

# Mapeamento de Forças com Sistema Baseado em Sensores de Macrocurvatura em Fibras Óticas

Vinícius de Carvalho, André Eugênio Lazzaretti, José Luís Fabris, Marcia Muller

Universidade Tecnológica Federal do Paraná

Curitiba, Brasil

crvlh.v@gmail.com, lazzaretti@utfpr.edu.br, fabris@utfpr.edu.br, mmuller@utfpr.edu.br

**Resumo**—Nesse trabalho apresentam-se detalhes da construção e resultados da caracterização de uma placa sensora instrumentada com 3 sensores de macrocurvatura em fibra ótica em série e multiplexados. Uma estrutura rígida retangular com 150 cm<sup>2</sup> foi utilizada na monitoração da magnitude e posição de uma única força entre 100 gf e 2000 gf aplicada sobre sua superfície. Foram consideradas seis regiões de sensoriamento preestabelecidas. A interrogação dos sensores é realizada por meio da leitura do espectro de transmissão do sistema entre 400-720 nm. Para processamento dos dados, foram aplicados modelos de regressão lineares baseados em Rede Elástica e Vetores Suporte. Com objetivo de garantir baixo custo computacional, foi avaliado o potencial de redução de variáveis preditivas na análise dos modelos. Considerando a capacidade de sensoriamento na etapa de teste, que simulava operação efetiva do sistema, foram detectados erros absolutos médios de monitoração de 177 gf na predição da magnitude da força e 2,41 cm na predição da posição da força. Entendendo a estrutura composta por seis áreas de mesmas dimensões, em 87,5% das amostras a força foi predita na área correta, além disso o sistema detectou a magnitude da força com erros inferiores a 300 gf também em 87,5% das amostras.

**Palavras-chave**—sensores óticos; sensores multiplexados; macrocurvatura em fibra ótica; modelos de regressão.

## I. INTRODUÇÃO

Sistemas de mapeamento de força têm sido propostos recorrentemente em tecnologias relacionadas à monitoração da integridade de estruturas e em sistemas robóticos [1], [2]. Métodos de sensoriamento voltados a monitorar a condição de componentes estruturais na indústria aeroespacial e na engenharia civil atuam para que medidas de reparo ou substituição sejam aplicadas, promovendo a redução de custos e o aumento da segurança de operações [3], [4]. Na robótica a implementação de sensores para mapeamento de forças é justificada pela crescente complexidade das atividades desenvolvidas por robôs, como por exemplo a realização de tarefas médicas onde existe necessidade de identificação da posição de aplicação de força em instrumentos [5], [6]. Uma característica relevante para essas monitorações se refere à capacidade de multiplexação dos sensores [7]. Redes de sensores multiplexados para monitoração *quasi*-distribuída têm contribuído para simplificação de sistemas de sensoriamento, justificando estudos abordando técnicas de interrogação e demodulação voltadas a sensores multiplexados [8], [9].

Sistemas com sensores em fibras óticas aplicados à monitoração de diferentes parâmetros são atraentes devido

a vantagens como pequeno tamanho, alta velocidade de operação, resistência à corrosão e imunidade à interferência eletromagnética, características que os permitem operar sob condições que seriam inadequadas para outros sensores [10]. No que se refere a sensores óticos aplicados em sensoriamento *quasi*-distribuído de forças, as características intrínsecas das redes de Bragg em fibra (FBGs) foram recentemente exploradas [11], [12].

A capacidade de multiplexação de um arranjo contendo seis sensores de força baseados em macrocurvaturas em fibras óticas foi demonstrada em 2019 [13]. O sistema foi aplicado na detecção de configurações de cargas depositadas diretamente sobre cada um dos 6 sensores conectados em série que compunham o arranjo. Os sensores de macrocurvatura foram produzidos em fibra ótica padrão de telecomunicações e interrogados na região espectral do visível num regime multimodal de operação. Os espectros de transmissão detectados pelo espectrômetro no UV-VIS foram analisados usando modelos de regressão lineares. No mesmo trabalho, foi indicada a possibilidade de redução de variáveis características, associadas aos comprimentos de onda, sem perda significativa de informação no sinal detectado [13].

