

引用本文:夏雨,刘亚文,孙宾.基于Q学习超启发算法的FBG混叠光谱解调方法[J].光通信技术,2026,50(3):29-35.

基于Q学习超启发算法的FBG混叠光谱解调方法

夏雨^{1,2},刘亚文³,孙宾^{3*}

(1.江苏省特种设备安全监督检验研究院,南京 210036;

2.江苏省市场监管技术创新中心(油气储运设施安全运维),南京 210036;3.东南大学 土木工程学院,南京 211189)

摘要:为解决光纤布喇格光栅(FBG)复用系统中反射光谱混叠问题,提出一种基于Q学习的超启发式差分进化(QHDE)算法。该算法以差分进化(DE)框架为基础,构建包含4种异构变异策略的算子库,并引入Q学习机制实现变异策略的自适应选择,通过实时评估策略性能,动态优化计算资源调度。解调结果表明,QHDE算法在测试范围内对FBG混叠光谱的波长解调均达到皮米级精度,其解调性能显著优于单一变异策略的DE算法,展现出优异的鲁棒性与解调能力。

关键词:光纤布喇格光栅;波长解调;超启发算法;Q学习;光谱混叠;差分进化

中图分类号:TN253 **文献标志码:**A **文章编号:**1002-5561(2026)03-0029-07

DOI:10.13921/j.cnki.issn1002-5561.2026.03.005

FBG aliasing spectrum demodulation method based on Q-learning hyper-heuristic algorithm

XIA Yu^{1,2}, LIU Yawen³, SUN Bin^{3*}

(1. Jiangsu Special Equipment Safety Supervision and Inspection Research Institute, Nanjing 210036, China; 2. Technology Innovation Center of Safety Operations and Maintenance for Oil and Gas Storage and Transportation Equipment Facilities for Jiangsu Province Market Regulation, Nanjing 210036, China; 3. School of Civil Engineering, Southeast University, Nanjing 211189, China)

Abstract: To address the reflection spectrum aliasing problem in fiber Bragg grating (FBG) multiplexing systems, a Q-learning hyper-heuristic differential evolution (QHDE) algorithm is proposed in this paper. Based on the differential evolution (DE) framework, the algorithm constructs an operator library containing four heterogeneous mutation strategies, and introduces the Q-learning mechanism to achieve the adaptive selection of mutation strategies. By evaluating the performance of the strategy in real time, computational resource scheduling is dynamically optimized. The demodulation results show that the QHDE algorithm achieves picometer-level accuracy for wavelength demodulation of FBG aliasing spectrum in the test range, and its demodulation performance is significantly better than the DE algorithm with single mutation strategy, exhibiting excellent robustness and demodulation capability.

Key words: fiber Bragg grating, wavelength demodulation, hyper-heuristic algorithm, Q-learning, spectral aliasing, differential evolution

收稿日期:2025-10-15。

基金项目:江苏省特种设备安全监督检验研究院直属分院科技计划项目(2024JC01-KT-01)资助。

作者简介:夏雨(1987—),男,本科,工程师,江苏省特种设备安全监督检验研究院直属分院存储设备检验室副主任。主要研究方向是常压储罐沉降监测及底板腐蚀的检验检测。参与并完成了地标 DB32/T 4484-2023 常压储罐定期检验规则、承压设备用封头检验技术规范团标及聚乙烯燃气管道焊接接头检测评价方法。

*通信作者:孙宾(1988—),男,工学博士,副教授,主要研究方向为智能优化、结构健康监测。



0 引言

光纤布喇格光栅(FBG)传感器凭借高灵敏度、耐腐蚀等优势,在结构健康监测及其他领域广泛应用^[1]。其传感机制依赖于反射光谱中心波长偏移量与物理量(如应变、温度)的映射关系,因此波长偏移量的高精度解调是保障传感有效性的核心环节^[2]。FBG复用技术(如波分复用、时分复用、空分复用)通过在波长、时间或空间维度上区分不同传感器的反射信号,使单根光纤可同时承载多个FBG传感器的测量数据,显著提升系统容量并降低成本^[3-4]。然而,复用系统中多传感器反射谱混叠会导致传统解调方法因依赖清晰独

