos, com comprimentos variando entre 23,0 e 27,0 cm e massas entre 208,0 e 562,0 g. A fim de simular situações nas quais um mesmo pé pode vir a aplicar pressões de diferentes magnitudes sobre a placa, foi usada uma caixa de MDF com dimensões externas de $9,0 \times 27,0 \times 30,0$ cm posicionada sobre o modelo de pé. A caixa comporta até 7 barras de aço com dimensões de $5,8 \times 2,5 \times 20,0$ cm empilhadas umas sobre as outras (Figuras 12a e 12b). Os testes foram feitos em ciclos de aumento e de diminuição de carga através da adição ou retirada das barras de aço, de forma que a carga mínima em cada lado totalizou aproximadamente 8,8 kg (caixa + 3 barras), e, a carga máxima, aproximadamente 18,5 kg (caixa + 7 barras).

Figura 12 – Materiais acoplados ao pé de borracha para simular a pisada. Em (a), tem-se a representação da caixa de MDF e em (b), a representação da barra de aço.



Fonte: Autoria própria.

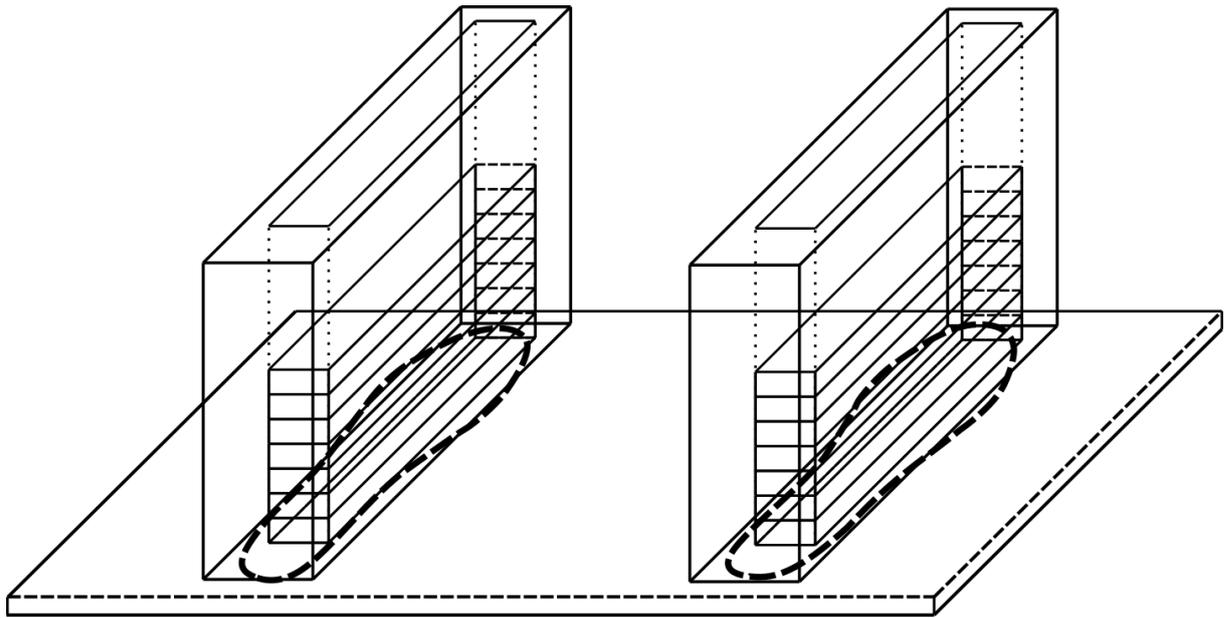
Para a realização dos testes com os pés, fixou-se a caixa sobre a superfície de cada pé de borracha, e o sistema caixa + pé foi colocado sobre a placa, nas regiões aproximadas delimitadas para cada pé, conforme ilustrado na Figura 13. O teste com cada pé foi repetido 5 vezes, com duração de cada teste igual a 90 s. Para cada repetição, os dados foram coletados em λ_B e, para cada FBG, as primeiras 50 amostras foram subtraídas das 50 últimas. Do resultado da subtração, calculou-se o valor médio e o módulo, representando o deslocamento de comprimento de onda de Bragg. Ao final de 5 repetições, calculou-se o deslocamento de comprimento de onda de Bragg médio ($\Delta\lambda_{B_{medio}}$) para cada FBG, e seu respectivo desvio-padrão. Estes valores foram utilizados para representar o comportamento médio da resposta de cada sensor.

Inicialmente, a aplicação de cargas foi feita de maneira **unilateral**. À medida que uma das regiões delimitadas para um dado pé recebia o sistema caixa+pés, a região do lado oposto permanecia em repouso. Posteriormente, o teste ocorreu de forma **bilateral**: tanto o lado esquerdo quanto o lado direito receberam cargas (Figura 13), com diferença de aproximadamente 5 segundos entre a alocação das caixas nos dois lados.

Por conseguinte, foi possível analisar o acoplamento das respostas do sistema quando de aplicações uni ou bilaterais.

Ao fim desta fase de testes, a etapa seguinte consistiu na manipulação dos dados para que, com as modelagens adequadas, sistemas de reconhecimento de padrão pudessem ser treinados objetivando a classificação dos modelos de pés e, conseqüentemente, a autenticação biométrica dos 12 indivíduos. Dois algoritmos de reconhecimento de padrão foram testados neste trabalho: SVM e CNN.

Figura 13 – Sistema com máxima aplicação de carga bilateral.



Fonte: Autoria própria.

3.3 Sistema de autenticação biométrica de pisadas baseado em SVM

3.3.1 Organização dos dados

Modelou-se o problema de reconhecimento de padrão supervisionado a partir da organização matricial dos deslocamentos de comprimento de onda de Bragg obtidos por cada par de pés, associados aos *labels* correspondentes. Um dos algoritmos escolhidos para a resolução deste problema foi o SVM, por equilibrar o custo computacional com a eficiente capacidade de classificação para problemas multi-classe. A técnica de *data augmentation* foi utilizada para expandir artificialmente a base de dados, visando aumentar a generalidade do modelo. Gerou-se 400 respostas diferentes para cada pé ou cada par de pé a partir das médias e dos desvios-padrão das amostras coletadas. A mesma quantidade de dados artificiais foi criada para cada classe buscando evitar problemas de desequilíbrio de classe na classificação final. Além disso, a ordenação adequada dos sensores é fundamental para a modelagem correta do problema. Justifica-se, portanto, a escolha dos valores médios e dos desvios-padrão como únicos parâmetros utilizados para o *data augmentation*.

Em uma abordagem inicial, treinou-se um modelo para os 12 pés esquerdos e outro modelo para os 12 pés direitos. Na organização matricial de cada um destes modelos, as matrizes possuem dimensões 4800×8 , onde as linhas correspondem aos comprimentos de onda normalizados ($\Delta\lambda_{B_{medio}}$) das classes após o *data augmentation*, e as colunas representam as 7 FBGs e o respectivo *label* da classe, como pode ser visto em (13):

$$\begin{pmatrix} \Delta\lambda_{11} & \Delta\lambda_{12} & \Delta\lambda_{13} & \Delta\lambda_{14} & \Delta\lambda_{15} & \Delta\lambda_{16} & \Delta\lambda_{17} & label_1 \\ \Delta\lambda_{21} & \Delta\lambda_{22} & \Delta\lambda_{23} & \Delta\lambda_{24} & \Delta\lambda_{25} & \Delta\lambda_{26} & \Delta\lambda_{27} & label_1 \\ \Delta\lambda_{31} & \Delta\lambda_{32} & \Delta\lambda_{33} & \Delta\lambda_{34} & \Delta\lambda_{35} & \Delta\lambda_{36} & \Delta\lambda_{37} & label_1 \\ \vdots & \vdots \\ \Delta\lambda_{k1} & \Delta\lambda_{k2} & \Delta\lambda_{k3} & \Delta\lambda_{k4} & \Delta\lambda_{k5} & \Delta\lambda_{k6} & \Delta\lambda_{k7} & label_k \\ \vdots & \vdots \\ \Delta\lambda_{n1} & \Delta\lambda_{n2} & \Delta\lambda_{n3} & \Delta\lambda_{n4} & \Delta\lambda_{n5} & \Delta\lambda_{n6} & \Delta\lambda_{n7} & label_n \end{pmatrix} \quad (13)$$

Posteriormente, considerou-se como uma classe cada par de pé. Para este caso, a matriz assumiu dimensões 4800 x 15, onde novamente as linhas correspondem a $\Delta\lambda_{B_{medio}}$. Contudo, esta modelagem assume que as 7 primeiras colunas representam o pé esquerdo, as 7 seguintes o pé direito, resultantes da concatenação dos dados unilaterais esquerdos e direitos, respectivamente, e a última coluna corresponde aos respectivos *labels* das classes. Este mapeamento pode ser observado em (14):

$$\begin{pmatrix} \Delta\lambda_{11} & \Delta\lambda_{12} & \Delta\lambda_{13} & \dots & \Delta\lambda_{112} & \Delta\lambda_{113} & \Delta\lambda_{114} & label_1 \\ \Delta\lambda_{21} & \Delta\lambda_{22} & \Delta\lambda_{23} & \dots & \Delta\lambda_{212} & \Delta\lambda_{213} & \Delta\lambda_{214} & label_1 \\ \Delta\lambda_{31} & \Delta\lambda_{32} & \Delta\lambda_{33} & \dots & \Delta\lambda_{312} & \Delta\lambda_{313} & \Delta\lambda_{314} & label_1 \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \vdots \\ \Delta\lambda_{k1} & \Delta\lambda_{k2} & \Delta\lambda_{k3} & \dots & \Delta\lambda_{k12} & \Delta\lambda_{k13} & \Delta\lambda_{k14} & label_k \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \vdots \\ \Delta\lambda_{n1} & \Delta\lambda_{n2} & \Delta\lambda_{n3} & \dots & \Delta\lambda_{n12} & \Delta\lambda_{n13} & \Delta\lambda_{n14} & label_n \end{pmatrix} \quad (14)$$

A modelagem bilateral é, portanto, a composição dos dados de dois pés pisando individualmente sobre a plataforma e posteriormente reunidos na nova modelagem dos dados.

Dos 4800 dados disponíveis, 50% foram utilizados para treinamento, 25% para testes e os 25% restantes para a validação do modelo. base de dados será detalhada em uma próxima seção.

3.3.2 Método de classificação baseado em SVM

As matrizes de dados foram submetidas a um classificador SVM com função de kernel não-linear e polinomial de ordem 3 (Eq. 15):

$$G(x_j, x_k) = (1 + x_j'x_k)^3 \quad (15)$$

Por tratarem fundamentalmente de problemas de classificação, onde um dado é classificado de acordo com sua posição em relação ao hiperplano de separação ótimo, as SVMs não fornecem estimativas de probabilidade que determinam diretamente a qualidade (acurácia) do classificador gerado. Para solucionar este problema, aplica-se a técnica de validação cruzada. Neste trabalho, utilizou-se a técnica *k-fold*, com $k = 5$.

3.4 Sistema de autenticação biométrica de pisadas baseado em CNN

Por se tratar fundamentalmente de um problema que utiliza pressões plantares em uma placa instrumentada para identificação biométrica dos indivíduos, buscou-se explorar também a representação gráfica do sistema, permitindo uma conferência visual dos resultados obtidos. Para isto, os sinais oriundos das FBGs são transformados em imagens RGB e aplicados a um classificador que realiza o processamento das imagens.

Diante da mudança do formato dos dados de entrada, propõe-se a utilização de uma Rede Neural Convolutiva, baseada em *deep learning*, capaz de processar o novo formato e oferecer uma solução para o problema de classificação abordado.

3.4.1 Geração de imagens de pressão

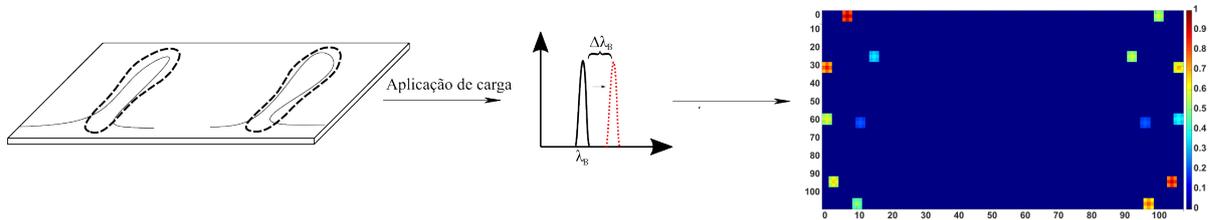
Os dados obtidos nos testes descritos na Subseção 3.2.3.2 foram pré-processados e utilizados para gerar uma representação gráfica do sistema. Para isto, modelou-se matricialmente o sistema de forma que cada elemento da matriz representasse 0,5 cm das dimensões originais da placa. A matriz foi preenchida com valores normalizados entre 0 e 1, onde 0 representa resposta mínima e 1 corresponde à resposta máxima absoluta observada em deslocamento de comprimento de onda. O módulo do valor de $\Delta\lambda_B$ foi convertido para uma escala de cores na qual quanto maior o valor de $\Delta\lambda_B$, mais intensa é a resposta na escala de cores escolhida.

A princípio, considerou-se cada pé individualmente, com dimensões $27,0 \times 9,0$ cm. As figuras resultantes são quadradas em suas dimensões, para sua posterior utilização no modelo com redes neurais convolucionais. Portanto, as matrizes resultantes desta modelagem são de dimensões 54×54 , onde cada elemento descreve o sistema com resolução de 0,5 cm. Modelando-se o sistema na totalidade, a matriz assumiu dimensões 108×108 .

Cada FBG foi representada por 9 elementos da matriz, distribuídos de forma quadrada e em dimensões 3×3 , onde o elemento central da matriz assumiu o valor de $\Delta\lambda_B$ calculado como valor médio dos experimentos realizados em 3.2.3.2, e os demais elementos foram preenchidos a partir deste valor decaídos de 5,0% e 10,0%. Na Figura 14 observa-se o processo simplificado de transformação do dado coletado em imagem.

A partir da representação gráfica do sistema, a etapa seguinte consistiu na construção da rede neural convolutiva.

Figura 14 – Transformação do dado de comprimento de onda em imagem. Após a aplicação de carga sobre a plataforma, os deslocamentos de comprimento de onda de Bragg são representados como elementos centrais na modelagem dos mapas de pressão, nos quais cada FBG corresponde a uma matriz 3×3 .



Fonte: Autoria própria.

3.4.2 Rede neural convolucional

As imagens obtidas a partir da representação gráfica serviram como entrada para uma rede neural convolucional inspirada na LeNet-5. Inicialmente, analisou-se a aplicação de cargas nos pés de maneira unilateral e considera-se cada classe como um pé. As imagens de entrada possuem dimensões $54 \times 54 \times 3$. Os parâmetros *zero padding* e *stride* foram regulados como 0 e 1, respectivamente.

Tal qual para a SVM, a confiabilidade de uma CNN exige um grande volume de dados para treinamento, teste e validação. Para isto, calculou-se a média e o desvio-padrão de 5 experimentos realizados e, a partir destes valores, aplicou-se novamente a técnica de *data augmentation*, gerando artificialmente 400 dados para cada classe. Novamente, a expansão da base de dados se baseou somente nos valores médios e de desvio-padrão de $\Delta\lambda_B$, não havendo quaisquer rotações em torno dos eixos para as imagens geradas. As imagens geradas, com as informações pertinentes ao processo de coleta, tais como data de coleta e tamanhos dos pés, estão disponíveis em (GIRAO, 2023).

Manteve-se a proporção de dados para treinamento, teste e validação do modelo. Portanto, do total de 4800 imagens representando cada região da placa, 50% (2400) foram utilizados para treinamento, 25% (1200) para teste e os 25% (1200) restantes para validação.

Os dados passaram por processo de validação cruzada com o método *k-fold*, com $k = 5$. Ao fim, foi escolhida a rede neural com maior taxa de acerto.

4 RESULTADOS

4.1 Caracterização da placa sensora

Todas as rotinas dos algoritmos utilizados neste trabalho foram executadas no *software* MATLAB, nas versões 2020a e 2023a, utilizando uma máquina com 16,0 GB de memória RAM e processador Intel(R) Core(TM) i7-7500U.

4.1.1 Teste com cargas localizadas

Os dados coletados neste teste permitiram a análise tanto do acoplamento das respostas das FBGs da placa sensora, quanto do comportamento dos deslocamentos de comprimento de onda para a situação de acréscimo de cargas sobre a localização aproximada das FBGs.

