

SENSOR ÓPTICO LPFG PARA AVALIAÇÃO DE FORÇAS BIDIRECIONAIS

FELIPE BARINO*, A. BESSA DOS SANTOS†

**Departamento de Circuitos, Universidade Federal de Juiz de Fora*

†*Departamento de Circuitos, Universidade Federal de Juiz de Fora*

Emails: felipe.barino@engenharia.ufjf.br, alexandre.bessa@engenharia.ufjf.br

Abstract— In this work a study about the application of birefringence induced by the lateral compression of LPFG sensors in intensity/direction forces sensing. A neural network regression model is presented and compared with polynomial regression by statistical data like mean squared error and R^2 .

Keywords— optical sensor, long period grating, force sensor, neural network

Resumo— Esse trabalho apresenta um estudo sobre a aplicação da birrefringência induzida pela deformação lateral em sensores LPFG no sensoriamento da intensidade/direção de forças. Um modelo de regressão por meio de redes neurais é apresentado e comparado com regressão polinomial por meio de dados estatísticos como erro médio quadrático e R^2 .

Palavras-chave— sensores ópticos, redes de período longo, sensor de força, rede neural

1 Introdução

Os avanços do mercado na área de instrumentação vêm beneficiando o desenvolvimento da tecnologia de sensores ópticos devido ao aumento da oferta de componentes ópticos a um bom custo-benefício e do número de fornecedores (Santos and Farahi, 2014). As chamadas Redes de Bragg (Fiber Bragg Grating - FBG) e Redes de Período Longo em Fibra (Long Period Fiber Grating - LPFG) são duas estruturas importantes no sensoriamento por fibra óptica. Ambas são redes de difração escritas dentro da fibra óptica por meio de um processo de modulação do índice de refração desta.

As Redes de Período Longo em Fibra (LPFGs) são estruturas mais simples de serem fabricadas, quando comparadas às Redes de Bragg, uma vez que sua fabricação pode ser feita em fibras ópticas padrão e também pelo seu período de modulação ser consideravelmente maior. Como consequência do período de modulação maior, as LPFGs são estritamente redes de transmissão e por isso podem ser consideradas filtros rejeita-faixa. Seu uso como sensor ocorre, pois o comprimento de onda central, denotado por λ_{res}^m , é função de parâmetros que variam com o ambiente. Esses parâmetros são: o índice de refração do núcleo $n_{eff,co}$, da casca $n_{eff,cl}$ e também do período Λ da LPFG, (Erdogan, 1997; Shu et al., 2002). Essa relação é dada por:

$$\lambda_{res}^m = (n_{eff,co} - n_{eff,cl}^m)\Lambda \quad (1)$$

Devido ao tamanho compacto e à imunidade eletromagnética dessa classe de sensores, o uso de sensores ópticos em sistemas robóticos vem aumentando. Park et al. (2007) apresentam um sensor de forças baseado em FBGs em um dedo robótico capaz de medir forças de até 0.01 N e também a localização desta. Já Franke et al. (2009) utiliza

FBGs em manipuladores robóticos, porém como sensor na malha de realimentação do sistema, para controle de vibração do mesmo. Outro sensor que pode ser utilizado como transdutor em sistemas de controle é apresentado em (Delgado et al., 2016). Nesse trabalho Delgado e colaboradores desenvolvem um sensor de corrente que pode ser utilizado no controle da velocidade angular em motores de quadrotoros.

Porém os sensores de deformação citados acima exploram majoritariamente os efeitos da deformação longitudinal na fibra óptica, aumentando consideravelmente o número de sensores necessários para o sistema ser eficaz em termos dimensionais. Ao passo que através da análise de birrefringência pode-se criar sensores capazes de medir forças em duas dimensões, como o sensor FBG de campos bidimensionais de stress estudado por Bosia et al. (2003), e até mesmo em três dimensões como em (Mawatari and Nelson, 2008) e (Zhou et al., 2012). Para LPFGs um estudo da variação do espectro, devido à birrefringência induzida pela aplicação de uma carga lateral no dispositivo é apresentado por Zhang et al. (1999). Já Wang et al. (2007) estudam a variação do ângulo de aplicação da carga lateral.