夏雨,刘亚文,孙宾:基于Q学习超启发算法的FBG混叠光谱解调方法

立的光谱特征而失效。

智能优化算法通过构建多峰光谱混叠模型,将波长监测转化为全局优化问题,为混叠光谱的精确解调提供了有效途径^[5-9]。然而,该算法性能高度依赖人工预设参数和固定搜索机制^[10-11]。现有文献提出的算法通常在特定参数设置下才能达到最佳性能,当复用规模变化、环境噪声水平改变或混叠模式不同时,预设的固定参数可能失效,导致算法性能急剧下降。此外,实际动态测量环境要求算法具备自适应能力,而现有研究多在静态场景测试,缺乏对动态调整策略的关注。超启发式算法因其能动态管理底层启发式搜索模式,克服了对单一机制和人工调参的依赖,成为突破现有局限的关键途径^[12-13]。差分进化(DE)算法具有丰富的变异策略,但传统DE算法及其变体在变异策略选择上依赖固定规则,难以自适应响应优化过程状态变化。为此,本文融合强化学习中的Q学习机制,提出一种适用于FBG混叠光谱解调的超启发式差分进化(QHDE)算法。

1 FBG混叠光谱解调原理

为实现多点同步测量并提高传感效率,FBG传感系统通常采用复用方式构建传感网络,系统结构图如图1(a)所示。FBG传感系统主要由宽带光源、耦合器、多个FBG传感器、光谱仪与计算机构成。各FBG传感器对应不同的布喇格波长,从而实现多点传感信号的同时传输与检测。

FBG传感原理如图1(b)所示,主要基于纤芯内部的周期性折射率调制结构,该结构可诱导前向传播基模与反向传播基模之间发生相位匹配耦合。当入射光波长满足布喇格条件 $\lambda_B = 2n_{\text{eff}}\Lambda$ 时,该耦合作用对特定波长产生窄带反射,在反射光谱中形成特征反射峰。其中, λ_B 为布喇格波长,即反射光谱的中心波长(对应

反射谱峰值位置), n_{eff} 为纤芯有效折射率, Λ 为光栅周期。FBG解调过程本质上是对反射光谱中布喇格波长的精确估计与动态跟踪。系统通过光谱仪获取FBG反射光谱,并结合解调算法实现多点传感信息的同步解调,从而建立反射谱特征与外界物理量之间的定量映射关系。

当温度、应变等外界物理量改变时,由于热光效应、弹光效应等的作用,纤芯有效折射率 n_{eff} 和光栅周期 Λ 随之变化,进而导致布喇格波长发生偏移。波长偏移量 $\Delta\lambda_B$ 可表示为

$$\Delta\lambda_B = \lambda_B [(\alpha + \xi)\Delta T + (1 - p_e)\Delta\epsilon] \quad (1)$$

式中: α 为热膨胀系数, ξ 为热光系数, p_e 为弹光系数, ΔT 为温度变化量, $\Delta\epsilon$ 为应变变化量。

通过测量波长偏移量 $\Delta\lambda_B$ 即可反演出外界物理量的定量变化。鉴于波长偏移量 $\Delta\lambda_B$ 的测量精度直接决定FBG传感器的最终测量精度,因此,需要对FBG反射光谱进行高精度解调以准确获取波长偏移量。

反射峰的谱形由反射率的分布决定,其表达式为


$$R(\lambda) = \frac{\kappa^2 \sinh^2(\sqrt{\kappa^2 - \delta^2} L)}{\delta^2 \sinh^2(\sqrt{\kappa^2 - \delta^2} L) + (\kappa^2 - \delta^2) \cosh^2(\sqrt{\kappa^2 - \delta^2} L)} \quad (2)$$