As Figuras 15 e 16 apresentam os módulos das respostas de todas as FBGs a cargas aplicadas sobre a FBG 1, localizada no pé esquerdo. Na Figura 15 são apresentados os módulos dos deslocamentos no comprimento de onda de Bragg de cada FBG, resultante da aplicação de cargas entre 1,0 e 10,0 kg, onde cada símbolo corresponde a uma carga diferente. Já na Figura 16, o mesmo resultado é apresentado em função da carga aplicada, onde cada FBG é representada por um símbolo diferente. Analogamente, as Figuras 17 e 18 ilustram os resultados para cargas aplicadas sobre a FBG 8, localizada no pé direito. As demais curvas de resposta podem ser encontradas no Apêndice B. As barras de erro presentes nos gráficos são resultantes das incertezas relacionadas às condições de repetibilidade e de precisão intermediária das medições, e da resolução dos interrogadores.

A partir destes gráficos, é possível confirmar a hipótese de resposta acoplada dos sensores, visto que todas as FBGs são influenciadas por uma carga aplicada de maneira localizada sobre a placa. Nos gráficos das Figuras 15 e 16, por exemplo, tem-se que os deslocamentos de maior magnitude são observados para as FBGs localizadas na região do pé esquerdo, enquanto os deslocamentos de menor magnitude, que podem ser visualizados melhor no *inset* do gráfico da Figura 15, são encontrados nas FBGs localizadas no pé direito, onde não houve aplicação direta de carga. Este comportamento também é visualizado quando a aplicação de carga ocorre no pé direito, com respostas de maiores intensidades nas FBGs 8 a 14 e de menor escala para as FBGs 1 a 7.

Figura 15 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação de carga sobre a FBG 1. À esquerda, observa-se o módulo do deslocamento no comprimento de onda de Bragg das FBGs em função da carga atuando na FBG 1. No *inset* do gráfico, é possível observar em outra escala os deslocamentos de menor magnitude. A imagem à direita ilustra a localização aproximada da aplicação das cargas.

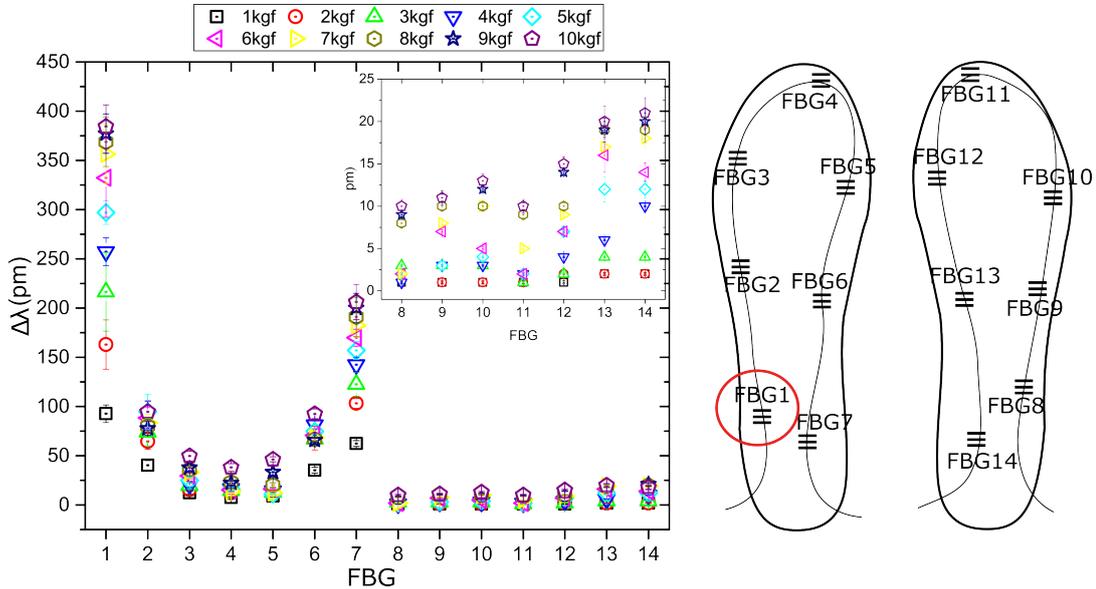


Figura 16 – Curvas de resposta das FBGs para cargas aplicadas de modo crescente na FBG 1. As linhas conectando os pontos são somente guias visuais.

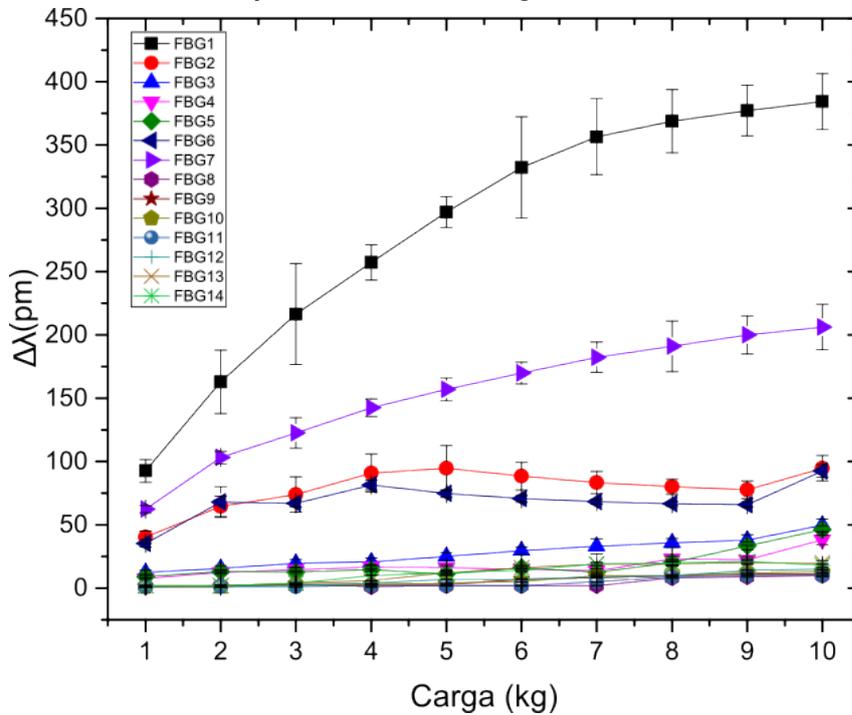


Figura 17 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação de carga sobre a FBG 8. À esquerda, observa-se o módulo do deslocamento no comprimento de onda de Bragg das FBGs em função da carga atuando na FBG 8. No *inset* do gráfico, é possível observar em outra escala os deslocamentos de menor magnitude. A imagem à direita ilustra a localização aproximada da aplicação das cargas.

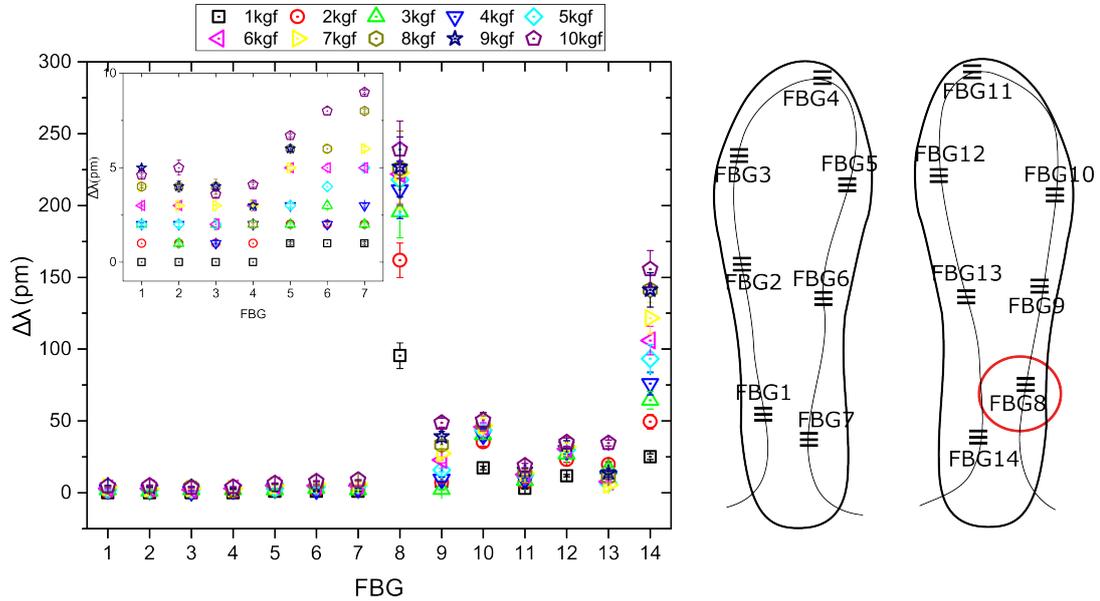
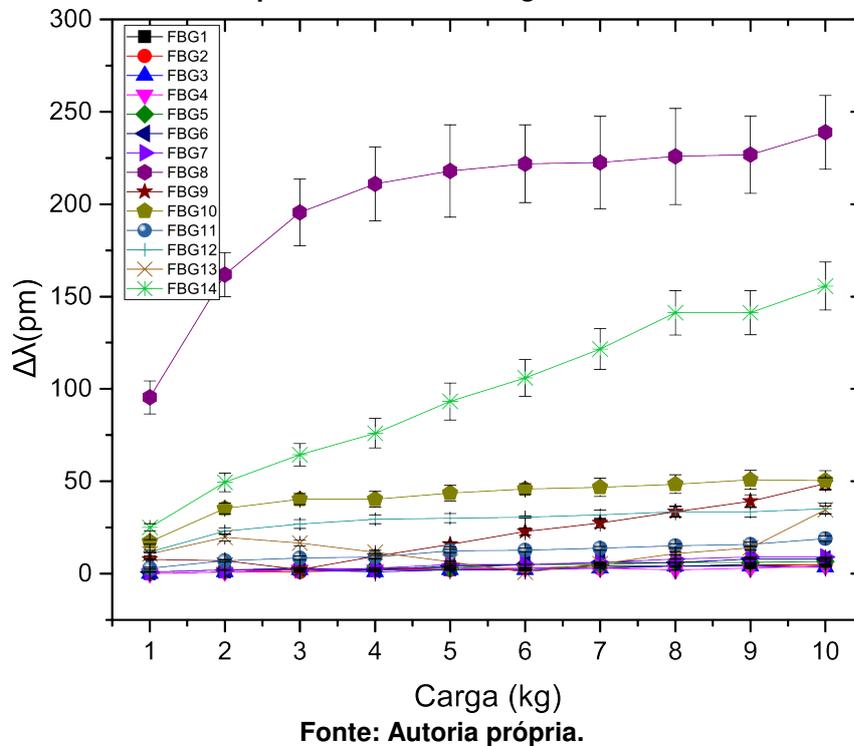


Figura 18 – Curvas de resposta das FBGs para cargas aplicadas de modo crescente na FBG 8. As linhas conectando os pontos são somente guias visuais.



Além disso, as linhas que funcionam como guias visuais nos gráficos de curvas de resposta (Figuras 16 e 18) indicam o comportamento não-linear das respostas das FBGs com o aumento de carga.

Para quantificar as respostas acopladas das FBGs, os deslocamentos de comprimento de onda das FBGs foram determinadas em relação a um deslocamento máximo de comprimento de onda. Portanto, quando uma carga de 10 kg é aplicada na plataforma sobre a localização de um FBG específica, que é mais influenciada pela perturbação, os deslocamentos de comprimento de onda experimentados por cada uma das outras 13 FBGs são calculados. A Tabela 3 e a Tabela 4 mostram os deslocamentos relativos de comprimento de onda das 14 FBGs quando uma carga de 10 kg é aplicada individualmente nas posições das FBGs 1 a 7 e das FBGs 8 a 14, respectivamente. As linhas das tabelas mostram os deslocamentos relativos de comprimento de onda experimentados pelas 14 FBGs, enquanto a FBG sob a qual a carga é aplicada está indicada no topo das colunas.

Quando a carga de 10 kgf é aplicada sobre a FBG1, por exemplo, o comprimento de onda de Bragg da FBG1 sofre deslocamento de 384 pm. Todavia, a FBG2 desloca espectralmente de 95 pm, o que representa uma resposta relativa em relação ao máximo desvio obtido de 25%.

Tabela 3 – Resposta relativa das FBGs comparativamente ao máximo desvio em comprimento de onda obtido quando da aplicação da carga diretamente sobre uma dada FBG do pé esquerdo.

FBG	1	2	3	4	5	6	7
1	100%	25%	13%	10%	12%	24%	54%
2	25%	100%	30%	12%	26%	35%	19%
3	13%	26%	100%	32%	52%	10%	12%
4	10%	21%	53%	100%	19%	10%	10%
5	12%	28%	63%	21%	100%	14%	15%
6	24%	18%	20%	11%	9%	100%	24%
7	54%	62%	14%	10%	10%	12%	100%
8	3%	4%	4%	3%	3%	2%	5%
9	3%	4%	4%	4%	3%	2%	3%
10	3%	5%	7%	5%	5%	3%	3%
11	3%	4%	7%	6%	6%	2%	5%
12	4%	6%	7%	5%	7%	3%	5%
13	5%	7%	7%	4%	6%	4%	6%
14	5%	7%	4%	3%	4%	3%	7%

Fonte: Autoria própria.

Tabela 4 – Resposta relativa das FBGs comparativamente ao máximo desvio em comprimento de onda obtido quando da aplicação da carga diretamente sobre uma dada FBG do pé direito.

FBG	8	9	10	11	12	13	14
1	2%	2%	1%	3%	2%	3%	3%
2	2%	3%	1%	4%	1%	5%	3%
3	2%	2%	1%	4%	2%	4%	2%
4	2%	1%	1%	7%	1%	8%	2%
5	3%	3%	2%	6%	3%	7%	3%
6	3%	3%	1%	6%	3%	6%	3%
7	4%	2%	1%	7%	2%	7%	6%
8	100%	30%	15%	23%	12%	22%	51%
9	20%	100%	18%	22%	16%	45%	11%
10	21%	76%	100%	61%	30%	34%	12%
11	8%	9%	46%	100%	29%	24%	9%
12	15%	8%	13%	89%	100%	33%	10%
13	15%	49%	11%	23%	33%	100%	21%
14	65%	9%	13%	22%	10%	43%	100%

Fonte: Autoria própria.

Observam-se deslocamentos de 8,0% a 89,0% para FBGs que se encontram na região de sensoriamento do pé onde estão sendo aplicadas as cargas, e de 1,0% a 7,0% na região de sensoriamento na qual não há aplicação de cargas. Ressalta-se que mesmo os valores mínimos, que são da ordem de 10 pm, são detectáveis pelo interrogador cuja resolução é de 0,5 pm.

Outro ponto a se destacar na análise destas tabelas é a assimetria no percentual de acoplamento das respostas. Por exemplo, a carga de 10 kgf na FBG2 induz uma resposta na FBG3 de 30% em relação ao deslocamento máximo obtido, porém a mesma carga aplicada na FBG3 induz uma resposta de 26% na FBG2. Isto se deve aos diferentes padrões não-lineares de respostas individuais de cada FBG para a aplicação de cargas.

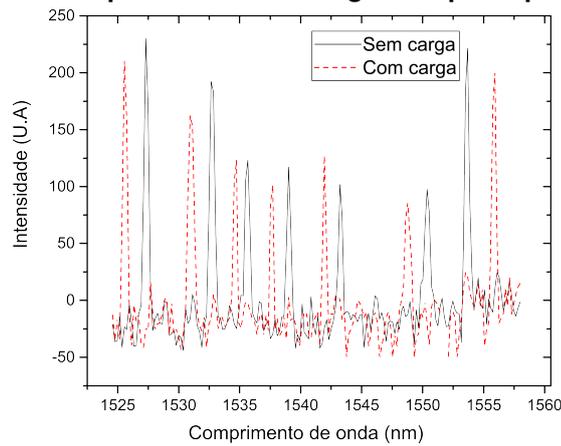
Tanto os gráficos de resposta das FBGs para diferentes cargas, quanto as tabelas que quantificam as respostas acopladas das FBGs para uma carga máxima aplicada, mostram que as 14 FBGs carregam informação sobre uma distribuição de pressão aplicada por uma pisada, mesmo que esta seja realizada em apenas uma das regiões de sensoriamento, seja ela a região do pé esquerdo ou do pé direito. Por fim, constata-se também que, conforme esperado, quanto mais distante estiver a FBG do ponto de aplicação da carga, menor é o efeito sobre ela, visto que os maiores desvios relativos ocorrem para FBGs localizadas na mesma região (pé esquerdo ou pé direito) em que a carga é aplicada.