O aumento da complexidade dos sistemas, seja ela pela monitoração simultânea de parâmetros distintos ou grande número de sensores, gerou a necessidade de aplicação de métodos capazes de realizar o tratamento de grandes conjuntos de dados. Neste sentido, o aprimoramento de métodos estatísticos e de modelos preditivos baseados em regressão ou classificação têm contribuído para a implementação de algoritmos de aprendizagem voltados ao processamento de sinais decorrentes de sensores [14], [15]. Na literatura existem diversas propostas que abordam a utilização de modelos de reconhecimento de padrões aplicados em dados obtidos por sensores voltados à monitoração estrutural [16]. Omenzetter e Lautour em 2010 implementaram algoritmos de classificação multiclasse para aprendizagem supervisionada baseados em *Nearest Neighbor* em conjunto a dados reduzidos por Análise de Componentes Principais (PCA). Para distinção de estados de segurança de estruturas, os dados utilizados na pesquisa foram detectados por múltiplos acelerômetros fixados em uma estrutura de teste [17]. Em 2006, Cowie e outros pesquisadores demonstraram um sistema capaz de monitorar a posição de uma carga sobre uma estrutura bidimensional utilizando nove FBGs. A detecção da posição da carga foi realizada com

base no treinamento de uma Rede Neural Artificial. Entre as limitações apontadas no trabalho constam a sensibilidade dos transdutores a variações de temperatura, e a consequente necessidade de lidar com a sensibilidade cruzada [18].

Este trabalho propõe a utilização de sensores de macrocurvatura em fibra ótica similares àqueles reportados por [13], com o intuito de realizar a monitoração de força aplicada sobre uma placa com um número de sensores menor do que o número de áreas de sensoriamento. O sistema de monitoração de força é constituído por uma placa sensora rígida instrumentada com somente três sensores. A resposta acoplada dos sensores multiplexados é utilizada na identificação da posição e magnitude de uma força individual aplicada sobre a placa em uma das seis diferentes regiões de sensoriamento predefinidas. Métodos preditivos baseados em regressão são aplicados ao conjunto de dados formado pelos espectros de transmissão do conjunto de sensores.

## II. METODOLOGIA

São apresentadas as características construtivas tanto dos sensores quanto da placa de sensoriamento e a metodologia utilizada para a organização dos conjuntos de dados voltados à caracterização e avaliação do sistema. São também apresentados aspectos conceituais e teóricos dos modelos de regressão responsáveis pelo processamento do sinal ótico resultante da operação do sistema.

### A. Sistema experimental

O sistema experimental, representado na Figura 1a, é composto por três sensores conectados em série fixados entre duas placas de polimetilmetacrilato retangulares com comprimento  $(30,0 \pm 0,1)$  cm, largura de  $(10,0 \pm 0,1)$  cm e espessura de  $(0,5 \pm 0,1)$  cm. Cada sensor consiste num anel de fibra ótica (SSMF, G-652, Draktel) com diâmetro de  $(0,5 \pm 0,1)$  cm, encapsulado em um cilindro de material elastomérico. Próximo às extremidades da estrutura, entre as placas, foram fixados elementos elastômeros cúbicos com função de aumentar a estabilidade mecânica da estrutura monitorada. Na superfície superior da estrutura foram preestabelecidas seis áreas de sensoriamento onde foram aplicadas individualmente diferentes forças. Cada uma dessas áreas é associada a uma coordenada que corresponde à distância desde o ponto central da respectiva área até uma das extremidades da estrutura, como apresenta a Figura 1b. Sob essa métrica, as coordenadas das posições dos elementos sensores são 7,5 cm, 15,0 cm e 22,5 cm. O sistema de interrogação é formado por uma fonte de luz branca (LS-1 Tungsten halogen lamp, Ocean Optics, 360 a 2000 nm) e um espectrômetro UV-Vis (HR4000 com resolução de 6,2 nm). A luz da fonte é acoplada ao sistema e transmitida pelos três sensores conectados em série. Mudanças espectrais ocorrem em cada elemento sensor devido à macrocurvatura do anel de fibra, sendo que a luz transmitida pelo primeiro sensor é o sinal de entrada para o segundo sensor e assim por diante. Quando qualquer um dos sensores é sujeito a uma deformação devido a uma força aplicada sobre a superfície da placa, alterações espectrais são observadas no espectro