式中: κ 为耦合系数,反映折射率调制对模式耦合的影响强度; δ 为相位失配量, L 为光栅长度。


在算法研究中,为简化模型并聚焦于解调方法本身,常对FBG反射谱谱形进行理想化假设。通常假设反射谱具有高斯型分布,即

$$R_i(\lambda, \lambda_{B,i}) = R_i \exp\left(-\frac{4 \ln 2 (\lambda - \lambda_{B,i})^2}{B_i^2}\right) \quad (3)$$

式中: $R_i(\lambda, \lambda_{B,i})$ 为第 i 个FBG的反射谱模型, λ 为光谱中的波长自变量,用于表征反射谱的波长分布, $\lambda_{B,i}$ 为第 i 个FBG的中心波长,用于确定反射谱的峰值位置; R_i 为反射率; B_i 是3 dB带宽,通常设定为0.2 nm。



(a) FBG传感系统结构图



(b) FBG传感原理图

图1 FBG传感系统结构图和FBG传感原理示意图

对于包含 N 个传感器的传感网络,其叠加形成的FBG混叠光谱可表示为各传感器独立高斯反射谱之和,并叠加噪声干扰项,其表达式为

$$I(\lambda) = \sum_{i=1}^N R_i(\lambda, \lambda_{B,i}) + n(\lambda) \quad (4)$$

式中: $I(\lambda)$ 为合成后的反射谱谱形, N 为传感器数量, $n(\lambda)$ 为高斯白噪声。

为实现各FBG传感器中心波长的反演,定义包含待优化参数的重构光谱模型如下:

$$I_v(\lambda) = \sum_{i=1}^N R_i(\lambda, x_i) \quad (5)$$

式中: $I_v(\lambda)$ 为重构的反射谱谱形,待优化的中心波长集合 $x_i = [\lambda_{B,1}, \lambda_{B,2}, \dots, \lambda_{B,N}]$,通过计算重构光谱与实测光谱的均方根误差(RMSE),可将FBG中心波长监测问题表述为一个多参数全局优化问题,其目标是 minimized RMSE。当优化算法使RMSE收敛至全局最小值时,对应的最优解即为各FBG传感器中心波长的最优估计值。然而,在实际复用过程中,各FBG传感器的反射谱在同一波长范围内叠加,易产生光谱混叠现象,使得目标函数呈现出强非线性特征,从而显著增加优化求解难度。传统优化方法在此类问题中易陷入局部最优,难以获得高精度的波长反演结果。因此,有必要引入具备更强全局搜索能力与收敛性能的优化算法,以实现FBG混叠光谱的高精度解调。

2 QHDE算法

2.1 底层算子库生成

DE算法通过简单的向量操作(变异、交叉、选择)驱动种群向全局最优解进化。为适应不同问题特性,研究者开发了多种变异策略,主要包括:1)DE/rand/XXX,通过随机差分向量进行广泛探索,不依赖当前最优信息;2)DE/best/XXX,利用当前找到的最优解信息引导搜索,在其附近进行精细开发;3)DE/current-to-XXX,以当前个体位置为基础,结合全局最优或邻

域最优信息进行引导,平衡全局探索与局部开发。丰富的变异策略使得DE算法成为构建超启发算法的理想框架。为此,本文选取4种典型DE变异策略作为超启发式算法的底层算子库,其位置更新方式如图2所示。 x_{best} 为理论全局最优解;蓝色箭头表示变异向量,即由当前个体经变异操作生成新个体的整体更新方向;黑色箭头表示差分向量,描述参与差分进化操作的个体之间的向量组合关系。由于超启发式框架本身具有通用性,底层算子库可根据实际需求灵活扩展或替换为其他DE变异策略,不影响QHDE算法核心流程。