4.1.2 Teste com modelos de pé

Seguindo a metodologia descrita em 3.2.3.2, a simulação de pisadas com modelos de pés resultou em deslocamentos em todas as FBGs, o que pode ser visualizado nas Figuras 19

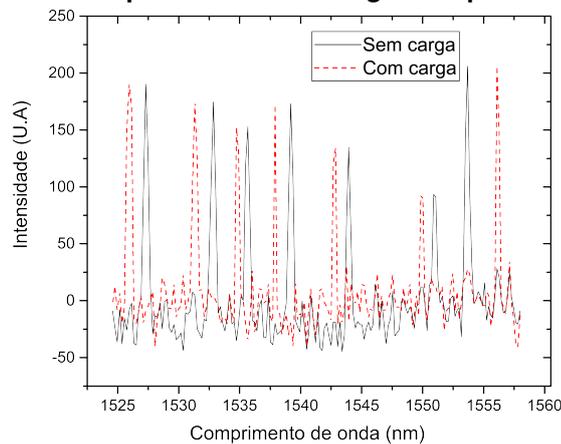
e 20, que mostram a resposta do sistema quando sob a ação de um par de pés. Neste exemplo, os pés com massas individuais de 18,5 kg foram posicionados simultaneamente sobre a placa e foram coletados os espectros das 14 FBGs. Os espectros para a condição em que nenhuma carga é aplicada sobre a placa estão representados em linhas cheias, enquanto as linhas tracejadas em vermelho representam os espectros coletados com o par de pés posicionado sobre a placa.

Figura 19 – Espectros coletados para as FBGs da região do pé esquerdo em aplicação bilateral



Fonte: Autoria própria.

Figura 20 – Espectros coletados para as FBGs da região do pé direito em aplicação bilateral



Fonte: Autoria própria.

Os deslocamentos das FBGs observados para maiores ou para menores valores de comprimento de onda resultam das diferentes intensidades de pressão plantar aos quais as redes são submetidas quando em contato com os modelos de pés. Contudo, não é possível associar o $\Delta\lambda_B$ apenas à deformação mecânica longitudinal uma vez que estes deslocamentos resultam de deformações atuando em várias direções nas FBGs encapsuladas na placa.

Esses valores de deslocamento observados foram normalizados para, em seguida, serem utilizados como entradas para os algoritmos de classificação propostos no trabalho.

4.2 Resultados SVM

Os modelos de SVM utilizados para os treinamentos tanto unilateral quanto bilateral foram obtidos a partir da *toolbox Classification Learner* disponibilizada no *software* MATLAB 2020b, cujo classificador pré-construído com função de *kernel* polinomial de ordem 3 foi configurado com os parâmetros apropriados para cada modelagem.

4.2.1 Resultado unilateral - SVM

Para a aplicação da SVM com a modelagem unilateral, os dados foram configurados de forma que a *inputTable* do modelo representasse as 7 FBGs com seus valores médios e respectivos desvios-padrão, e os *classNames* correspondentes às classes de 1 a 12. O percentual de *holdout* para separação do *dataset* foi definido em 50% e o valor de K para a validação do modelo *k-fold* foi deliberado como 5.

A aplicação da SVM para a modelagem unilateral resultou em tempos de treinamento inferiores a 1 min. Em termos de taxas de acerto global e de cada classe para a etapa de validação, têm-se as matrizes de confusão nas Figuras 21 e 22. Em uma matriz de confusão, as diagonais indicam a quantidade de dados corretamente classificados em cada classe (TP). A soma destes valores dividida pela quantidade total de dados resulta na taxa de acerto global (acurácia) do algoritmo. Neste caso, a SVM treinada para os pés esquerdos resultou em 94,42% de acurácia, enquanto para o lado direito, o valor obtido foi de 90,58%. As colunas à direita da matriz de confusão mostram os valores das precisões das classes (PPR), que indica a proporção de identificações positivas corretas. Nas linhas abaixo da matriz de confusão estão os valores de sensibilidade de cada classe (TPR), que avalia a capacidade do algoritmo treinado em identificar corretamente os dados positivos - localizados na diagonal principal.

Extraiu-se, portanto, os valores de precisão, sensibilidade e o F1-Score para as 12 classes. Estes valores estão exibidos nas Tabelas 5 e 6.

Tabela 5 – Precisão, sensibilidade e F1-Scores para os pés esquerdos - SVM.

Pé esquerdo	Precisão	Sensibilidade	F1-Score
1	1	1	1
2	1	1	1
3	1	1	1
4	0,930	0,949	0,9394
5	1	0,990	0,9950
6	0,880	0,926	0,9024
7	1	0,952	0,9754
8	0,800	0,851	0,8247
9	0,950	0,913	0,9311
10	0,950	0,950	0,9500
11	0,910	0,827	0,8665
12	0,910	0,978	0,9428

Fonte: Autoria própria.

Tabela 6 – Precisão, sensibilidade e F1-Scores para os pés direitos - SVM.

Pé direito	Precisão	Sensibilidade	F1-Score
1	1	1	1
2	1	1	1
3	1	1	1
4	1	1	1
5	0,970	0,960	0,9650
6	0,960	0,980	0,9699
7	0,950	0,960	0,9550
8	0,910	0,843	0,8752
9	0,850	0,914	0,8808
10	0,620	0,620	0,6200
11	0,660	0,647	0,7260
12	0,950	0,960	0,9550

Fonte: Autoria própria.

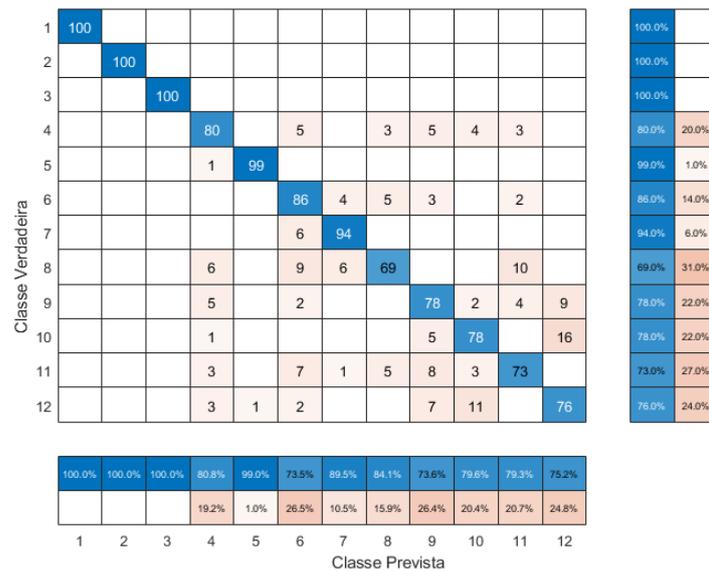
4.2.2 Resultado bilateral - SVM

Para o treinamento bilateral, onde os modelos de pés foram colocados sobre a placa sobre a região do pé esquerdo e do pé direito, manteve-se os dados e os parâmetros utilizados para os treinamentos anteriores, bem como as porcentagens de treinamento, teste e validação, além do método de validação 5-fold. A principal diferença se deu quanto à organização matricial dos dados de entrada, conforme já explicado anteriormente em 3.3.1. Essa diferença impactou no formato da *inputTable*, que passou de 8 para 15 colunas devido à inclusão das 7 FBGs correspondentes à outra região de sensoriamento.

O modelo, cujo tempo de treinamento foi de aproximadamente 2 minutos, retorna taxa de acerto 86,08% para as amostras de validação, e a matriz de confusão resultante está mostrada na Figura 23. Adicionalmente, diante dos valores de precisão e sensibilidade, os valores obtidos para os F1-scores para cada uma das classes podem ser vistos na Tabela 7.

As análises anteriores descritas na seção 4.1 já demonstram respostas distintas para os conjuntos de fibras do lado esquerdo e do lado direito. De forma complementar, é sabido que existem diferenças entre os padrões de distribuição de pressão do pé esquerdo e do pé direito que compõem um par. Portanto, o padrão de distribuição de pressão plantar resultante de um par de pés pode se assemelhar a outro sem que, necessariamente, isto ocorra para os dados unilaterais. Desta maneira, é possível que esses fatores tenham contribuído para uma menor acurácia para a modelagem bilateral.

Figura 23 – Matriz de confusão dos dados de validação para a modelagem bilateral - SVM.



Fonte: Autoria própria.

Tabela 7 – Precisão, sensibilidade e F1-Scores para a modelagem bilateral - SVM.

Par de pés	Precisão	Sensibilidade	F1-Score
1	1	1	1
2	1	1	1
3	1	1	1
4	0,800	0,808	0,8040
5	0,990	0,990	0,9900
6	0,860	0,735	0,7926
7	0,940	0,895	0,9169
8	0,690	0,841	0,7581
9	0,780	0,736	0,7574
10	0,780	0,796	0,7879
11	0,730	0,793	0,7602
12	0,760	0,752	0,7560

Fonte: Autoria própria.

Para o treinamento com a modelagem bilateral, os menores valores de F1-Score estão associados às classes 9 e 12, seguidos pelas classes 8 e 11, o que indica que, combinando em

uma média ponderada os valores de precisão e sensibilidade, essas são as classes susceptíveis a erro para a análise bilateral para o conjunto de dados fornecidos.

4.3 Resultados CNN

As imagens de representação gráfica do sistema foram geradas em rotinas do *software* MATLAB 2023b. A modelagem e o treinamento das redes neurais utilizadas neste trabalho foram realizados com o auxílio dos *layers* de aprendizado profundo disponibilizados no mesmo *software*. A unidade de processamento disponível é uma CPU de configurações Intel(R) Core(TM) i7-7500U.

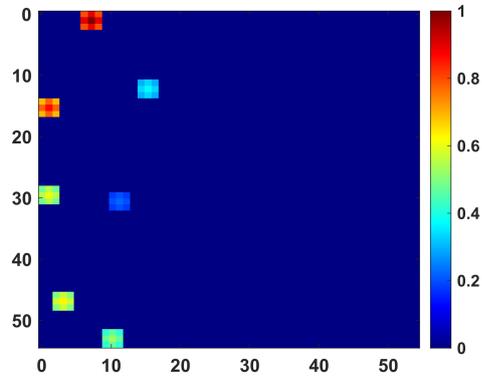
4.3.1 Representação gráfica do sistema - imagens de pressão

As imagens em RGB geradas foram salvas em PNG, com dimensões $(54 \times 54 \times 3)$, quando representando os pés individualmente, e $(108 \times 108 \times 3)$, para o caso da placa completa. As Figuras 24 e 25 mostram exemplos das imagens geradas.

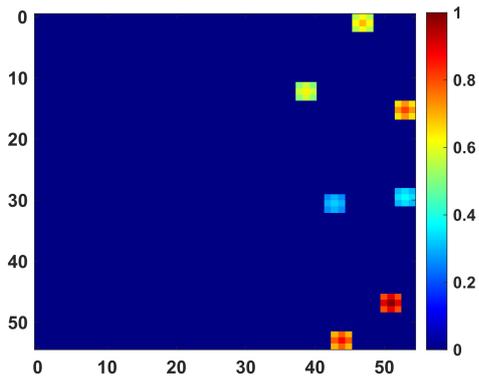
Os mapas de pressão normalizados de aplicações unilaterais, se analisados separadamente, pouco diferem dos mapas de pressão obtidos quando de aplicações bilaterais, como pode ser observado na Figura 26. Este resultado corrobora o que foi observado na Subseção 3.2.3.2, que já indicava índices de acoplamento de até 89,0% ao se analisar apenas um lado da aplicação e níveis de acoplamento inferiores a 8,0% no lado oposto, sem aplicação de carga.

Figura 24 – Representação gráfica das respostas com aplicações unilaterais com os pés (a) esquerdo 1 e (b) direito 1 - dimensões $54 \times 54 \times 3$.

(a)

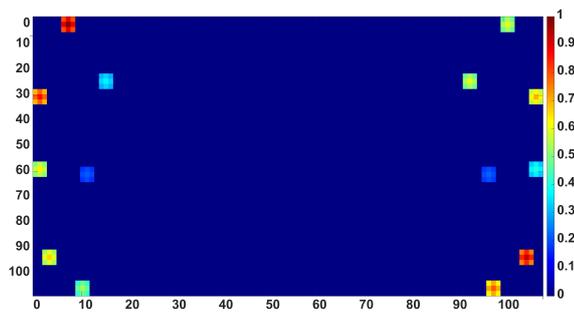


(b)



Fonte: Autoria própria.

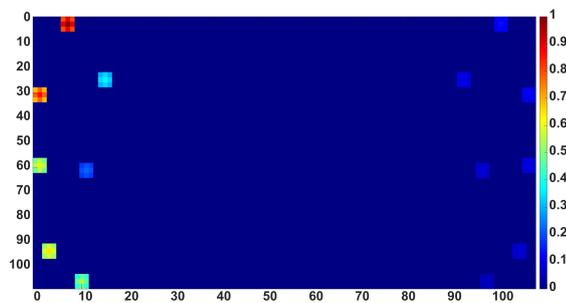
Figura 25 – Representação gráfica das respostas para aplicações bilaterais com os pés esquerdo 1 e direito 1 - dimensões $108 \times 108 \times 3$.



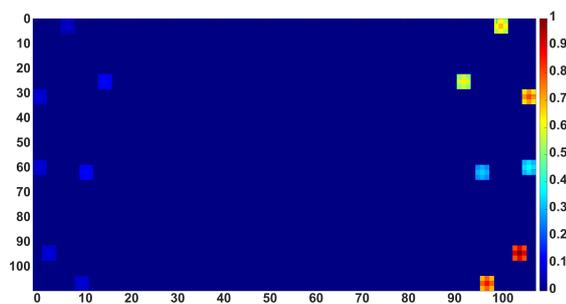
Fonte: Autoria própria.

Figura 26 – Representação gráfica das respostas com aplicações unilaterais com os pés esquerdo 1 e direito 1 com baixa resposta acoplada nos lados em que não foram aplicadas cargas - dimensões $108 \times 108 \times 3$. Em (a), tem-se a aplicação apenas no pé esquerdo 1, e em (b), a aplicação apenas no pé direito 1.

(a)



(b)



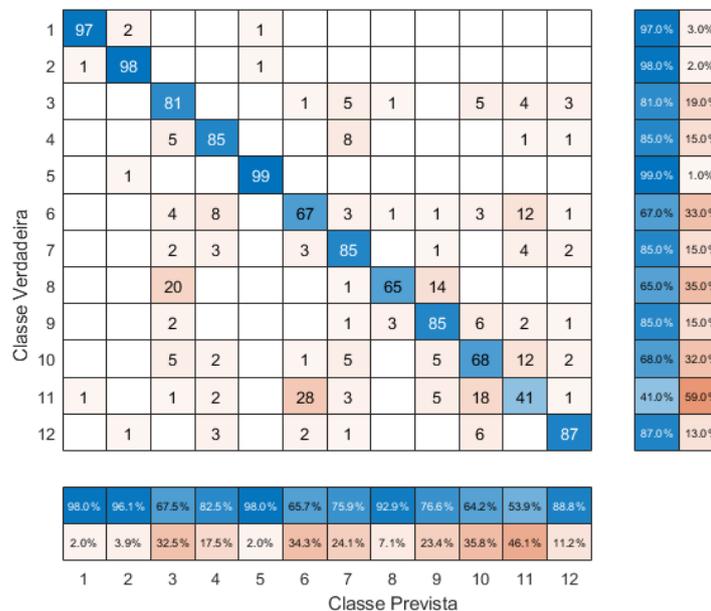
Fonte: Autoria própria.

4.3.2 Resultado unilateral - CNN

Em termos de tempo para treinamento do algoritmo, para 10 épocas e com mini *batch-size* de 16, foram necessários 29 minutos e 24 segundos para as amostras do lado esquerdo e 26 minutos e 7 segundos para o lado direito. Uma época é definida como uma passagem completa do algoritmo por todo o conjunto de dados, já o mini *batch-size* é o tamanho do lote de dados de treinamento.

As taxas de acerto globais foram de 79,83% e 77,58% para o lado esquerdo e para o lado direito, respectivamente. As matrizes de confusão (Figura 27 e Figura 28) e as tabelas com os valores de F1-Scores (Tabela 8 e Tabela 9) mostram o desempenho da CNN por classe.

Figura 27 – Matriz de confusão dos dados de validação do pé esquerdo - CNN.



Fonte: Autoria própria.

Observa-se que as classes 10 e 11, tanto para o lado esquerdo quanto para o lado direito, possuem os valores mais baixos combinados de precisão e sensibilidade, resultando nos menores F1-Scores entre todas as classes.

Também, pelas matrizes de confusão, é possível afirmar que as CNNs treinadas confundem principalmente a classe 10 com a classe 11. Contudo, a classe 11 é confundida, além da classe 10, com a classe 6.