transmitido pelo conjunto que é detectado pelo espectrômetro. Essa característica contribui para o processo de multiplexação pois no espectro resultante do sistema existe informação acerca da operação de cada um dos sensores, sem necessidade de separar os sinais após a recepção [13].

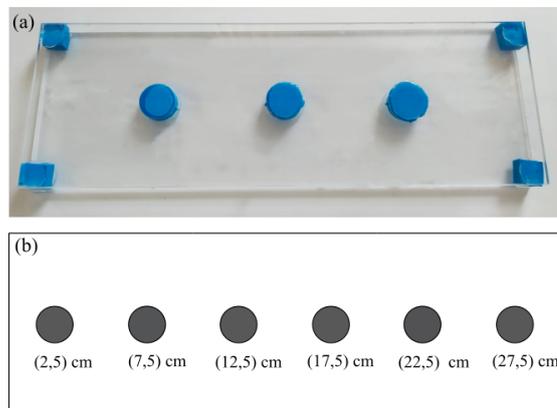


Fig. 1. (a) Placa de sensoriamento com sistema multiplexado. (b) Diagrama esquemático da placa de sensoriamento indicando as áreas de aplicação de força preestabelecidas.

As mudanças espectrais ocorrem de acordo com a configuração de força responsável pela deformação dos sensores, sendo que uma configuração de força é caracterizada pela magnitude e posição de aplicação da força. Para forças com magnitudes entre 100 gf e 2000 gf, foram utilizados pesos padronizados depositados sobre as áreas de sensoriamento da estrutura. Para avaliar a resistência mecânica dos elementos sensores, transdutores semelhantes aos instalados na placa foram submetidos à forças progressivas de até 4000 gf sem constatação de quebra da fibra ótica. Testes realizados com diferentes configurações de força indicaram a repetibilidade do sistema com a manutenção das características espectrais que são fundamentais para a operação do sistema.

### B. Organização dos conjuntos de dados

Para a avaliação da capacidade de sensoriamento foram estabelecidos dois conjuntos de dados. Cada amostra destes conjuntos é associada à resposta espectral frente a uma configuração de força aplicada sobre a estrutura, ou seja, cada amostra contém as intensidades óticas em 1229 comprimentos de onda na faixa espectral (400 - 720) nm. Estas intensidades foram utilizadas como variáveis características para implementação dos métodos computacionais. Com isso, a organização dos dados é feita por matrizes compostas por colunas associadas a comprimentos de onda, e linhas referentes às intensidades de cada amostra. O primeiro conjunto de dados, exclusivo para etapas de treinamento e validação, contém 72 amostras sendo 70% dessas voltadas a treinamento (50 amostras) e 30% voltadas à validação *hold-out* (22 amostras). O segundo conjunto, exclusivo para teste, contém 24 amostras e são decorrentes de medidas tomadas 20 minutos após a aquisição dos dados de treinamento; com isso entende-se que os dados de teste simulam a operação efetiva do sistema.

As configurações de força utilizadas foram determinadas e ordenadas aleatoriamente.