Este trabalho apresenta um estudo sobre a birrefringência em LPFGs devido à aplicação de cargas laterais, bem como o impacto da direção da aplicação desta em relação ao eixo de propagação da fibra óptica. Além disso, apresenta-se um método de interrogação baseado em redes neurais para o sistema, e também a comparação deste com interrogação baseada em regressão polinomial. Uma aplicação proposta para o sensor aqui apresentado é ilustrada na Figura 1, em que o sensor é posicionado na extremidade de uma ferramenta acoplada a um braço robótico, a fim de medir a intensidade e direção de uma força apli-

cada à ponta desta. E, dessa forma, avaliar o contato entre a ferramenta e o objeto manipulado pelo braço.




Figura 1: Uso do sensor LPFG para avaliação da intensidade e direção de contato em um manipulador robótico.

2 Metodologia

2.1 Modelo do sensor

Um dos efeitos da ação de uma carga transversal em uma LPFG é o aumento da birrefringência na mesma, levando à separação de cada modo propagante em dois, relacionados aos dois eixos principais de polarização (Zhang et al., 1999). Porém as grades escritas pelo método de descargas elétricas, como as produzidas pelo LITel, já possuem birrefringência, induzida pelo próprio processo de fabricação (Bachim and Gaylord, 2003). Essa segunda assimetria ocorre, pois ao receber a descarga elétrica o índice de refração em cada eixo de polarização da fibra sofre alterações que podem chegar a $\Delta n \approx 2 \cdot 10^{-3}$ (Sévigny et al., 2009). Porém, devido à exposição unilateral da fibra à descarga elétrica, essa variação não é uniforme em todos os ângulos da seção transversal da fibra, ou seja, o dispositivo se torna sensível à polarização de entrada. Sendo assim os comprimentos de onda ressonantes, nos eixos principais de polarização, são dados por (Bachim and Gaylord, 2003):

$$\lambda_{res}^{max} = \Lambda(\Delta n^{min}) \quad (2)$$

$$\lambda_{res}^{min} = \Lambda(\Delta n^{max}) \quad (3)$$

Já a birrefringência induzida pela aplicação de cargas laterais pode ser calculada pela variação do índice de refração em cada eixo de polarização, denotada por Δn_x para o eixo x e Δn_y para o eixo y. As equações do chamado efeito foto-elástico são:

$$\Delta n_x = -\frac{(n_{eff}^3)}{2E}((p_{11} - 2\nu p_{12})\sigma_x + ((1 - \nu)p_{12} - \nu p_{11})(\sigma_y + \sigma_z)) \quad (4)$$

$$\Delta n_y = -\frac{(n_{eff}^3)}{2E}((p_{11} - 2\nu p_{12})\sigma_y + ((1 - \nu)p_{12} - \nu p_{11})(\sigma_x + \sigma_z)) \quad (5)$$

Onde E , ν e p_{ij} são respectivamente o módulo de Young, o coeficiente de Poisson e os componentes do tensor fotoelástico. Para a sílica esses parâmetros são: $E = 74.52$ GPa, $\nu = 0.17$, $p_{11} = 0.121$ e $p_{12} = 0.270$.




Figura 2: Aplicação de uma força F em um sensor LPFG.

Considerando um sensor devidamente encapsulado, esquematizado na Figura 2, em que uma força F aplicada a ele pode ser considerada como uma distribuição linear e constante ao longo de todo o comprimento L da grade, e que esta faz um ângulo θ com o eixo-y de polarização da fibra de raio b , os estresses σ_x e σ_y nos eixos de polarização da fibra são obtidos a partir da sobreposição dos dois casos ilustrados na Figura 3 e são dados pelas equações (6) e (7):

$$\sigma_x = \frac{F}{\pi L b}(\cos(\theta) - 2 \sin(\theta)) \quad (6)$$

$$\sigma_y = \frac{F}{\pi L b}(\sin(\theta) - 2 \cos(\theta)) \quad (7)$$




Figura 3: Decomposição dos estresses em relação aos eixos de polarização da fibra: σ_{x, F_x} e σ_{y, F_x} para a componente de força F_x paralela ao eixo x de polarização e σ_{x, F_y} e σ_{y, F_y} para a componente F_y .