4.3.3 Resultado bilateral - CNN

Para o treinamento bilateral com CNN, a solução encontrada foi inspirada no problema descrito e resolvido por (KENTA, 2023), que modelou o problema de reconhecimento de dígitos dividindo as imagens entre partes superiores e inferiores. No presente trabalho, são propos-

Figura 28 – Matriz de confusão dos dados de validação do pé direito - CNN.

1	98	1			1										98.0%	2.0%
2	1	99													99.0%	1.0%
3			74			1	9	7					4	5	74.0%	26.0%
4			3	53		3	32						7	2	53.0%	47.0%
5					100										100.0%	
6			2	6		64	7	1	1	3	16				64.0%	36.0%
7			1	2		2	87						6	2	87.0%	13.0%
8			9				3	81	7						81.0%	19.0%
9							6	6	74	13				1	74.0%	26.0%
10				2		1	4	1	5	60	16	11			60.0%	40.0%
11						19	3		3	21	52	2			52.0%	48.0%
12		1		3			2				4	1	89		89.0%	11.0%

99.0%	98.0%	83.1%	80.3%	99.0%	71.1%	56.9%	84.4%	82.2%	59.4%	51.0%	79.5%
1.0%	2.0%	16.9%	19.7%	1.0%	28.9%	43.1%	15.6%	17.8%	40.6%	49.0%	20.5%
1	2	3	4	5	6	7	8	9	10	11	12

Classe prevista

Fonte: Autoria própria.

Tabela 8 – Precisão, sensibilidade e F1-Scores para os pés esquerdos - CNN.

Classe	Precisão	Sensibilidade	F1-Score
1	0,970	0,980	0,9750
2	0,980	0,961	0,9704
3	0,810	0,675	0,7364
4	0,850	0,825	0,8373
5	0,990	0,980	0,9850
6	0,670	0,675	0,6634
7	0,850	0,759	0,8019
8	0,650	0,929	0,7649
9	0,850	0,766	0,8058
10	0,680	0,642	0,6605
11	0,410	0,539	0,4657
12	0,870	0,888	0,8789

Fonte: Autoria própria.

tas duas arquiteturas diferentes que utilizam os resultados combinados das CNNs unilaterais, concatenando-as e retreinando-as, obtendo uma única saída correspondente ao par de pés.

4.3.3.1 Primeira arquitetura

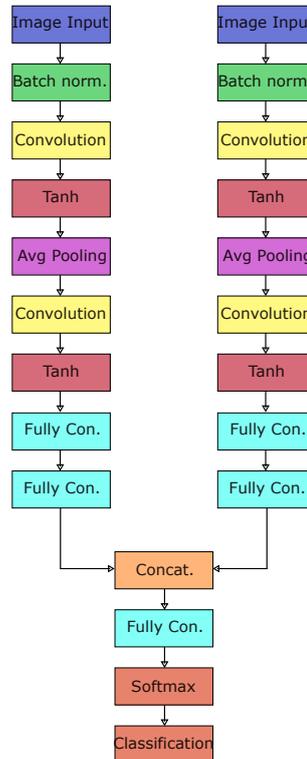
Em um primeiro momento, a rede *multi-input* é alimentada por CNNs com a mesma estrutura utilizada para o treinamento individual, mantendo-se exatamente as mesmas dimensões de cada camada. A estrutura é mostrada na Figura 29.

Tabela 9 – Precisão, sensibilidade e F1-Scores para os pés direitos - CNN.

Classe	Precisão	Sensibilidade	F1-Score
1	0,990	0,980	0,9850
2	0,980	0,990	0,9850
3	0,831	0,740	0,7829
4	0,803	0,530	0,6385
5	0,990	1	0,9950
6	0,711	0,640	0,6736
7	0,569	0,870	0,6880
8	0,844	0,810	0,8267
9	0,822	0,740	0,7788
10	0,593	0,600	0,5965
11	0,510	0,520	0,5150
12	0,795	0,890	0,8398

Fonte: Autoria própria.

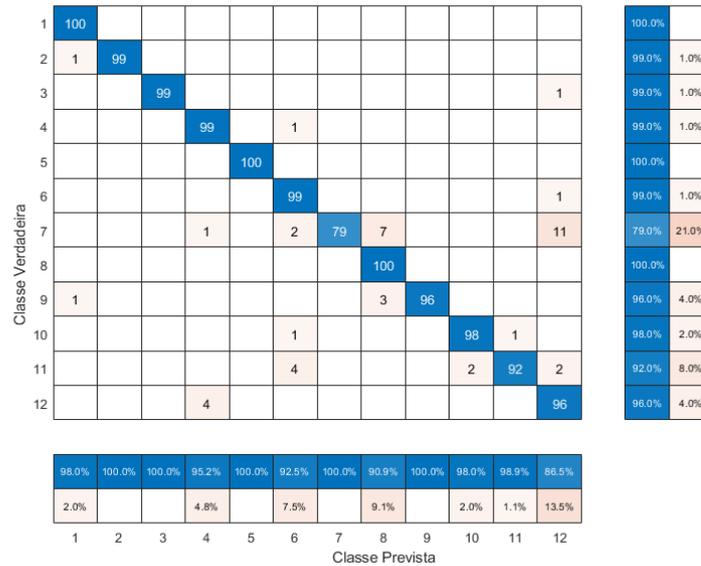
Figura 29 – Arquitetura de CNN *multi-input* proposta para obtenção de resultado bilateral.



Fonte: Autoria própria.

Para esta arquitetura, com o mini *batch-size* de 16 e 10 épocas, o tempo de treinamento total foi de 10 horas, com acurácia de 96,42%. A matriz de confusão é mostrada na Figura 30, e na Tabela 10 estão os valores de precisão e sensibilidade, bem como os F1-Scores calculados para cada classe.

Figura 30 – Matriz de confusão dos dados de validação do treinamento bilateral com CNN.



Fonte: Autoria própria.

Tabela 10 – Precisão, sensibilidade e F1-Scores do treinamento bilateral - CNN.

Classe	Precisão	Sensibilidade	F1-Score
1	1	0,980	0,9899
2	0,990	1	0,9950
3	0,990	1	0,9950
4	0,990	0,952	0,9706
5	1	1	1
6	0,990	0,952	0,9564
7	0,790	1	0,8827
8	1	0,909	0,9523
9	0,960	1	0,9796
10	0,980	0,980	0,9800
11	0,920	0,989	0,9533
12	0,960	0,865	0,9100

Fonte: Autoria própria.

4.3.3.2 Segunda arquitetura

Aplicando a técnica de ablação (MEYES *et al.*, 2019), na qual se manipula a estrutura da rede subtraindo camadas para observar o comportamento da rede após a modificação na arquitetura, retirou-se a penúltima camada plenamente conectada de cada braço das CNNs individuais, conforme é mostrado na Figura 31.

Para os dados de validação, a taxa de acerto da rede para a arquitetura proposta foi de 98,67%. O mini *batch-size* e a quantidade de épocas permaneceram iguais aos da primeira arquitetura, porém o tempo de treinamento decaiu para 1 hora. A matriz de confusão pode ser

Tabela 11 – Precisão, sensibilidade e F1-Scores bilateral da arquitetura após ablação - CNN.

Classe	Precisão	Sensibilidade	F1-Score
1	1	1	1
2	1	1	1
3	1	1	1
4	1	0,943	0,9707
5	1	1	1
6	0,950	0,979	0,9643
7	0,980	0,990	0,9850
8	1	1	1
9	1	0,980	0,9899
10	0,920	1	0,9583
11	0,990	0,980	0,9850
12	1	0,971	0,9853

Fonte: Autoria própria.

Novamente, para as duas arquiteturas, as classes 6, 10 e 11 estão entre as com menores F1-Scores, fato já observado no treinamento unilateral.

As duas arquiteturas apresentadas possuem taxas de acerto superiores a 96%, e, embora a diferença de 2% entre as duas não apresente grandes efeitos em termos práticos, o custo computacional se mostrou consideravelmente inferior após a retirada da penúltima camada convolucional. Adicionalmente, o treinamento da arquitetura proposta após a aplicação da técnica de ablação mostrou que a existência da penúltima camada plenamente conectada, além ser um gargalo em termos de processamento, é uma fonte de erro na classificação final do sistema.

4.4 Comparativo dos resultados unilaterais

Quanto ao tempo de treinamento, a SVM foi capaz de retornar resultados em tempos quase 30 vezes menores que a CNN. Ressalta-se aqui a maior carga computacional do modelo neural em relação à SVM, que envolve fatores como tipo e dimensionalidade dos dados de entrada, além da complexidade da estrutura do algoritmo.

As CNNs possuem maior complexidade estrutural se comparadas às SVMs devido às camadas e aos parâmetros que são calculados. As operações de convolução, pooling e ativação de uma CNN, por exemplo, resultam em complexidade estrutural maior, que exigem operações matriciais mais custosas computacionalmente, se comparadas à busca por um hiperplano ótimo que separa classes a partir de operações matriciais mais simples e cálculos de produto escalar, como propõe a SVM.

Outro fator a ser considerado é o tipo do dado de entrada dos modelos propostos. Enquanto a SVM utiliza matrizes (portanto, dados tabulares) como dados de entrada, a CNN é alimentada por imagens, dados com maior dimensionalidade e aumentam os custos computacionais para o treinamento.

Comparando também os F1-Scores para os treinamentos individuais dos pés esquerdos e direitos, tem-se:

Tabela 12 – Diferença entre os F1-Scores para os pés esquerdos - SVM e CNN.

Classe	F1-Score _{SVM}	F1-Score _{CNN}	F1-Score _{SVM} - F1-Score _{CNN}
1	1	0,9750	0,0250
2	1	0,9704	0,0296
3	1	0,7364	0,2636
4	0,9394	0,8373	0,1021
5	0,9950	0,9850	0,0100
6	0,9024	0,6634	0,2390
7	0,9754	0,8019	0,1735
8	0,8247	0,7649	0,0598
9	0,9311	0,8058	0,1253
10	0,9500	0,6605	0,2895
11	0,8665	0,4657	0,4008
12	0,9428	0,8789	0,0639

Fonte: Autoria própria.

Tabela 13 – F1-Scores para cada os pés direitos - SVM e CNN.

Classe	F1-Score _{SVM}	F1-Score _{CNN}	F1-Score _{SVM} - F1-Score _{CNN}
1	1	0,9850	0,0015
2	1	0,9850	0,0015
3	1	0,7829	0,2171
4	1	0,6385	0,3615
5	0,9650	0,9950	-0,030
6	0,9699	0,6736	0,2946
7	0,9550	0,6880	0,2670
8	0,8752	0,8267	0,0485
9	0,8808	0,7788	0,1020
10	0,6200	0,5965	0,0235
11	0,7260	0,5150	0,2110
12	0,9550	0,8398	0,1152

Fonte: Autoria própria.

O algoritmo baseado em CNN supera a SVM apenas para o pé direito 5. Ademais, o restante das subtrações entre os F1-Scores dos dois algoritmos indica maior vantagem de desempenho da SVM em relação à CNN para as classes 11, 10, 3 e 6 dos pés esquerdos, e 4, 6, 7 e 11 dos pés direitos.

4.5 Comparativo dos resultados bilaterais

Diferentemente do que foi observado nos resultados unilaterais, para os resultados bilaterais a CNN foi superior à SVM em quase todos os casos para as duas arquiteturas propostas, como mostram as Tabelas 14 e 15:

Tabela 14 – F1-Scores para cada o caso bilateral - SVM e CNN.

Classe	F1-Score _{SVM}	F1-Score _{CNN}	F1-Score _{SVM} - F1-Score _{CNN}
1	1	0,9899	0,0101
2	1	0,9950	0,0050
3	1	0,9950	0,0050
4	0,8040	0,9706	-0,1666
5	0,9900	1	-0,0100
6	0,7926	0,9564	-0,1638
7	0,9169	0,8827	0,0342
8	0,7581	0,9523	-0,1942
9	0,7574	0,9796	-0,2222
10	0,7879	0,9800	-0,1921
11	0,7602	0,9533	-0,1931
12	0,7560	0,9100	-0,1540

Fonte: Autoria própria.

Tabela 15 – F1-Scores para o caso bilateral - SVM e CNN após a ablação.

Classe	F1-Score _{SVM}	F1-Score _{CNN_{ab.}}	F1-Score _{SVM} - F1-Score _{CNN_{ab.}}
1	1	1	0
2	1	1	0
3	1	1	0
4	0,8040	0,9707	-0,1667
5	0,9900	1	-0,0100
6	0,7926	0,9643	-0,1717
7	0,9169	0,9850	-0,0681
8	0,7581	1	-0,2419
9	0,7574	0,9899	-0,2325
10	0,7879	0,9583	-0,1704
11	0,7602	0,9850	-0,2248
12	0,7560	0,9853	-0,2203

Fonte: Autoria própria.

No geral, o desempenho superior da CNN para o caso bilateral se deu às arquiteturas propostas utilizarem como entradas duas redes pré-treinadas, o que reduz o erro do algoritmo aplicado. Adicionalmente, a entrada para sinais bilaterais da SVM pode ter introduzido características que o kernel utilizado não foi capaz de diferenciar, o que foi resolvido para a CNN pelas sucessivas camadas de convolução e pooling. Para a arquitetura proposta após a ablação, o desempenho ainda melhor se justifica pela retirada de uma camada plenamente conectada que adicionava erro ao treinamento.

5 CONCLUSÃO

5.1 Considerações

O trabalho mostrou que a instrumentação da placa sensora com FBGs gera respostas adequadas para a finalidade proposta: a distinção de pisadas humanas para reconhecimento biométrico. Quanto ao processo de fabricação da placa, o silicone utilizado para o encapsulamento das FBGs evita a influência de mudanças de temperatura, além de proteger contra rupturas sem comprometer as respostas das redes que se mostraram adequadas para o funcionamento do sistema. O sistema é capaz de gerar respostas distintas para diferentes pés, demonstrando robustez inclusive para variações de carga, que simulam pressões diferentes aplicadas pelo mesmo pé. Para aplicações reais, tal característica se apresenta como uma vantagem - um mesmo indivíduo pode distribuir a pressão plantar de diferentes formas, a depender do posicionamento dos pés sobre a plataforma ou de uma variação de peso corporal, por exemplo. Estes dados são passados para o treinamento dos sistemas de reconhecimento a partir de valores normalizados para deslocamentos de comprimento de onda tanto numericamente, quanto graficamente.

Um dos principais gargalos para o treinamento de algoritmos de reconhecimento de padrão envolvendo aprendizado de máquina reside na necessidade de uma grande quantidade de amostras. Isto foi superado com a geração de amostras obtidas a partir do comportamento médio das respostas dos sensores, pautado na confiabilidade dos processos de instrumentação e coleta de dados para aplicações de diferentes perfis.

Foi possível modelar o problema de forma que dois algoritmos com abordagens de classificação diferentes fossem utilizados: uma SVM para dados numéricos organizados matricialmente, e uma CNN quando estes dados são convertidos em mapas de pressão plantares. Tanto SVM quanto CNN foram capazes de autenticar biometricamente os 12 indivíduos considerando-se aplicações unilaterais, com taxas de acerto superiores a 90% e 77%, respectivamente. Para aplicações bilaterais, diante de outro gargalo para treinamento de algoritmos de aprendizado de máquina - o custo computacional, foi proposta uma arquitetura que concatena as redes unilaterais já treinadas para a obtenção do resultado bilateral. A utilização de redes convolucionais pré-treinadas como entradas de uma camada final de classificação aumenta o número de parâmetros utilizados para a classificação do par de pés. Este fato, somado ao processo de retreinamento para a classificação final do sistema bilateral, ajudam a explicar o aumento nas taxas de acerto do sistema com CNN. Por fim, durante a investigação da influência das camadas convolucionais na arquitetura *multi-input*, concluiu-se que a penúltima camada convolucional de cada entrada contribui para a inserção de erro no sistema e aumenta notadamente o custo computacional.

Em comparação ao que foi reportado na literatura, o sistema proposto apresenta vantagens quanto à baixa complexidade do método de coleta. De forma complementar, a utilização de

sensores em fibras óticas em detrimento a sensores resistivos e capacitivos, possibilita o uso da capacidade de multiplexação e eliminação do risco adicional de interferência eletromagnética. Contudo, é pertinente pontuar a fragilidade do sistema dada a conexão com o interrogador e a fonte dada unicamente via fibra ótica. Já quanto aos algoritmos empregados para o reconhecimento de padrão, muito embora a adição de novas classes exija o retreinamento dos algoritmos, o presente trabalho possui como principal vantagem a ausência de necessidade de múltiplas etapas de pré-processamento, além de taxas de acerto superiores para o resultado bilateral da CNN.