### C. Processamento do sinal ótico

Foram avaliados modelos preditivos baseados em Regressão por Rede Elástica e Regressão por Vetores Suporte (SVR), sendo o segundo aplicado em conjunto à Análise de Componentes Principais (PCA). Todas as implementações foram realizadas em Matlab (R2018b, Mathworks Inc., MA, USA).

O algoritmo de Rede Elástica, que tem base em Regressão por Mínimos Quadrados, caracteriza-se por determinar os coeficientes de regressão linear,  $\beta$ , através de um problema de otimização descrito por (1), onde  $y$  se refere ao valor alvo,  $x$  à variável preditiva,  $m$  ao número de observações e  $p$  ao número de variáveis preditivas,

$$\beta = \arg \min_{\beta} \sum_{i=1}^m [y_i - (\beta_0 + x_i \beta_i)]^2 + (1 - \alpha) \sum_{j=1}^p |\beta_j| + \alpha \sum_{j=1}^p |\beta_j|^2 \quad (1)$$

com  $\alpha = (\lambda_2/\lambda_1 + \lambda_2)$ , onde  $\lambda_1$  e  $\lambda_2$  são parâmetros de penalização. Tem-se que o problema de minimização é composto por duas penalizações, sendo a primeira do tipo  $L_2$ , associado ao modelo Ridge e a segunda, do tipo  $L_1$  associado ao modelo LASSO, capaz de zerar coeficientes reduzindo o número de variáveis preditivas. Nota-se que o parâmetro  $\alpha$  se refere à contribuição das penalizações e, portanto, é capaz de determinar a dimensionalidade dos dados [23].

O modelo de Regressão por Vetores Suporte (SVR) busca determinar uma função do tipo representado em (2),

$$f(x) = \mathbf{w} \cdot \mathbf{x} - b \quad (2)$$

onde  $\mathbf{w}$  é um vetor de pesos associados às variáveis características  $x$ , e  $b$  é um parâmetro de bias associado aos erros preditivos e que permite generalização frente aos dados de treinamento. A formulação do modelo de SVR, permite a determinação de margens, ou planos suporte, afastados de  $\epsilon$  em relação à curva de ajuste. Com isso, determina-se um  $\epsilon$ -tube onde espera-se que constem os pontos amostrais. A permissividade a erros é determinada por parâmetros de folga  $\xi$  e  $\xi^*$  associados a distâncias ortogonais em relação aos planos suporte. A Figura 2 representa a operação de modelos de SVR. Com as condições apresentadas, o problema de otimização assume a forma apresentada em (3), onde  $C$  é responsável por determinar a tolerância quanto a medidas fora do  $\epsilon$ -tube, sendo essas as únicas amostras penalizadas [24].

$$\min_{\mathbf{w}} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad (3)$$

$$\text{sujeito a } \begin{cases} y_i - \mathbf{w} \cdot x_i - b \leq \epsilon + \xi_i \\ \mathbf{w} \cdot x_i + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

Em vista que sozinho o modelo SVR não é capaz de reduzir o número de variáveis características, os dados de entrada foram tratados por Análise de Componentes Principais (PCA).

Tal técnica determina componentes principais não relacionadas de modo que, quanto mais próxima à primeira componente principal, maior a variância dos dados iniciais explicada por essa componente principal.

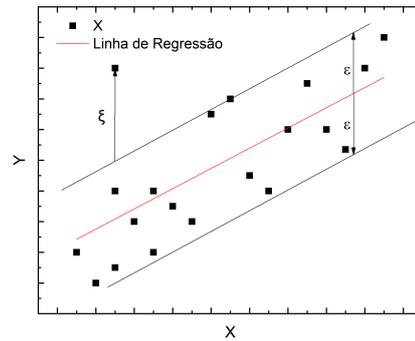


Fig. 2. Representação da operação de um modelo de regressão linear baseado em vetores suporte.