变异策略1(DE/rand/1)为随机探索策略,其提供了强大的全局搜索能力,避免早熟收敛,该表达式为

$$v_{i,j} = x_{r1,j}^t + F(x_{r2,j}^t - x_{r3,j}^t) \quad (6)$$

式中: $v_{i,j}^t$ 为变异个体, $x_{r1,j}^t$ 、 $x_{r2,j}^t$ 和 $x_{r3,j}^t$ 为从种群内选取且互不相同的3个随机个体; F 为缩放因子,控制差分向量的影响强度。

变异策略2(DE/rand-to-best/1)融合了随机向量与当前最优解信息,兼具一定探索能力和向最优区域收敛的趋势,其表达式为

$$v_{i,j} = x_{r1,j}^t + F(x_{best}^t - x_{r1,j}^t) + F(x_{r2,j}^t - x_{r3,j}^t) \quad (7)$$

式中: x_{best}^t 为第 t 代种群中的最优个体。

变异策略3(DE/current-to-best/1)以当前个体为基础向当前最优解方向移动,侧重于局部开发,加速收敛,表达式为

$$v_{i,j} = x_{i,j}^t + F(x_{best}^t - x_{i,j}^t) + F(x_{r1,j}^t - x_{r2,j}^t) \quad (8)$$

式中: $x_{i,j}^t$ 为第 t 代种群中的目标个体。

变异策略4(DE/current-to-rand/2)以当前个体为基础,融合2个随机差分向量,在开发当前个体信息的同时保持较强的随机扰动,有助于跳出局部最优,其表达式为

$$v_{i,j} = x_{i,j}^t + F(x_{r1,j}^t - x_{r2,j}^t) + F(x_{r3,j}^t - x_{r4,j}^t) \quad (9)$$

式中: $x_{r1,j}^t$ 、 $x_{r2,j}^t$ 、 $x_{r3,j}^t$ 和 $x_{r4,j}^t$ 为从种群内选取且互不相同的4个随机个体。




图2 4种变异策略的变异向量生成机制

夏雨,刘亚文,孙宾:基于Q学习超启发算法的FBG混叠光谱解调方法

2.2 高层决策机制

为实现对DE变异策略的自适应选择,引入强化学习中的Q学习作为超启发式的高层决策机制。Q学习是一种无模型的强化学习算法,其通过与环境的持续交互,学习在特定环境状态下选择最优动作策略,以最大化长期累积奖励。本文把将底层DE变异策略的选择建模为一个马尔可夫决策过程,允许算法根据种群状态的动态变化智能决策,相关参数有状态、奖励和Q值。

状态划分与种群状态有关,但仅根据种群最优适应度划分状态无法全面反映种群多样性、收敛趋势等关键信息。故结合种群最大适应度 $f_{\max}$,平均适应度 f_{ave} 和最小适应度 $f_{\min}$,定义归一化状态划分指标 β 为^[14]

$$\beta = \frac{f_{\text{ave}} - f_{\min}}{f_{\max} - f_{\min}} \quad (10)$$

根据状态划分指标 β ,将种群划分为4个状态,分别为 $0 < \beta < 0.2$, $0.2 < \beta < 0.4$, $0.4 < \beta < 0.6$ 和 $0.6 < \beta < 1$ 。

基于适应度的改进计算即时奖励 W ,计算式为

$$W = \frac{f_{\min}^{t+1} - f_{\min}^t}{f_{\min}^{t+1}} \quad (11)$$

式中: $f_{\min}^t$ 为第 t 次迭代的种群最小适应度, $f_{\min}^{t+1}$ 为第 $t+1$ 次迭代的种群最小适应度。

Q值的更新公式为

$$Q(s, a) \leftarrow Q(s, a) + \alpha[W + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (12)$$

式中: $Q(s, a)$ 表示在当前状态 s 选择策略 a 的预期奖励, α 为学习率,控制Q表更新速度,取值为0.5; γ 为折扣因子,表征算法对未来奖励的重视程度,取值为0.5。