Além do sistema de identificação proposto, que contempla a placa sensora e os algoritmos de reconhecimento de padrão aplicados, o banco de dados construído pode servir de referência para estudos de outros tipos de sistemas que analisam pegadas, como análise postural ou monitoramento da marcha.

5.1.1 Trabalhos futuros

Uma das linhas de continuidade deste trabalho se concentra na comparação do sistema de aquisição de pressão plantar proposto com outros sistemas comerciais, para validação dos padrões de pressão plantar obtidos, habilitando o sistema para aplicações em outras áreas, como a área médica, por exemplo.

Outra possibilidade reside na reutilização do banco de dados para o treinamento de outras redes neurais que aceitam imagens como entradas, para posterior comparação das métricas obtidas e, conseqüentemente, dos algoritmos empregados.

Por fim, também é possível para trabalhos futuros a alimentação do banco de dados disponibilizado com a inserção de novas classes.

REFERÊNCIAS

- ABE, S. **Support Vector Machines for Pattern Classification**. [S.l.: s.n.], 2005.
- AL-FAKIH, E.; OSMAN, N. A. A.; ADIKAN, F. R. M. The use of fiber bragg grating sensors in biomechanics and rehabilitation applications: The state-of-the-art and ongoing research topics. **Sensors**, MDPI AG, v. 12, n. 10, p. 12890–12926, Set. 2012.
- BALAMEENAKSHI, S.; SUMATHI, S. Biometric recognition of newborns: Identification using footprints. *In: Proceedings of 2013 IEEE Conference on Information and Communication Technologies (ICT 2013)*. [S.l.]: IEEE, 2013.
- BULDT, A. K. *et al.* Foot posture is associated with plantar pressure during gait: A comparison of normal, planus and cavus feet. **Gait & Posture**, Elsevier, v. 62, p. 235–240, Maio 2018.
- CAI, C.; LI, B. Training deep convolution network with synthetic data for architectural morphological prototype classification. **Frontiers of Architectural Research**, v. 10, n. 2, p. 304–316, 2021.
- DHIR, V. *et al.* Biometric recognition: a modern era for security. **International Journal of Engineering Science and Technology**, v. 2, p. 3364–3380, Ago. 2010.
- EL-ABED, M.; CHARRIER, C.; ROSENBERGER, C. Evaluation of biometric systems. *In: New Trends and Developments in Biometrics*. [S.l.]: InTech, 2012.
- FANT, G. **Acoustic Theory of Speech Production**. 2. ed. The Hague: Mouton, 1960. 323 p.
- FENG, Y.; GE, Y.; SONG, Q. A human identification method based on dynamic plantar pressure distribution. *In: 2011 IEEE International Conference on Information and Automation*. Shenzhen: IEEE, 2011. p. 329–332.
- GIRAO, N. S. **Palmilha Sensora para a Identificação do Formato do Pé**. 2019. 80 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Curitiba, 2019.
- GIRAO, N. S. **Footprint Database**: Banco de dados com imagens de footprints. 2023. Disponível em: <https://github.com/nsoares-g/footprint/>.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016.
- HERNANDEZ, M. E. *et al.* A correlation-based framework for evaluating postural control stochastic dynamics. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, IEEE, v. 24, n. 5, p. 551–561, Mai. 2016.
- HERSCHEL, S. W. J. **The Origin of Finger-Printing**. London: Oxford University Press, 1916.
- HUBEL, D.; WIESEL, T. Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex. **Journal of Physiology**, v. 160, p. 106–154, 1962.
- HUBEL, D. H.; WIESEL, T. N.; LEVAY, S. Plasticity of ocular dominance columns in monkey striate cortex. **Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences**, The Royal Society, v. 278, n. 961, p. 377–409, 1977.
- JAIN, A.; HONG, L.; PANKANTI, S. Biometric identification. **Communications of the ACM**, ACM, v. 43, n. 2, p. 90–98, Fev. 2000.

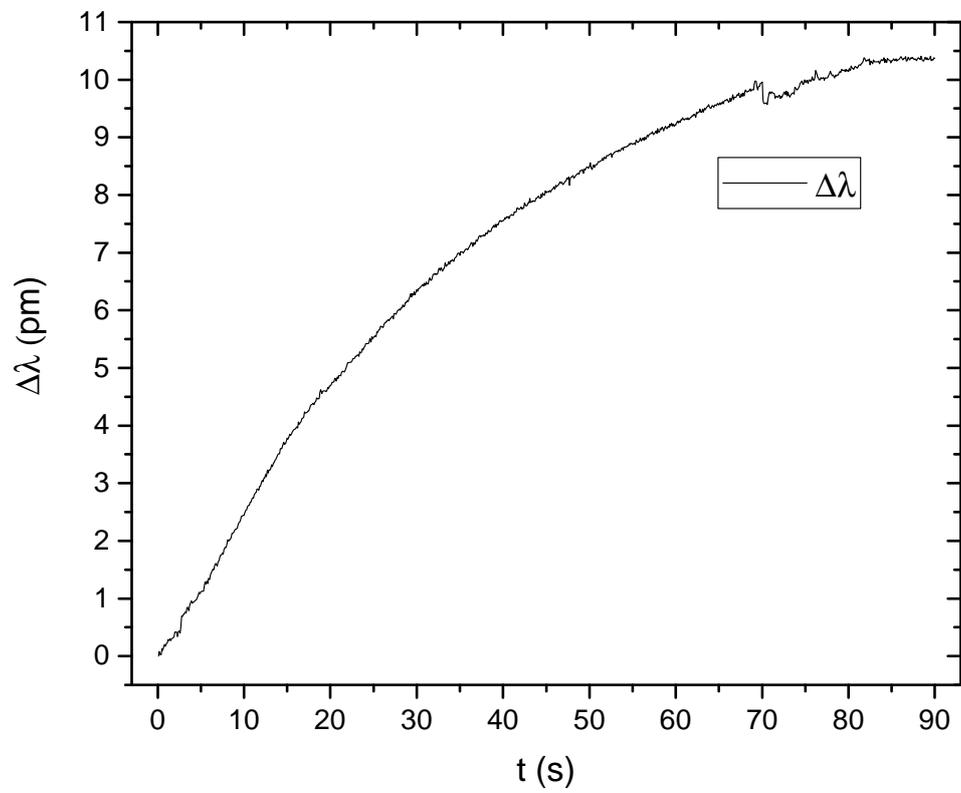
- JUNG, J.-W. *et al.* Dynamic-footprint based person identification using mat-type pressure sensor. *In: Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.]: IEEE, 2003.
- JUNG, J.-W.; SATO, T.; BIEN, Z. Unconstrained person recognition method using dynamic footprint. *In: Proceedings of International Conference on Fuzzy Information Processing 2003*. [S.l.: s.n.], 2003. v. 2, p. 531–536.
- JUNG, J.-W.; SATO, T.; BIEN, Z. Dynamic footprint-based person recognition method using a hidden markov model and a neural network. **International JOURNAL of Intelligent Systems**, Wiley, v. 19, n. 11, p. 1127–1141, 2004.
- KEATSAMARN, T. *et al.* Optical-based foot plantar pressure measurement for system potential application in human postural control measurement and person identification. **Sensors**, MDPI AG, v. 21, n. 21, Jun. 2021. Art. no. 4437.
- KENNEDY, R. B. Uniqueness of bare feet and its use as a possible means of identification. **Forensic Science International**, Elsevier, v. 82, n. 1, p. 81–87, Set. 1996.
- KENTA, I. **Image Classification using CNN with Multi Input using MATLAB**. 2023. Disponível em: <https://github.com/Kentaltakura/Image-Classification-using-CNN-with-Multi-Input-using-MATLAB>.
- KERSEY, A. D. A Review of Recent Developments in Fiber Optic Sensor Technology. **Optical Fiber Technology**, v. 2, n. 3, p. 291–317, 1996.
- KHOKHER, R.; SINGH, R. C. Footprint identification: Review of an emerging biometric trait. **Macromolecular Symposia**, Wiley, v. 397, n. 1, Jun. 2021. Art. no. 2000246.
- KRISHAN, K.; KANCHAN, T. Identification: Prints – footprints. *In: Encyclopedia of Forensic and Legal Medicine*. 2. ed. [S.l.]: Elsevier, 2016. p. 81–91. Editor(s): Jason Payne-James and Roger W. Byard.
- KUMAR, V. A. *et al.* Intruder identification using footprint recognition with PCA and SVM classifiers. **Advanced Materials Research**, Trans Tech Publications, v. 984-985, p. 1345–1349, Jul. 2014.
- LECUN, Y. *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, Institute of Electrical and Electronics Engineers (IEEE), v. 86, n. 11, p. 2278–2324, 1998.
- LIN, C.-J. *et al.* Multiple convolutional neural networks fusion using improved fuzzy integral for facial emotion recognition. **Applied Sciences**, v. 9, n. 13, 2019. Art. no. 2593.
- LIU, E. Infant footprint recognition. *In: 2017 IEEE International Conference on Computer Vision (ICCV)*. [S.l.]: IEEE, 2017.
- LU, P.; MEN, L.; CHEN, Q. Resolving cross sensitivity of fiber bragg gratings with different polymeric coatings. **Applied Physics Letters**, AIP Publishing, v. 92, n. 17, Apr. 2008. Art. no. 171112.
- MAKIHARA, Y. *et al.* The ou-isir gait database comprising the treadmill dataset. **IPSJ Transactions on Computer Vision and Applications**, v. 4, p. 53–62, 2012.
- MENADIÉ, C.; KISSINGER, C.; ADKINS, H. **The fotonic sensor: Analysis and design (complex adaptive systems)**. Massachusetts, USA: Instrum & Control Systems, 1967. v. 40. 114 p.

- MEYES, R. *et al.* **Ablation Studies in Artificial Neural Networks**. [S.l.]: arXiv, 2019. Art. no. 1901.08644.
- NAGWANSHI, K. Cyber-forensic review of human footprint and gait for personal identification. **IAENG International Journal of Computer Science**, v. 46, p. 645–661, Nov. 2019.
- NAKAJIMA, K. *et al.* Footprint-based personal recognition. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 47, n. 11, p. 1534–1537, 2000.
- NEDOMA, J. *et al.* Encapsulation of fbg sensor into the pdms and its effect on spectral and temperature characteristics. **Advances in Electrical and Electronic Engineering**, v. 14, Nov. 2016.
- OTHONOS, A.; KALLI, K. **Fiber Bragg Gratings: Fundamentals and Applications in Telecommunications and Sensing**. [S.l.]: Artech House Optoelectronics Library, 1999. 433 p.
- PEREIRA, D. C. A. **Sensores de fibra óptica baseados em redes de Bragg para monitorização ambiental e estrutural**. 2003. 105 p. Dissertação (Mestrado) — Faculdade de Ciências do Porto, Porto, 2003.
- ROBBINS, L. M. **Footprints: Collection, analysis and interpretation**. [S.l.]: Springfield, 1985. v. 72. Art. no. 225.
- SAHOTA, J. K.; GUPTA, N.; DHAWAN, D. Fiber bragg grating sensors for monitoring of physical parameters: a comprehensive review. **Optical Engineering**, SPIE, v. 59, n. 06, p. 1, Jun. 2020.
- SCHÖLKOPF, B.; SMOLA, A. J. **Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond**. [S.l.]: MIT Press, 2002.
- SHAWE-TAYLOR, J.; CRISTIANINI, N. **Kernel Methods for Pattern Analysis**. [S.l.]: Cambridge University Press, 2004.
- SHIRAGA, K. *et al.* Geinet: View-invariant gait recognition using a convolutional neural network. *In: 2016 International Conference on Biometrics (ICB)*. [S.l.: s.n.], 2016. p. 1–8.
- SHIVANANJU, B. N. *et al.* CO2 sensing at room temperature using carbon nanotubes coated core fiber bragg grating. **Review of Scientific Instruments**, AIP Publishing, v. 84, n. 6, Jun. 2013. Art. no. 065002.
- TAKEDA, T. *et al.* Biometric personal authentication by one step foot pressure distribution change by load distribution sensor. *In: 2009 IEEE International Conference on Fuzzy Systems*. [S.l.]: IEEE, 2009. p. 906–910.
- TAKEMURA, N. *et al.* On input/output architectures for convolutional neural network-based cross-view gait recognition. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 29, n. 9, p. 2708–2719, 2019.
- UHL, A.; WILD, P. Footprint-based biometric verification. **Journal of Electronic Imaging**, SPIE, v. 17, n. 1, Jan. 2008. Art. no. 011016.
- VAPNIK, V. **The Nature of Statistical Learning Theory**. [S.l.]: Springer, 1995.

APÊNDICES

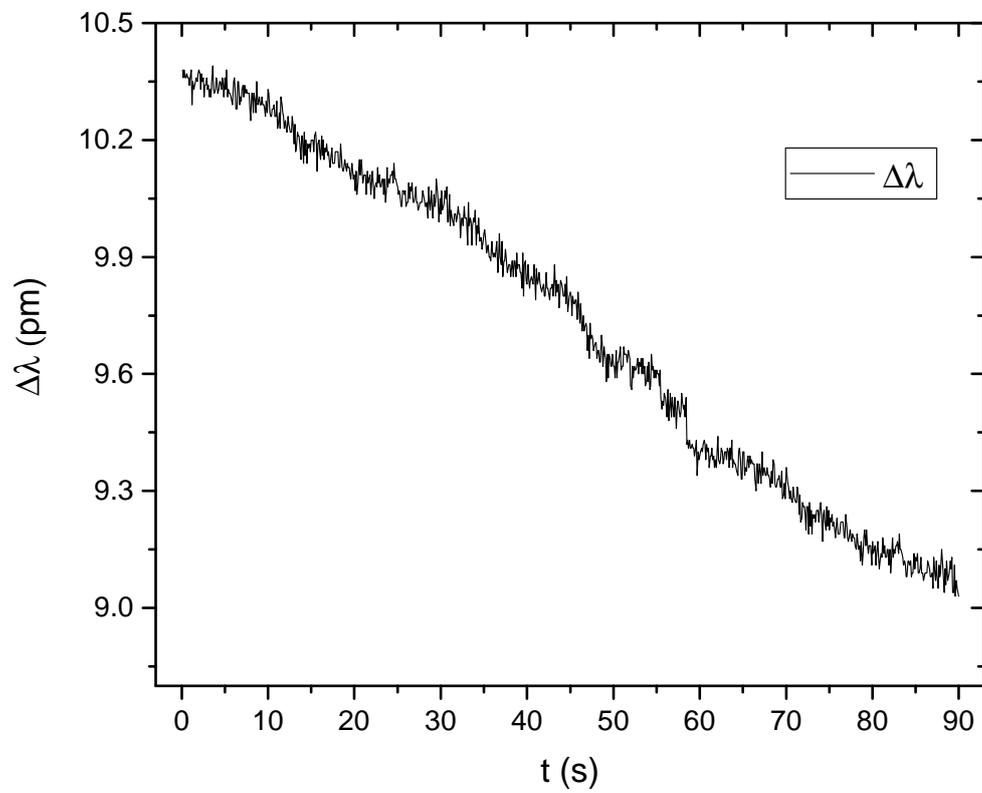
**APÊNDICE A – Testes de temperatura com $\Delta T = 3 \text{ }^\circ\text{C}$ após o
encapsulamento das FBGs**

Figura 33 – Deslocamento de comprimento de onda no processo de aquecimento.



Fonte: Autoria própria.

Figura 34 – Deslocamento de comprimento de onda no processo de resfriamento.



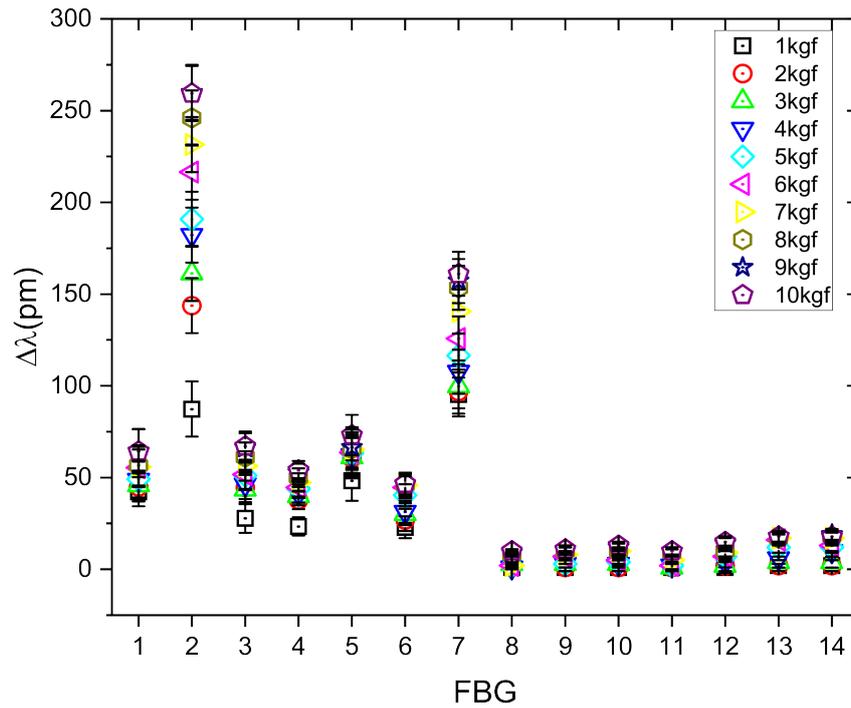
Fonte: Autoria própria.