Após a implementação da PCA é necessário determinar o número de componentes principais investigados para uso nos modelos de aprendizagem. Essa escolha está associada à quantidade de informação fornecida para operação. Para isso são utilizados critérios como selecionar apenas componentes com grande importância ou predeterminar um total de variância explicada requerida [25].

### III. RESULTADOS

As macrocurvaturas promovem alterações na potência ótica guiada no núcleo da fibra, sejam elas resultantes de Perda Pura por Curvatura [19], Perdas por Transição [20] ou Ressonâncias de Modos de Galeria Sussurrantes (WGM). Os WGM são responsáveis pelo reacoplamento da potência ótica no núcleo devido a reflexões que ocorrem principalmente na interface casca-revestimento [21]. Esses fenômenos associados a vazamentos e reacoplamentos de modos têm eficiências determinadas pela estrutura de curvatura do guia e pelo comprimento de onda da luz transmitida [22], e são verificados pois, na faixa espectral de operação adotada (400 nm - 720 nm), a fibra convencional utilizada opera em regime multimodal.

Durante o mapeamento de uma força individual aplicada sobre a superfície rígida, deformações são produzidas nos elementos sensores do arranjo. Estas deformações, associadas à magnitude e à posição da força aplicada, promovem alterações nas condições de propagação nas macrocurvaturas, determinando as características espectrais do sinal de banda larga transmitido.

Uma análise preliminar foi realizada antes da instalação do conjunto de sensores na placa sensora, com objetivo de avaliar a capacidade de sensoriamento de forças do conjunto. A Figura 3 apresenta os espectros de transmissão resultantes da aplicação de cargas entre 500 gf a 2000 gf em variações de 500 gf, posicionadas individualmente e diretamente sobre a superfície superior de cada um dos três sensores. Espectros de transmissão diferentes são obtidos para uma mesma força

aplicada sobre elementos sensores distintos do sistema, resultado que demonstra a possibilidade de identificação da posição da aplicação da força com base no sinal óptico transmitido.

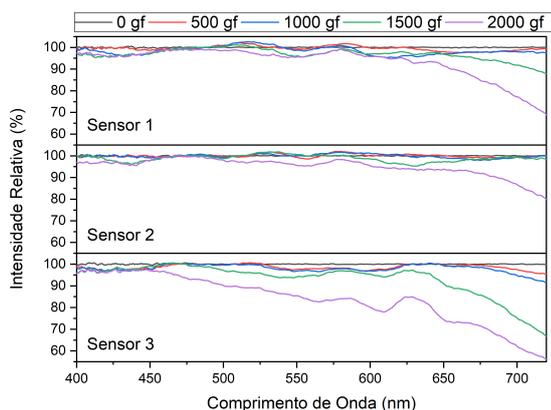


Fig. 3. Espectros de transmissão do conjunto de sensores para diferentes cargas aplicadas individualmente e diretamente sobre cada um dos sensores.

Após a instalação do conjunto de sensores na placa, a repetibilidade do sistema foi avaliada por meio da aplicação de uma determinada configuração de força, em intervalos de tempo fixos e regulares. Cinco configurações de força aleatoriamente escolhidas, apresentadas na Tabela I, foram aplicadas ordenadamente sobre a estrutura em intervalos de 20 minutos.

TABELA I  
CONFIGURAÇÕES DE FORÇA APLICADAS SOBRE A PLACA SENSORA PARA ANÁLISE DE REPETIBILIDADE.

Configuração	Posição (cm)	Magnitude (gf)
1	27,5	1000
2	22,5	600
3	27,5	400
4	17,5	200
5	22,5	1500

Os resultados obtidos não indicam variações significativas nos espectros que impossibilitem o mapeamento da força sobre a estrutura com base no sinal óptico transmitido. Os espectros de transmissão, sujeitos às flutuações de intensidade ótica inerentes a fonte, são apresentados na Figura 4. Cada espectro corresponde à média de três medições e as barras de erro são os desvios padrões experimentais.