Já os efeitos da deformação física são calculados pela variação no período da grade, seja Λ_0 o período da grade sem sofrer deformação:

$$\Lambda = \Lambda_0 \left(1 + \frac{1}{E} (\sigma_z - \nu(\sigma_x + \sigma_y)) \right) \quad (8)$$

Com o uso das equações (4) a (8) pode-se modelar os efeitos de forças laterais na LPFG. A caracterização do sensor constituído por uma LPFG escrita em fibra SMF28 com período $\Lambda = 470 \mu\text{m}$ foi realizada através da colocação de pesos variando entre 1 kg e 5 kg com diferentes ângulos de atuação.

2.2 Interrogação

Propõe-se aqui discutir a interrogação do sistema por meio da análise do comprimento de onda ressonante utilizando redes neurais. Uma rede neural é um modelo computacional cujo funcionamento é inspirado no sistema nervoso central de animais. Esse modelo consiste em um conjunto de unidades, chamadas de neurônios artificiais, interconectadas e é capaz de mapear valores de entradas em valores de saída com base em exemplos que o sistema aprendeu durante a fase de aprendizado.

Um neurônio artificial, assim como o biológico, processa informação e a transmite para outros neurônios. Esse processamento consiste na aplicação da combinação linear das entradas do neurônio em uma função, chamada função de ativação, sendo que a determinação dos coeficientes dessa combinação linear ocorre durante o treinamento da rede.

A topologia de redes neurais escolhida foi o MLP (Multilayer perceptron), a qual é capaz de mapear, quando devidamente treinada, um grupo de entradas em um grupo de saídas. Sendo assim, ela realiza a regressão de uma dada função (Murtagh, 1991). O sistema em si foi desenvolvido em python com auxílio da biblioteca scikit-learn.

3 Resultados

3.1 Resposta do sensor

Primeiramente foi observada a resposta da LPFG à compressão por cargas equivalentes a 0 kg, variando até 5 kg. Os espectros para a LPFG sem cargas e carregada com 5 kg podem ser vistos na Figura 4, nela estão representadas as potências ópticas dos espectros de transmissão: em preto da LPFG, em vermelho do eixo x de polarização e em azul do eixo y de polarização.

Pode-se notar que com o aumento da carga a qual o sensor LPFG é submetido, a separação entre $\lambda_{res,x}$ e $\lambda_{res,y}$ também aumenta. Esse tipo de comportamento ocorre, pois quando F cresce, σ_x também cresce ao passo que σ_y diminui, levando ao aumento da birrefringência e, consequen-

temente, ao aumento da separação entre os comprimentos de onda ressonantes.






Figura 4: Espectros obtidos na caracterização do sistema: (a) Para carga equivalente à 0 kg. (b) Para carga equivalente à 5 kg..

Em seguida a LPFG foi exposta à carga de 5 kg, porém atuando em diferentes ângulos com relação ao eixo de polarização. Nesse caso nota-se um comportamento periódico no vale de ressonância: de fato, ao aplicar as equações (6) e (7) às equações (4) e (5) nota-se que a variação do índice de refração é uma função senoidal. Também nota-se que os vales nos eixos de polarização ortogonais não apresentam simetria quando o sensor é rotacionado em 180° . Esse fato se deve à birrefringência induzida no processo de fabricação do sensor. Como cada eixo de polarização apresenta um índice médio, a variação no índice de refração em cada um dos eixos ocorre de maneira ligeiramente diferente. Quatro espectros são mostrados na Figura 5, dentre estes estão destacados os comprimentos de onda ressonantes dos eixos x e y para $\theta = 120^\circ$ e $\theta = 300^\circ$, note a assimetria causada pela birrefringência.


O procedimento de rotação da LPFG foi repetido para as 5 intensidades de carga (de 1 kg a 5 kg), e o resultado foi a superposição dos dois casos discutidos anteriormente: Observa-se curvas senoidais na Figura 6 representando a variação do comprimento de onda ressonante em função do ângulo de atuação da carga, com amplitudes diferentes, em função da variação na intensidade desta.




(a)



(b)



(c)



(d)

Figura 5: Espectros para carga igual a 5 kg: (a) $\theta = 0^\circ$ (b) $\theta = 30^\circ$ (c) $\theta = 120^\circ$ (d) $\theta = 300^\circ$




Figura 6: Relação entre ângulo de atuação/intensidade da carga e comprimento de onda ressonante.