**APÊNDICE B – Deslocamento no comprimento de onda de Bragg das
FBGs quando da aplicação com aumento gradual de carga sobre as FBGs**

2 à 7 e 9 à 14

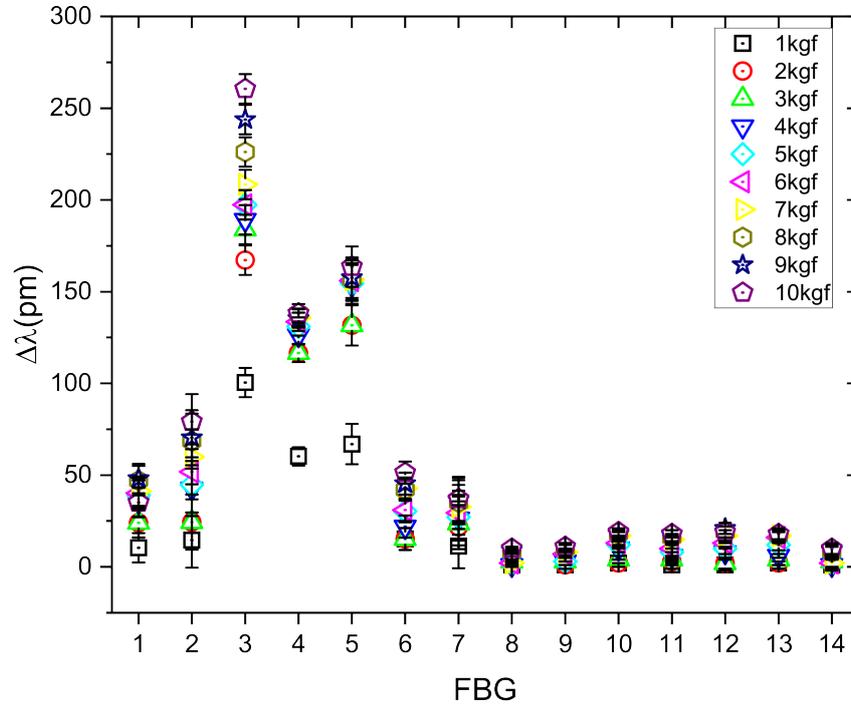
Nas Figuras 35 à 40 e 47 à 52, os gráficos à esquerda representam o deslocamento no comprimento de onda de Bragg quando da aplicação com aumento gradual de carga. A localização aproximada da aplicação das cargas está ilustrada nas figuras à direita.

Figura 35 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 2.



Fonte: Autoria própria.

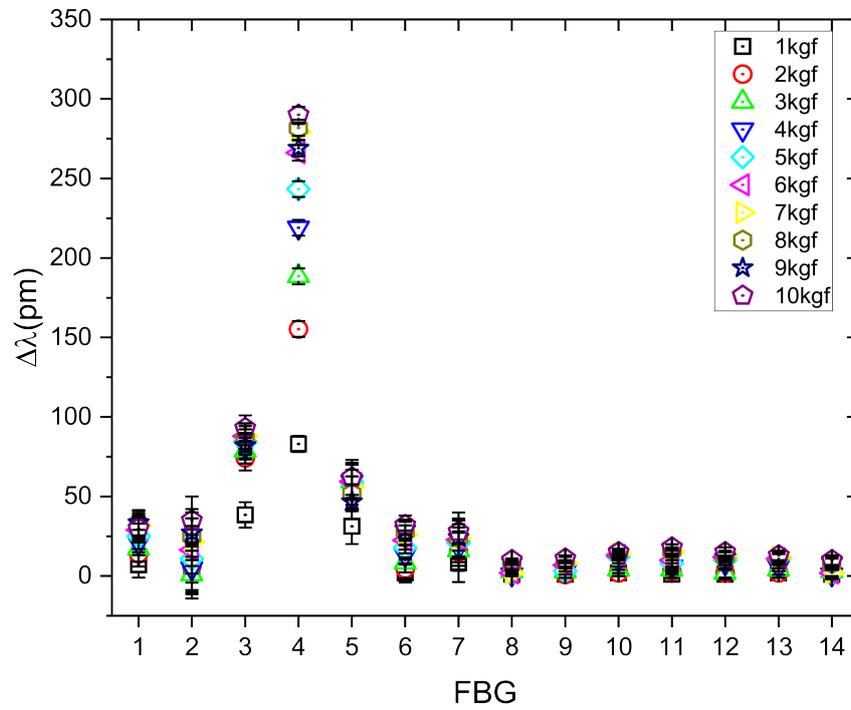
Figura 36 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 3.



Fonte: Autoria própria.

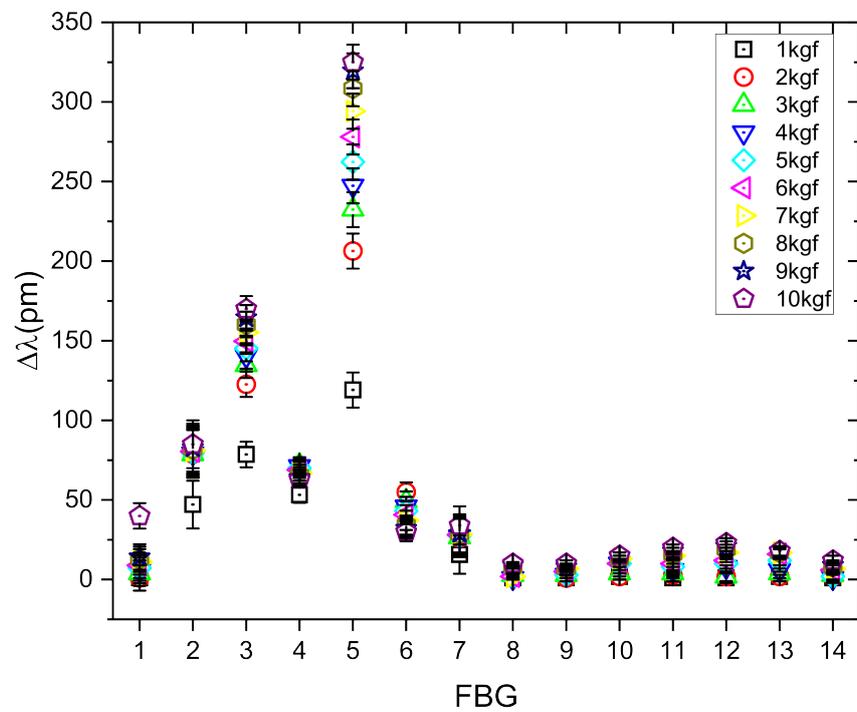
Nas Figuras 41 à 46 e 53 à 58, observa-se as curvas de resposta das FBGs para cargas aplicadas em modo crescente nas FBGs 2 à 7 e 9 à 14. As linhas conectando os pontos são somente guias visuais.

Figura 37 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 4.



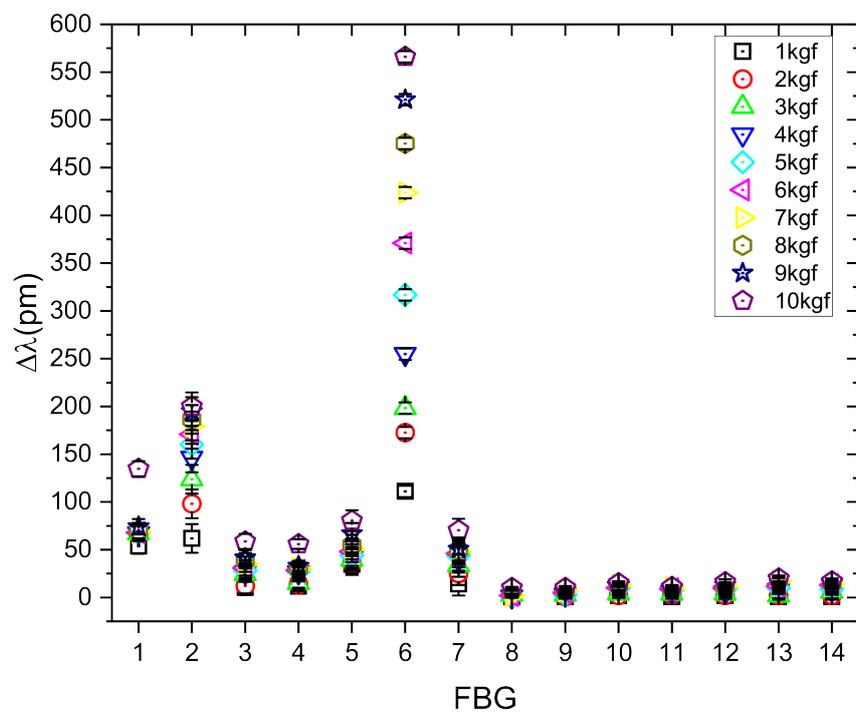
Fonte: Autoria própria.

Figura 38 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 5.



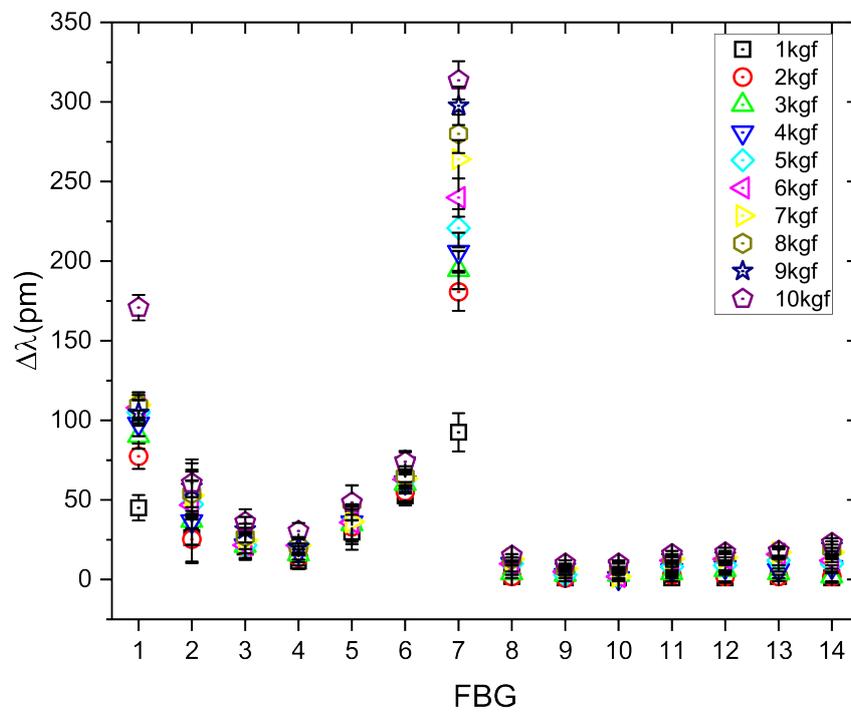
Fonte: Autoria própria.

Figura 39 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 6.



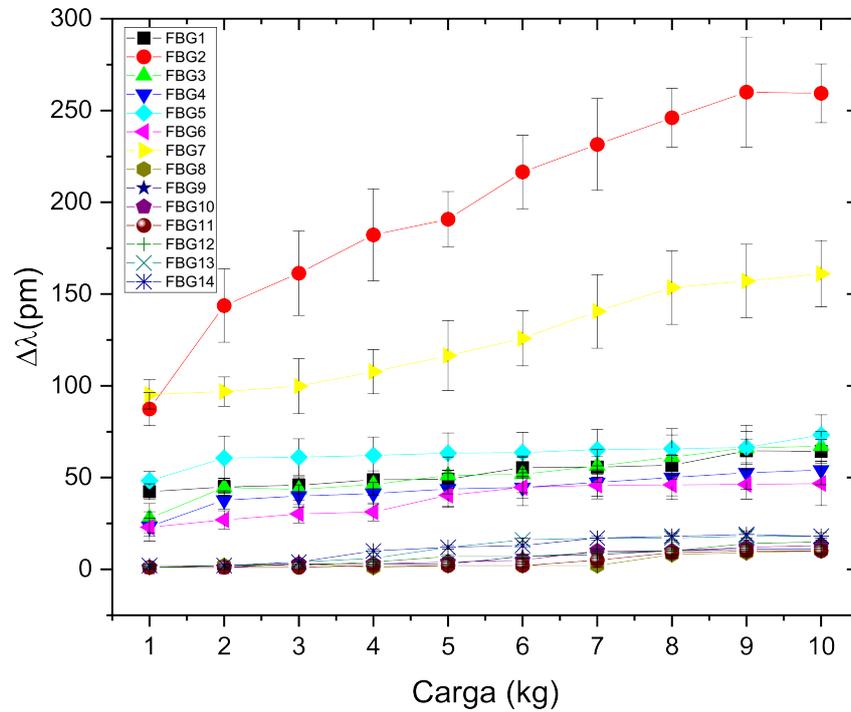
Fonte: Autoria própria.

Figura 40 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 7.



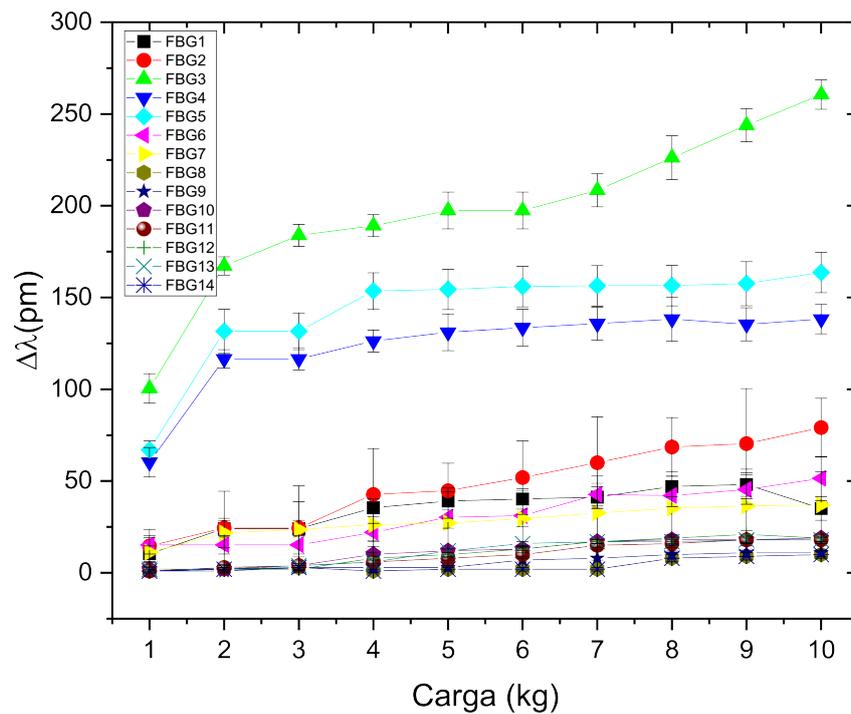
Fonte: Autoria própria.

Figura 41 – Curvas de resposta das FBGs para cargas aplicadas na FBG 2.



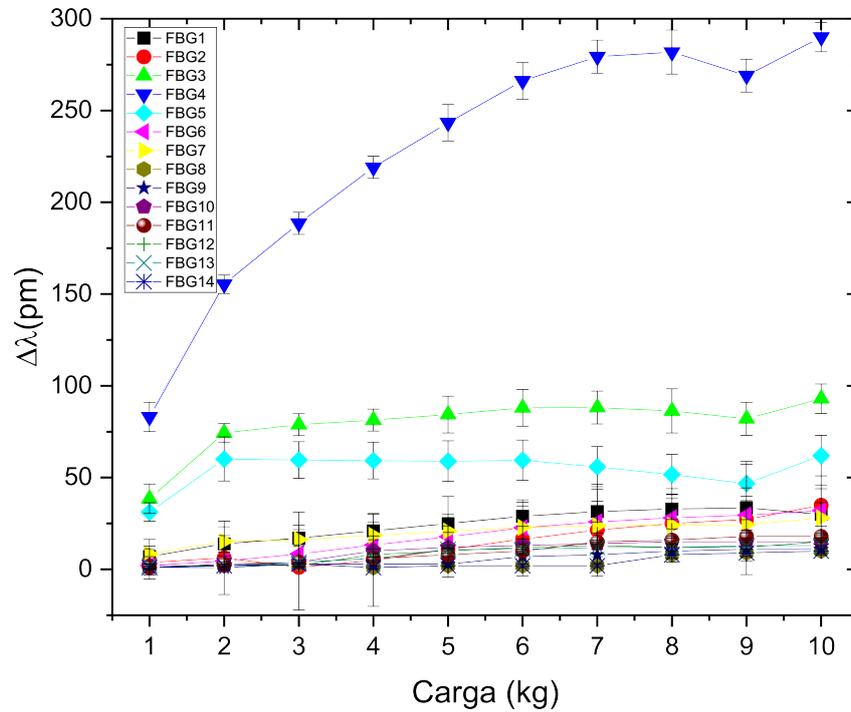
Fonte: Autoria própria.