Utilizando o conjunto de dados de treinamento e validação, o modelo de regressão por Rede Elástica foi implementado com o parâmetro  $\alpha = 0,1$  em vista que esse valor, segundo a formulação do modelo apresentada, propicia a maior redução possível de variáveis características. Com esse valor, foram estabelecidos 15 e 22 coeficientes de regressão não-nulos para os modelos de predição da posição e magnitude da força, respectivamente. Os parâmetros  $\lambda$  foram determinados por validação cruzada 10-fold onde os valores selecionados apresentaram o erro quadrático médio de validação 10-fold igual ao erro quadrático médio mínimo acrescido de um desvio padrão.

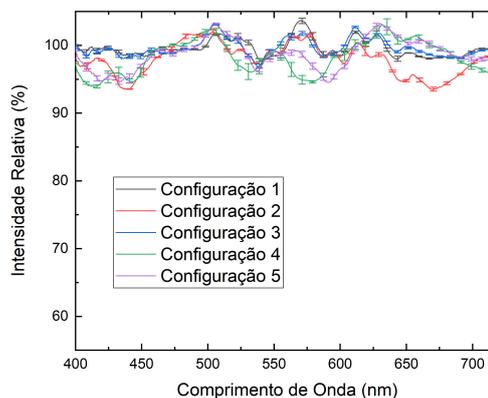


Fig. 4. Repetibilidade do sistema para 5 configurações de forças distintas.

Para inicialização do modelo preditivo de regressão linear baseado em Vetores Suporte, primeiramente foi realizada a redução de dimensionalidade por PCA. Com base nas amostras de treinamento, a Figura 5 representa variabilidades cumulativas explicadas pelas primeiras 71 componentes principais. Juntas essas componentes explicam o valor predeterminado de 99% da variabilidade dos dados de treinamento e validação. Considera-se que a contribuição de variabilidade explicada por componentes maiores do que a quinta são baixas, por isso destacam-se as cinco primeiras componentes principais que juntas explicam aproximadamente 90% da variabilidade total dos dados de treinamento, sendo essas as componentes principais utilizadas para treinamento do modelo de SVR.

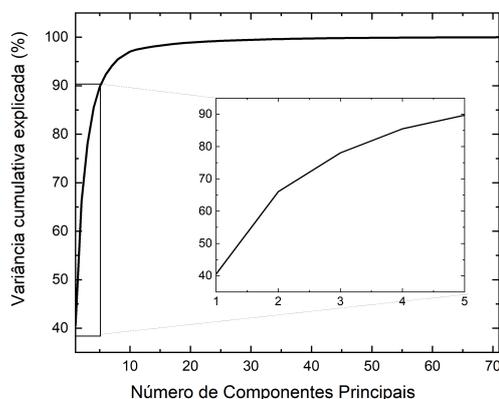


Fig. 5. Variabilidade cumulativa explicada pelas Componentes Principais resultantes da implementação da PCA.

A Tabela II contém os resultados de sensoriamento obtidos pelo sistema, sendo apresentados os erros absolutos médios (MAE) das amostras de validação *hold-out* e teste. Avaliando resultados em termos de erros absolutos médios, notam-se desempenhos de teste semelhantes dos modelos na predição da posição da força monitorada. Por outro lado, para identificação da magnitude da força, na etapa de teste o modelo baseado em Rede Elástica apresentou menor erro quando comparado ao modelo de SVR.

TABELA II  
RESULTADOS DE SENSORIAMENTO DO SISTEMA OPERANDO COM OS  
MODELOS DE REGRESSÃO LINEARES.