2.3 QHDE算法流程

本文提出QHDE算法用于FBG混叠光谱解调,其基本流程图如图3所示。首先生成包含 m 个候选解的初始种群,每个个体 x_i^0 ($i=1, 2, \dots, m$)为 D 维向量,其分量 $x_{i,j}^0$ 通过均匀随机采样生成,表达式为

$$x_{i,j}^0 = \text{rand}(lb_j, ub_j) \quad (13)$$

式中:待解调的FBG数量 $D=N_{\text{FBG}}$, lb_j 和 ub_j 分别表示第 j

个FBG中心波长偏移的下界与上界,用于约束其可能的波长偏移范围, $j=1, 2, \dots, D$ 。

为实现差分变异策略的自适应选择,设计了一种融合协同进化思想与Q学习的种群更新机制。该机制的核心在于,将整个种群划分为4个子组,每个子组应用不同的DE策略进行变异。算法根据各子组适应度的变化情况,每隔若干代进行种群规模重分配。当满足收敛条件后,输出全局最优解。具体步骤如下:

1)初始化种群和Q表后,将其均匀分配到4个子组中。基于当前组内所有个体的适应度值,计算状态划分指标,以确定每个子组所处的状态。

2)对组内个体依次执行变异、交叉和选择。交叉是通过组合当前个体和变异个体来生成新的个体,表达式为

$$u_{i,j}^t = \begin{cases} v_{i,j}^t, & \text{rand}(0, 1) < C \text{ 或 } j = j_{\text{rand}} \\ x_{i,j}^t, & \text{其他} \end{cases} \quad (14)$$

式中: $u_{i,j}^t$ 为交叉后生成的新个体, $v_{i,j}^t$ 为变异个体, $x_{i,j}^t$ 为当前个体; C 为交叉概率; j_{rand} 为随机选择的维度索引,需要确保至少有一个维度来自变异个体。

交叉后,采用贪婪策略进行选择,若变异后个体适应度优于变异前的个体,更新该个体;若没有改进,保持原有个体。

3)当子组内所有个体更新后,根据组内最优适应度值的变化,计算即时奖励,并据此更新Q表。

4)算法每隔 G 代进行分组调整。根据当前算法状态和Q值,重新计算并分配4个子组的种群规模。重复步骤1)~步骤3),直至达到最大迭代次数。

QHDE算法本质上构建了一个双层优化架构,将多样化的DE搜索策略与Q学习机制紧密结合。其整体计算复杂度 O 与标准DE算法相同,主要由迭代次数 G 、种群规模 P 和优化维度 S 决定,约为 $O(G \times P \times S)$ 。由于在每次迭代中需进行Q值更新和子群状态评估,单轮计算的复杂度略有增加,但对总体复杂度量级影响较小。此外,算法的空间开销主要来自种群向量与Q表




图3 QHDE算法流程

存储,其中 Q 表规模远小于种群规模,因此整体资源需求并未显著增加。

3 结果与分析

本文构建不同规模的仿真与实验场景,以系统评估QHDE算法在光谱重叠、噪声干扰及多传感器复用等复杂条件下的解调精度与鲁棒性。首先通过双FBG网络分析光谱重叠程度的影响,进而扩展至多FBG场景验证大规模复用能力;最后基于真实FBG光谱数据解调实验,进一步验证算法在实际工程场景中的适用性。

3.1 双FBG传感网络解调

本文首先构建双FBG传感网络仿真模型以探究光谱重叠程度对QHDE算法解调精度的影响。此外,为进一步分析不同反射率条件下的解调性能,设置2种反射率场景。一是反射率 R 不同的情况($R_1 = 0.95$, $R_2 = 0.42$),二是反射率 R 相同的情况($R_1 = R_2 = 0.95$)。2种场景中心波长的设置情况相同,FBG₁中心波长固定为1550 nm,FBG₂中心波长以0.1 nm为步长从1549 nm递增至1550 nm,实现了从光谱分离到完全重叠的连续变化过程。QHDE算法参数设置为:中心波长反演范围为1548~1552 nm,信噪比为30 dB,种群规模为100,最大迭代次数为200。