Figura 42 – Curvas de resposta das FBGs para cargas aplicadas na FBG 3.



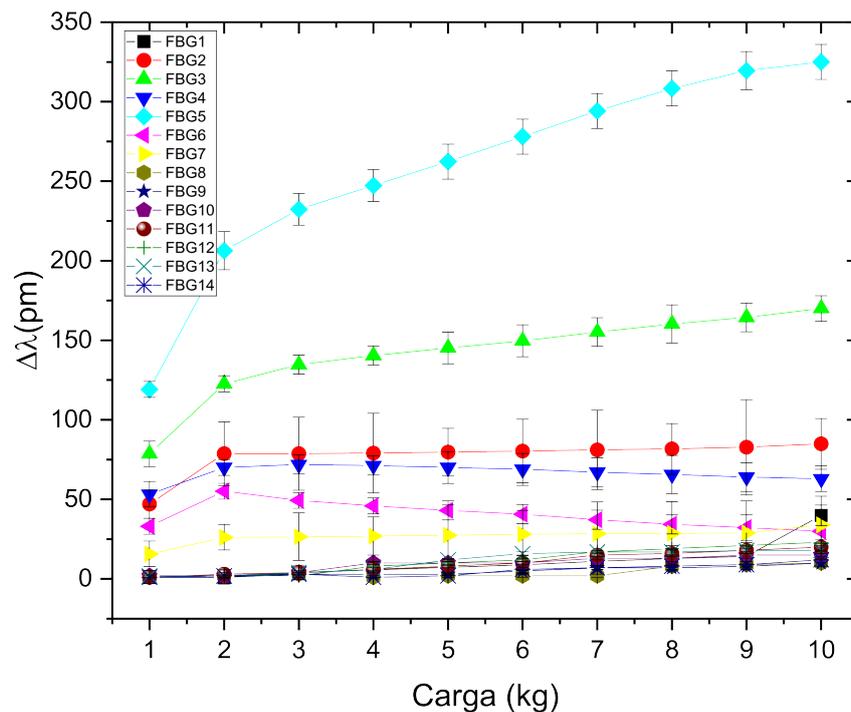
Fonte: Autoria própria.

Figura 43 – Curvas de resposta das FBGs para cargas aplicadas na FBG 4.



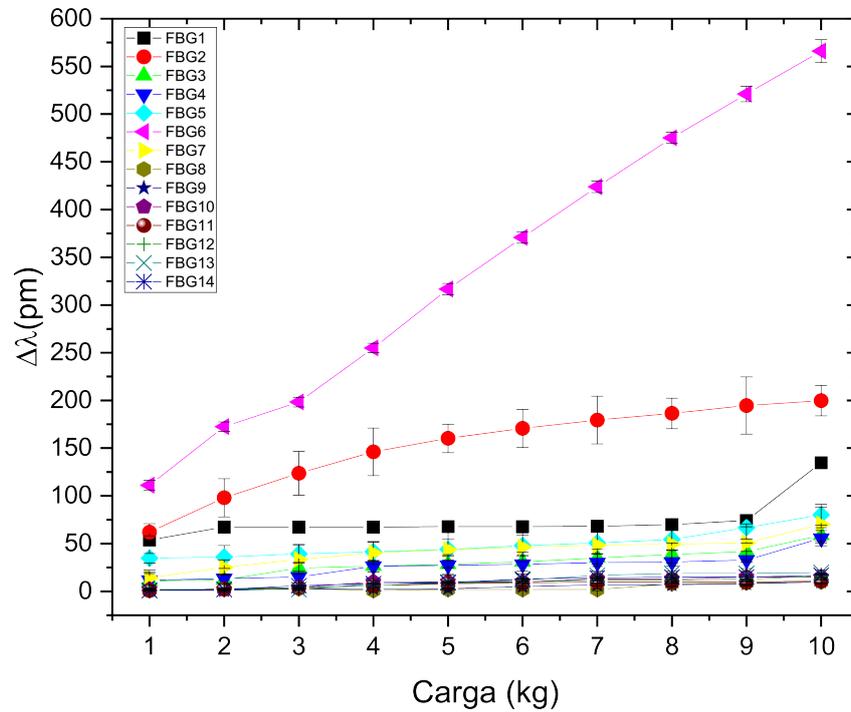
Fonte: Autoria própria.

Figura 44 – Curvas de resposta das FBGs para cargas aplicadas na FBG 5.



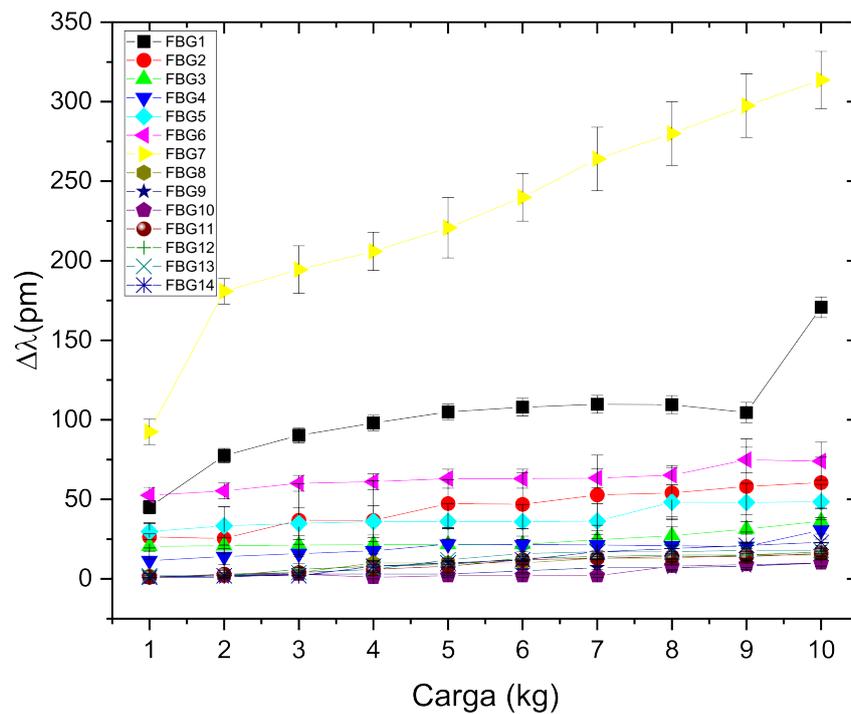
Fonte: Autoria própria.

Figura 45 – Curvas de resposta das FBGs para cargas aplicadas na FBG 6.



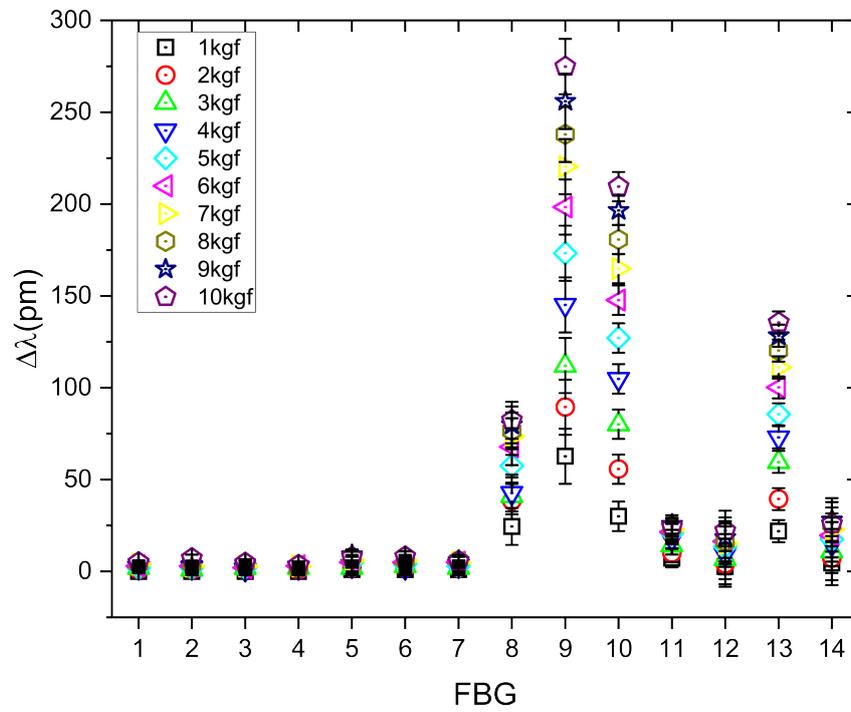
Fonte: Autoria própria.

Figura 46 – Curvas de resposta das FBGs para cargas aplicadas na FBG 7.



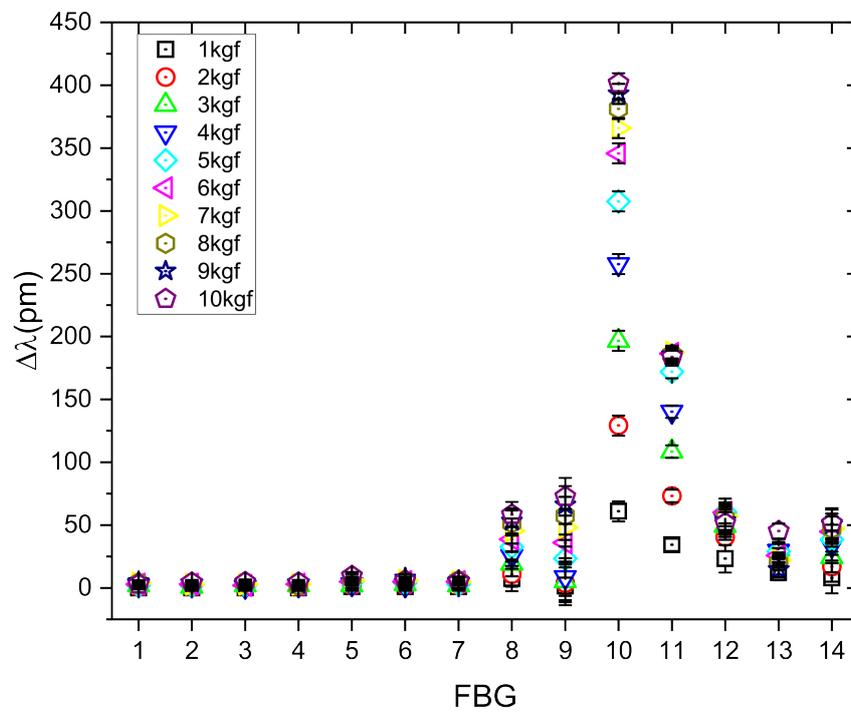
Fonte: Autoria própria.

Figura 47 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 9.



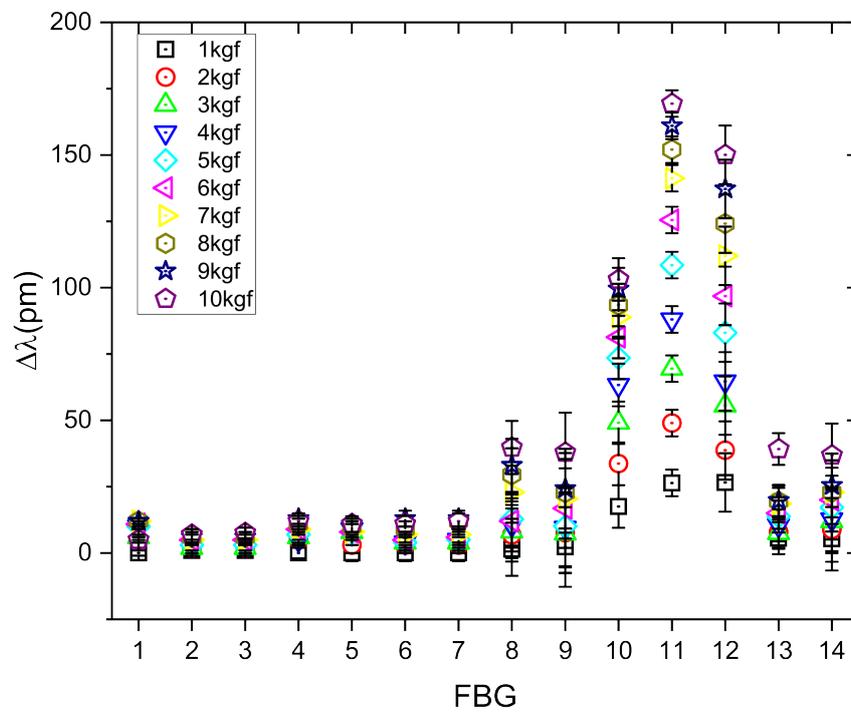
Fonte: Autoria própria.

Figura 48 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 10.



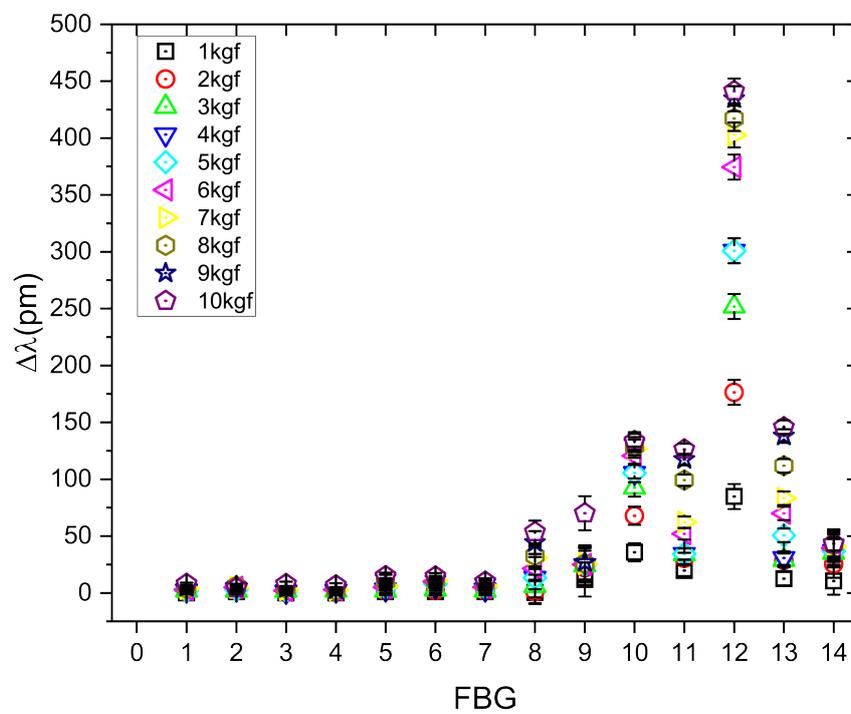
Fonte: Autoria própria.

Figura 49 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 11.



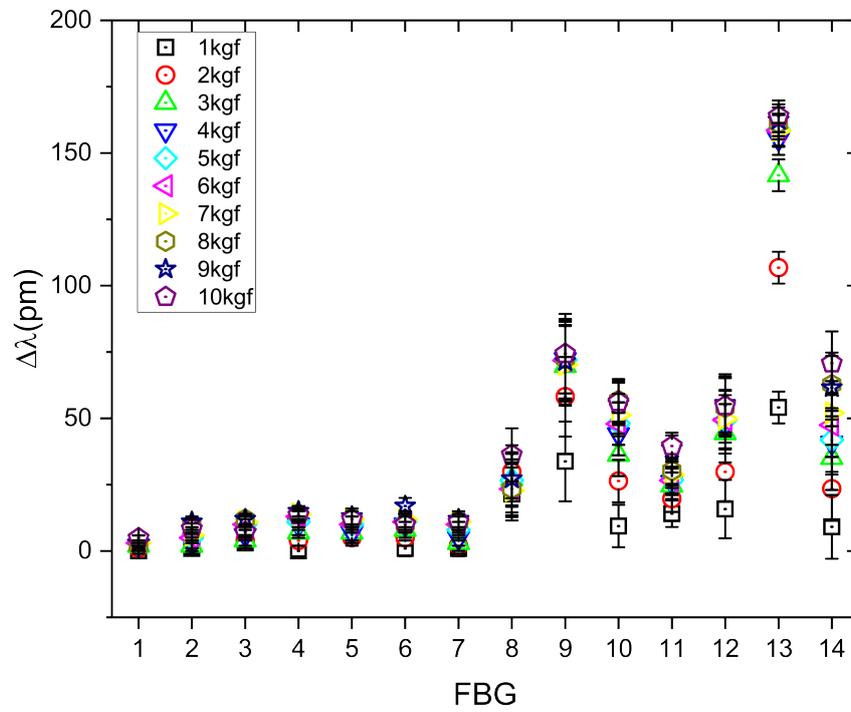
Fonte: Autoria própria.