Modelo	Validação		Teste	
	MAE (gf)	MAE (cm)	MAE (gf)	MAE (cm)
Rede Elástica	196	2,90	177	2,45
Vetores Suporte	182	2,19	329	2,41

Para verificar o desempenho efetivo de sensoriamento, além dos erros médios é conveniente a avaliação dos erros absolutos individuais de amostras de teste. Nessa etapa, com o modelo baseado em Rede Elástica, o sistema apresentou erros absolutos de predição que variaram entre 2 gf e 700 gf para monitoração da magnitude da força e entre 0,16 cm e 5,81 cm para predição da posição de aplicação da força. Avaliando apenas a predição da magnitude da força por esse modelo, ressalta-se que apenas 3 entre as 24 amostras de teste (12,5%) apresentaram erros absolutos superiores a 300 gf.

Quanto aos resultados de sensoriamento com o modelo baseado em SVR, tem-se que os erros absolutos de monitoração na etapa de teste foram entre 11 gf e 1101 gf para predição da magnitude e entre 0,14 cm e 9,70 cm para predição da posição da força. Considerando a capacidade de monitorar a posição da força com o modelo SVR, destaca-se que ao entender a estrutura como composta por seis regiões com 5 cm de comprimento, apenas três amostras (12,5%) foram preditas em regiões erradas.

#### IV. CONCLUSÕES

A placa sensora desenvolvida demonstrou a capacidade de realização de sensoriamento *quasi*-distribuído de forças com um número de sensores menor do que o número de áreas de sensoriamento. Considerando os resultados em termos de erros absolutos de monitoração e custo computacional, entende-se que os modelos de Rede Elástica e Vetores de Suporte apresentaram desempenhos semelhantes. Na fase de teste, os erros absolutos médios de 177 gf e 2,41 cm, na detecção da magnitude e da posição da força indicam a viabilidade da operação de mapeamento.

Entre as vantagens do sistema multiplexado proposto estão a facilidade de produção, baixo custo e simplicidade computacional. Para aprimoramento do método, considera-se contornar flutuações de intensidade inerentes às fontes incandescentes que podem influenciar o desempenho do sistema sensor. Pesquisas estão em andamento buscando melhorar o desempenho do sistema e aplicar o método com uma distribuição bidimensional de sensores.

#### V. AGRADECIMENTOS

Ao CNPq, Fundação Araucária, Finep e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

#### REFERENCES

[1] H. Wang, M. Totaro, L. Beccai, "Toward perceptive soft robots: Progress and challenges," *Advanced Science*, vol. 5, 2018.

[2] K. Worden, C. R. Farrar, J. Haywood, M. Todd, "A review of nonlinear dynamics applications to structural health monitoring," *Structural Control and Health Monitoring: The Official Journal of the International Association for Structural Control and Monitoring and of the European Association for the Control of Structures*, vol. 15, pp. 540–567, 2008.

[3] M. Javaid, A. Haleem, R. P. Singh, S. Rab, R. Suman, "Significance of sensors for industry 4.0: roles, capabilities, and applications," *Sensors International*, vol. 2, pp. 100–110, 2021.

[4] Y. Liu, S. Nayak, "Structural health monitoring: State of the art and perspectives," *JOM*, vol. 64, pp. 789–792, 2012.

[5] N. Bandari, J. Dargahi, M. Packirisamy, "Image-based optical-fiber force sensor for minimally invasive surgery with ex-vivo validation," *Journal of The Electrochemical Society*, vol. 167, 2020.

[6] W. Lai, et al. "Force sensing with 1 mm fiber bragg gratings for flexible endoscopic surgical robots," *Transactions on Mechatronics*, vol. 25, pp. 371–382, 2019.

[7] P. Roriz, S. Silva, O. Frazão, S. Novais, "Optical fiber temperature sensors and their biomedical applications," *Sensors*, vol. 20, 2020.

[8] Y. Wang, J. Gong, D. Y. Wang, B. Dong, W. Bi, A. Wang, "A quasi-distributed sensing network with time-division-multiplexed fiber Bragg gratings," *IEEE Photonics Technology Letters*, vol. 23, pp. 70–72, 2010.