3.2 Interrogação

A fim de utilizar a LPFG modelada como um sensor, esta foi caracterizada conforme o método de interrogação proposto. Os pontos da Figura 6 foram aleatoriamente divididos em grupo de treino (85%) e teste (15%), para se analisar o desempenho da rede neural com relação à generalização. A rede neural utilizada possui uma camada de entrada, uma escondida e uma de saída. A camada de entrada é alimentada com os comprimentos de onda ressonante em cada eixo de polarização da fibra, enquanto a camada de saída retorna o valor estimado para intensidade de força e ângulo de atuação desta. A camada escondida, por sua vez, foi configurada com 35 neurônios possuindo função de ativação ReLU, definida por:

$$\Phi(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (9)$$

Já a camada de saída possui função de ativação identidade, que é em termos práticos igual à nenhuma função de ativação. Desta forma, a saída do sistema pode assumir praticamente qualquer valor real e possibilita à rede neural realizar a regressão de uma função qualquer. O algoritmo de treinamento utilizado foi o LBFGS com taxa de aprendizado igual a 10^{-5} . Este método foi escolhido por ter menor custo computacional quando comparado ao método do Gradiente Descendente.

Além do MLP, um polinômio de grau quatro de $\mathbb{R}^2 \rightarrow \mathbb{R}$ foi ajustado, a fim de comparação. A performance de ambos foi comparada qualitativamente através das retas de regressão e quantitativamente por meio do Erro Médio Quadrático (EMQ) e do coeficiente de determinação (R^2). Nessa comparação, um bom modelo deve possuir EMQ tão próximo de zero quanto possível, indicando que os resultados obtidos se aproximam do real. Mas também deve apresentar um R^2 perto da unidade, indicando que o modelo consegue explicar os valores observados.

Outro fator que indica qualidade do sistema de interrogação é a pouca diferença entre as estatísticas dos grupos de treinamento e teste. Uma vez que o grupo de treino foi utilizado para o ajuste do modelo aos dados observados este tende a ter melhor performance quando comparado ao grupo de teste. Logo se os dados estatísticos para o grupo de teste é próximo aos dados do grupo de treinamento, o modelo apresenta uma boa generalização. Sabendo disso o desempenho de cada método pode ser quantitativamente avaliado pelos dados tabelados abaixo.

Tabela 1: Performance da regressão polinomial.

	Carga		Ângulo	
	Treino	Teste	Treino	Teste
EMQ	0,0706	0,0388	2924	2822
R^2	0,9632	0,9813	0,6386	0,5516

Tabela 2: Performance da regressão por Rede Neural.

	Carga		Ângulo	
	Treino	Teste	Treino	Teste
EMQ	0,04267	0,2046	724,3	811,5
R^2	0,9785	0,8972	0,9342	0,9263

Dos resultados mostrados nas Tabelas 1 e 2 nota-se que a rede neural obteve um bom resultado, quando comparado à regressão polinomial, principalmente para regressão do ângulo de atuação da força. Note que o coeficiente de determinação neste caso é próximo à unidade e o erro médio quadrático é baixo. Outra observação importante é que esses resultados também se apresentam com poucas discrepâncias entre os subgrupos de treino e teste, indicando que o sistema de interrogação possui boa capacidade de generalização.

As Figuras 7 e 8 mostram as retas de regressão para os dois modelos comparados, tanto para intensidade da carga quanto para ângulo de atuação da mesma. Vale ressaltar que, para cada valor de carga, existem 12 valores de ângulo de atuação e, consequentemente, para cada ângulo existem cinco cargas. Por esse motivo, as possíveis variações que possam existir para valores constantes de carga ou ângulo estão representadas pelas barras de erro.

Note que, para a regressão polinomial os erros estão mais distribuídos ao longo de todo o banco de dados, com erros maiores para ângulos de atuação próximos à origem (0° e 360°). Fato que corrobora com os resultados apresentados na Tabela 3.2, que mostra R^2 distantes da unidade. Já para a rede neural, os erros acontecem majoritariamente na origem. Esse fato pode ser associado à natureza periódica do problema e pode ser contornado aumentando o banco de dados, acrescentando novos valores de ângulo, entre $[-45^\circ, 0^\circ]$ e





Figura 7: Relação Experimento-Estimativa para o modelo polinomial.





Figura 8: Relação Experimento-Estimativa para a Rede Neural.