Figura 50 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 12.



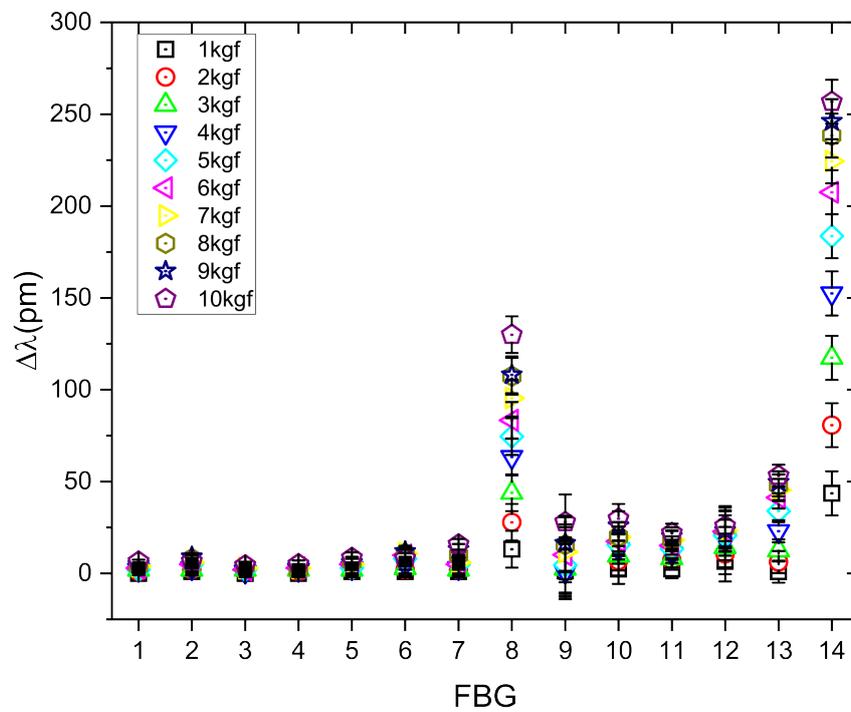
Fonte: Autoria própria.

Figura 51 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 13.



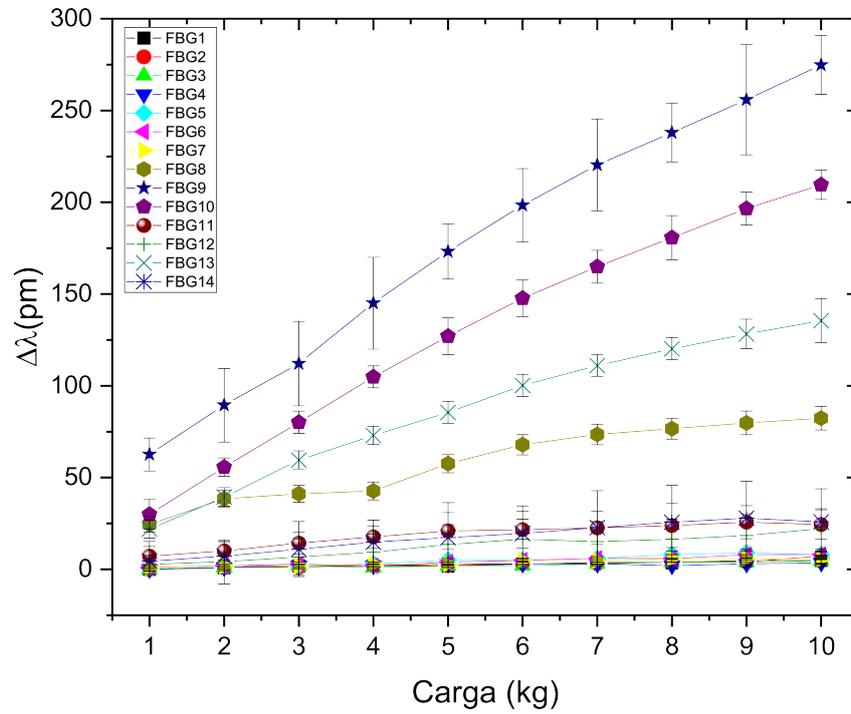
Fonte: Autoria própria.

Figura 52 – Deslocamento no comprimento de onda de Bragg das FBGs quando da aplicação na FBG 14.



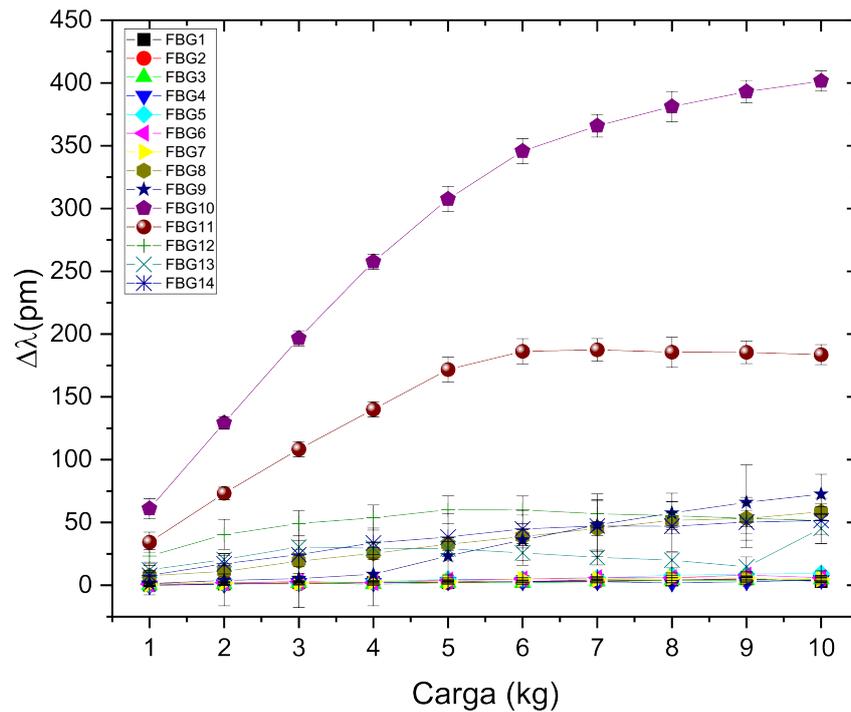
Fonte: Autoria própria.

Figura 53 – Curvas de resposta das FBGs para cargas aplicadas na FBG 9.



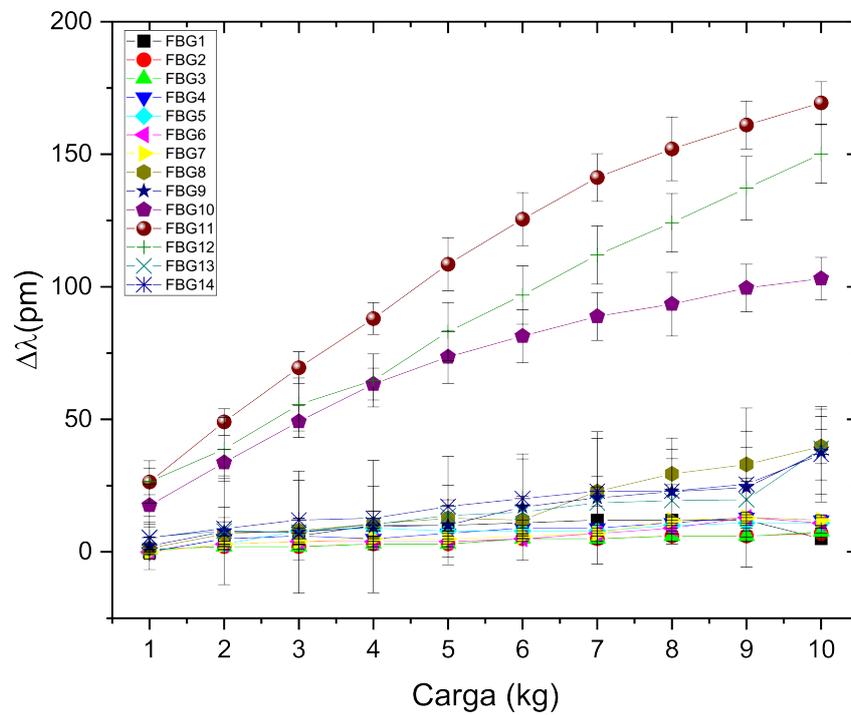
Fonte: Autoria própria.

Figura 54 – Curvas de resposta das FBGs para cargas aplicadas na FBG 10.



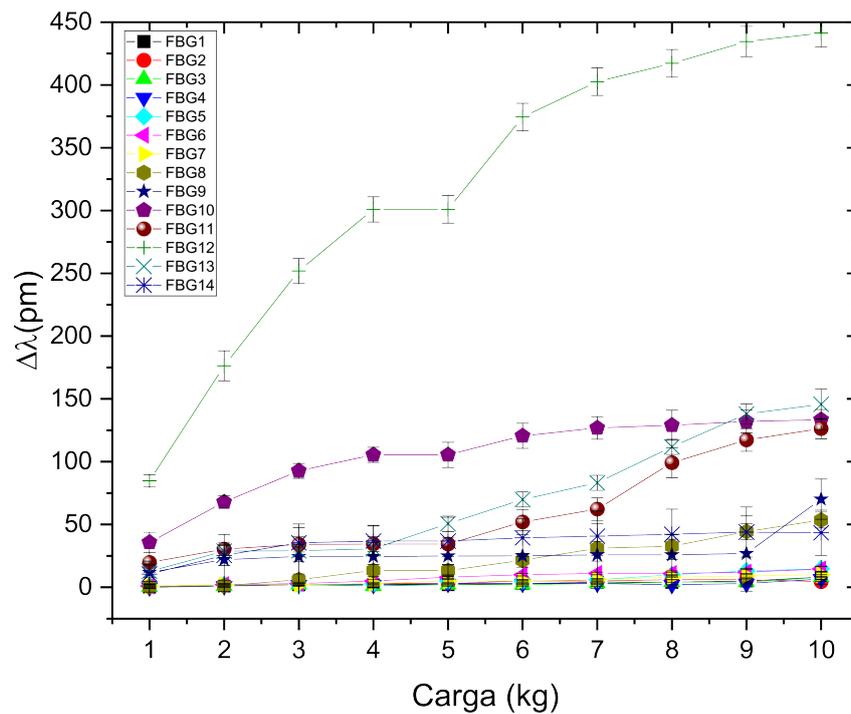
Fonte: Autoria própria.

Figura 55 – Curvas de resposta das FBGs para cargas aplicadas na FBG 11.



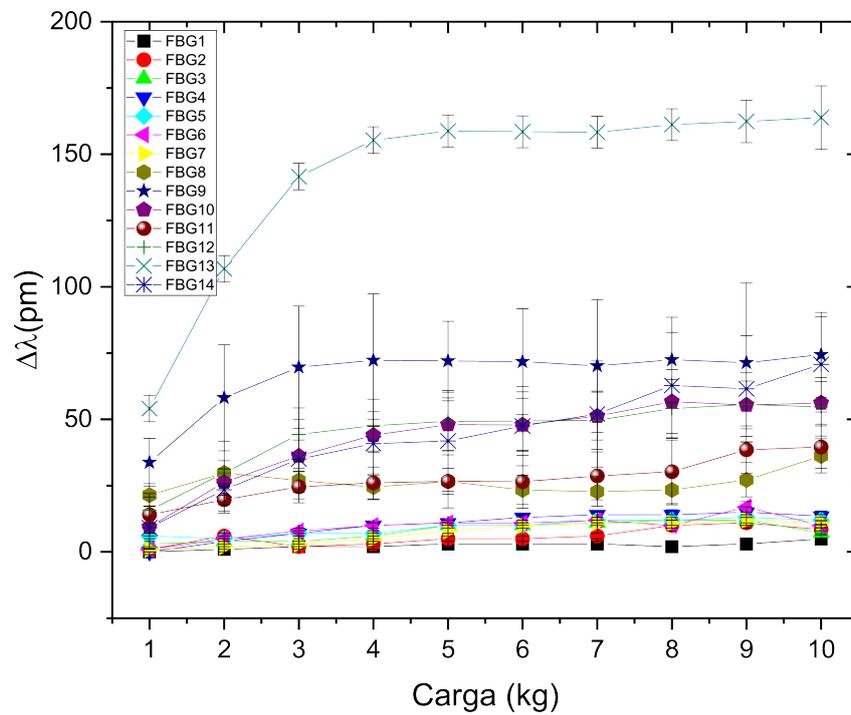
Fonte: Autoria própria.

Figura 56 – Curvas de resposta das FBGs para cargas aplicadas na FBG 12.



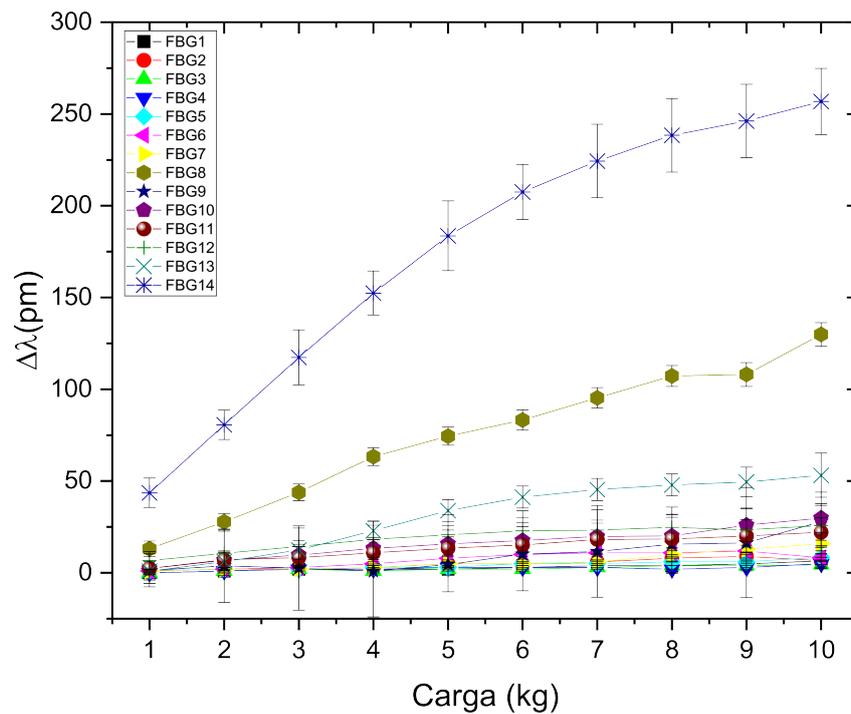
Fonte: Autoria própria.

Figura 57 – Curvas de resposta das FBGs para cargas aplicadas na FBG 13.



Fonte: Autoria própria.

Figura 58 – Curvas de resposta das FBGs para cargas aplicadas na FBG 14.



Fonte: Autoria própria.

APÊNDICE C – Publicações resultantes deste trabalho

Listam-se neste apêndice os trabalhos publicados em periódicos e em anais de eventos:

01: GIRÃO, N. S.; MULLER, M.; DE ARRUDA, L. V. R. A New Biometric Identification System Based on Plantar Pressure. **IEEE Sensors Journal**, IEEE. DOI: 10.1109/JSEN.2023.3286255.

02: GIRÃO, N. S.; MULLER, M.; DE ARRUDA, L. V. R. Desenvolvimento de Sistema Sensor Para Reconhecimento Biométrico Baseado Em Pressão Plantar. *In* 20^º SBMO - Simpósio Brasileiro de Microondas e Optoeletrônica e 15^º CBMAG - Congresso Brasileiro de Eletromagnetismo. [S.l.: s.n.], 2022. p. 1-3.

03: LUGARINI, D.; GIRÃO, N. S.; DE ARRUDA, L. V. R.; FABRIS, J. L.; MULLER, M. Foot Type Recognition with Multiplexed Optical Fiber Macro-Bend Sensors. *in* Optical Fiber Sensors Conference 2020 Special Edition. OSA, 2020. p. T3.14.