不同/相同反射率 R 下的解调结果如图4所示。可以看出,当 R 不同时,随着FBG₁和FBG₂的中心波长间距 $\Delta\lambda_B$ 逐渐减小,平均波长误差始终保持在较低水平,说明中心波长解调结果始终与实际值高度一致,仅在完全重叠区域(2个FBG波长间距 $\Delta\lambda_B = 0$ 时)出现微小偏差,对应的平均波长误差始终低于0.5 pm。即使在光谱完全重叠情况下,误差仍稳定维持在皮米量级,表明QHDE算法在 R 不同条件下具有较强的抗光谱重叠能力和较高的解调精度。当 R 相同时,在




图4 不同/相同反射率 R 下解调结果对比

$\Delta\lambda_B \geq 0.3$ nm 范围内,随着波长间距 $\Delta\lambda_B$ 的减小,平均波长误差保持在较低水平,表明解调结果曲线仍能较好地跟踪真实值曲线;当 $\Delta\lambda_B$ 减小至0.2 nm时,误差显著增大,表明解调结果曲线开始明显偏离真实值,反映出光谱高度重叠条件下解调难度提升。进一步分析可知,在 R 相同且信噪比为30 dB的条件下,QHDE算法能够稳定区分波长间距 $\Delta\lambda_B \geq 0.3$ nm的FBG传感器,最小可区分光谱间隔约为0.3 nm。

此外,为评估算法的计算效率,本文对比了QHDE算法与DE/rand、DE/current-to-best、DE/rand-to-best及粒子群优化(PSO)算法的运行时间,结果如图5所示。可以看出,在相同的参数设置下,QHDE算法在双FBG传感网络中的平均耗时约为0.7~0.8 s,其他算法在双FBG传感网络中的平均耗时为0.5~0.6 s。由此可知,由于引入 Q 值更新与子群规模动态调整机制,QHDE算法在单次迭代中的计算量略有增加,导致总体耗时稍高。但是,在固定迭代次数下,该差异主要反映了机制层面的计算开销,而非算法效率下降。随着后续研究在多FBG场景中引入自适应终止准则,QHDE算法的自适应策略选择优势有望抵消该开销。进一步对比反射率不同与反射率相同2种条件下的运行时间可以发现,各算法在2种条件下的耗时差异较小,整体变化趋势基本一致。这表明计算时间主要受算法结构及迭代过程影响,与反射谱幅值分布(由反射率决定)关联较弱。




图5 不同算法平均耗时对比

3.2 多FBG大规模复用解调

为系统评估QHDE算法在高密度FBG传感网络中的解调能力,本文设计随机波长分布和固定波长2类典型场景。随机波长分布场景模拟传感器波长随机重叠

夏雨,刘亚文,孙宾:基于Q学习超启发算法的FBG混叠光谱解调方法

表1 不同算法的解调结果

编号	真实波长/nm	各算法的平均波长误差/pm				各算法的平均耗时/s			
		DE/rand	DE/current-to-best	DE/rand-to-best	QHDE	DE/rand	DE/current-to-best	DE/rand-to-best	QHDE
1	1548.632/1548.649/ 1547.230/1547.830	5.351	606.547	123.192	4.031	1.823	1.722	1.691	1.923
2	1548.563/1547.733/ 1548.231/1547.292	0.119	381.108	229.437	0.119	1.879	1.911	1.823	2.074
3	1548.052/1548.815/ 1547.000/1547.329	57.072	511.795	554.120	0.106	1.882	1.820	1.684	1.904
4	1547.765/1548.442/ 1547.756/1547.558	3.686	116.490	119.822	2.617	1.891	1.881	1.840	2.112
5	1548.495/1547.779/ 1548.740/1547.523	0.167	181.638	513.142	0.167	1.939	1.862	1.825	2.065