[9] C. Li, J. Tang, C. Cheng, L. Cai, M. Yang, "FBG arrays for quasi-distributed sensing: A review," *Photonic Sensors*, vol. 11, pp. 91–108, 2021.

[10] I. Floris, J. M. Adam, P. A. Calderón, S. Sales, "Fiber optic shape sensors: A comprehensive review," *Optics and Lasers in Engineering*, vol. 139, 2021.

[11] M. A. Pedroso, L. H. Negri, M. A. Kamizi, J. L. Fabris, M. Muller, "Tactile sensor array with fiber Bragg gratings in quasi-distributed sensing," *Journal of Sensors*, vol. 2018, 2018.

[12] A. G. Lean-Junior, et al. "Quasi-distributed torque and displacement sensing on a series elastic actuator's spring using FBG arrays inscribed in CYTOP fibers," *IEEE Sensors Journal*, vol. 19, pp. 4054–4061, 2019.

[13] M. A. Kamizi, D. Lugarini, R. Fuser, L. H. Negri, J. L. Fabris, M. Muller, "Multiplexing optical fiber macro-bend load sensors," *Journal of Lightwave Technology*, vol. 37, pp. 4858–4863, 2019.

[14] L. Zou, C. Ge, Z. J. Wang, E. Cretu, L. X. Edmond, "Novel tactile sensor technology and smart tactile sensing systems: A review," *Sensors*, vol. 17, pp. 2653, 2017.

[15] P. Roberts, M. Zadan, C. Majidi, "Soft Tactile Sensing Skins for Robotics," *Current Robotics Reports*, vol. 2, pp. 343–354, 2021.

[16] G. A. Angulo-Saucedo, J. X. Leon-Medina, W. A. Pineda-Muñoz, M. A. Torres-Arredondo, D. A. Tibaúiza, "Damage Classification Using Supervised Self-Organizing Maps in Structural Health Monitoring," *Sensors*, vol. 22, pp. 1484, 2022.

[17] P. Omenzetter, O. R. Lautour, "Classification of damage in structural systems using time series analysis and supervised and unsupervised pattern recognition techniques," *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems*, vol. 7647, pp. 1424–1435, 2010.

[18] B. M. Cowie, D. J. Webb, B. Tam, P. Slack, P. N. Brett, "Distributive tactile sensing using fibre Bragg grating sensors for biomedical applications," *International Conference on Biomedical Robotics and Biomechatronics*, pp. 312–317, 2006.

[19] G. Rajan, "A macro-bend fiber based wavelength demodulation system for optical fiber sensing applications," *School of Electrical and Electronics Engineering, Dublin Institute of Technology*, 2008.

[20] I. Papakonstantinou, K. Wang, D. R. Selviah, F. A. Fernández, "Transition, radiation and propagation loss in polymer multimode waveguide bends," *Optics Express*, vol. 15, pp. 669–679, 2007.

[21] Q. Wang, G. Farrel, T. Freir, "Theoretical and experimental investigations of macro-bend losses for standard single mode fibers," *Optics Express*, vol. 13, pp. 4476–4484, 2005.

[22] A. Boleininger, T. Lake, S. Hami, C. Vallance, "Whispering gallery modes in standard optical fibres for fibre profiling measurements and sensing of unlabelled chemical species," *Sensors*, vol. 10, pp. 1765–1781, 2010.

[23] H. Zou, T. Hastie, "Regularization and variable selection via the elastic net," *Journal of the royal statistical society: series B (statistical methodology)*, vol. 67, pp. 301–320, 2005.

[24] A. J. Smola, B. Schölkopf, "A tutorial on support vector regression," *Statistics and computing*, vol. 14, pp. 199–222, 2004.

[25] S. M. Holland, "Principal components analysis (PCA)," *Department of Geology, University of Georgia*, 2008.