$[360^\circ, 405^\circ]$ e limitando a função de ativação linear da saída para $[0^\circ, 360^\circ]$, por exemplo.

4 Conclusão

Esse trabalho explora uma área do sensoriamento por fibra óptica ainda pouco utilizada em aplicações de robótica e automação que tem o potencial de aumentar as possibilidades de sensoriamento de forças, introduzindo a possibilidade de medir tanto intensidade quanto a direção na qual a força é aplicada.

O método de regressão por rede neural se mostrou uma boa alternativa ao método mais convencional de regressão polinomial, apesar de ainda manter erros na origem da circunferência, fato que também se mostrou real com a regressão polinomial.

Com isso conclui-se que o método de sensoriamento por meio da análise de birrefringência em sensores LPFG possui um grande potencial para a fabricação de sensores bidirecionais de forças, devido à capacidade de determinar não só a intensidade da mesma, mas também a direção. Sendo necessário, em caso de aplicações práticas, a calibração do mesmo com um banco de dados coerente com a aplicação em questão e grande o suficiente para se atender aos requisitos do projeto.

Agradecimentos

Agradecemos ao apoio da FAPEMIG, CNPq, Propeq-UFJF, Inerge-UFJF e CPFL Energia.

Referências

- Bachim, B. L. and Gaylord, T. K. (2003). Polarization-dependent loss and birefringence in long-period fiber gratings, *Applied optics* **42**(34): 6816–6823.
- Bosia, F., Giaccari, P., Botsis, J., Facchini, M., Limberger, H. G. and Salathé, R. P. (2003). Characterization of the response of fibre Bragg grating sensors subjected to a two-dimensional strain field, *Smart materials and Structures* **12**(6): 925.
- Delgado, F., Carvalho, J., Coelho, T. and Dos Santos, A. (2016). An optical fiber sensor and its application in uavs for current measurements, *Sensors* **16**(12): 1800.
- Erdogan, T. (1997). Fiber grating spectra, *Journal of Lightwave Technology* **15**(8): 1277–1294.
- Franke, R., Malzahn, J., Nierobisch, T., Hoffmann, F. and Bertram, T. (2009). Vibration control of a multi-link flexible robot arm with fiber-Bragg-grating sensors, *2009 IEEE International Conference on Robotics and Automation*.
- Mawatari, T. and Nelson, D. (2008). A multi-parameter Bragg grating fiber optic sensor and triaxial strain measurement, *Smart Materials and Structures* **17**(3): 035033.
- Murtagh, F. (1991). Multilayer perceptrons for classification and regression, *Neurocomputing* **2**(5-6): 183–197.
- Park, Y.-L., Chau, K., Black, R. J. and Cutkosky, M. R. (2007). Force sensing robot fingers using embedded fiber Bragg grating sensors and shape deposition manufacturing, *Proceedings 2007 IEEE International Conference on Robotics and Automation*.
- Santos, J. L. and Farahi, F. (2014). *Handbook of optical sensors*, 1 edn, CRC Press.
- Sévigny, B., Leduc, M., Faucher, M., Godbout, N. and Lacroix, S. (2009). Characterization of the large index modification caused by electrical discharge in optical fibers, *Conference on Lasers and Electro-Optics*, Optical Society of America, p. JTuD72.
- Shu, X., Zhang, L. and Bennion, I. (2002). Sensitivity characteristics of long-period fiber gratings, *Journal of Lightwave Technology* **20**(2): 255–266.
- Wang, Y., Wang, D. N., Jin, W. and Rao, Y. (2007). Asymmetric transverse-load characteristics and polarization dependence of long-period fiber gratings written by a focused co 2 laser, *Applied optics* **46**(16): 3079–3086.
- Zhang, L., Liu, Y., Overall, L., Williams, J. and Bennion, I. (1999). Design and realization of long-period grating devices in conventional and high birefringence fibers and their novel applications as fiber-optic load sensors, *IEEE Journal of Selected Topics in Quantum Electronics* **5**(5): 1373–1378.
- Zhou, Z., Liu, W., Huang, Y., Wang, H., Jianping, H., Huang, M. and Jinping, O. (2012). Optical fiber Bragg grating sensor assembly for 3d strain monitoring and its case study in highway pavement, *Mechanical Systems and Signal Processing* **28**: 36–49.