的复杂性,固定波长场景探究相同波长极端复用下的性能。

3.2.1 随机波长分布场景

首先在1 547~1 549 nm内随机生成5组4个FBG的混叠光谱数据,分别采用DE/rand、DE/current-to-best、DE/rand-to-best与QHDE算法进行解调,每组光谱重复5次以消除随机性影响。表1列出了不同算法的解调结果。可以看出,QHDE算法的平均波长误差明显低于其他算法,表现出更强的光谱解调能力和更高的稳定性。相比之下,DE/current-to-best与DE/rand-to-best的平均波长误差明显偏大(均超过100 pm),这主要是由于两者在变异过程中均引入当前最优个体信息进行引导,具有较强的收敛倾向。在多FBG复用情况下,该类策略容易导致种群过早向局部最优区域集中,从而降低全局搜索能力,最终造成解调误差显著增大。在计算耗时方面,各算法整体差异较小,单次解调时间均在1.6~2.2 s范围内。其中,QHDE算法的平均耗时略高于其余3种算法,这主要与其在进化过程中引入更复杂的搜索机制有关,但其时间开销增加幅度有限。综合考虑解调精度与计算效率,QHDE算法在保证较高计算效率的同时显著提升了解调精度,表现出更优的综合性能。

在此基础上,进一步扩展至大规模随机波长分布场景。在1 547~1 549 nm波长范围内随机生成FBG传感器中心波长,传感器数量设置为3~5个,构建100组混叠光谱的测试数据集。QHDE算法参数统一配置为:中心波长反演范围为1 547~1 549 nm,种群规模为200,最大迭代次数为500。每组光谱独立执行5次重复解调以消除随机性影响,解调结果如图6所示。可以看出,所有混叠光谱平均波长误差均低于5 pm,其




图6 随机波长分布下的解调误差

中89%的样本误差小于1 pm,证明QHDE算法对随机重叠光谱具有强适应性,可满足具有随机重叠程度的FBG传感网络解调需求。

3.2.2 固定波长高密度场景

固定所有FBG中心波长为1 550 nm,传感器数量从2逐步递增至100(2,5,10,20,40,60,80,100),反射率按指数规律衰减。QHDE算法参数统一配置为:中心波长反演范围为1 549~1 551nm,种群规模为200,最大迭代次数为500。每组光谱独立执行5次重复解调以消除随机性影响,解调误差如图7所示。可以看




图7 固定波长下的解调误差




图8 实测光谱与重构光谱对比图

出,随着传感器数量增加,平均波长误差呈阶梯式增长。当传感器数量 ≤ 40 时,平均波长误差稳定在 $5\text{ }\mu\text{m}$ 以内(标准差 $<0.2\text{ }\mu\text{m}$);当传感器数量 >40 时,平均波长误差随传感器数量增加显著上升;当传感器数量为100时,平均误差达到 $15.67\pm 6.59\text{ }\mu\text{m}$ 。这是高密度FBG引起光谱混叠度呈指数级增强导致的。

3.3 真实FBG光谱解调实验

为验证QHDE算法在实际应用场景中的可行性,本文基于图1中的FBG复用解调实验装置进行实测光谱采集。设置 FBG_1 和 FBG_2 的反射率分别为1和0.79,3 dB带宽分别为0.3 nm和0.5 nm,通过调节光栅参数获得3组不同中心波长间距的混叠光谱数据。

与理想仿真光谱不同,实测光谱受到仪器噪声、光纤非线性效应及环境扰动等综合影响,反射谱通常呈现非对称展宽及旁瓣结构,使得基于理想化模型的仿真结果与实验结果之间存在一定系统偏差。采用QHDE算法对实测光谱进行解调后的结果如图8所示。可以看出,重构光谱与实测光谱在主峰位置上基本重合,尽管在谱形细节(如旁瓣及非对称展宽)上存在一定差异,但整体拟合趋势一致,各FBG对应的主反射峰位置能够被准确识别,说明QHDE算法具有良好的工程应用潜力。

4 结束语

本文提出了一种QHDE算法用于FBG混叠光谱的解调。该算法融合了Q学习的智能决策机制与差分进化算法的全局搜索能力,并通过协同机制对解空间进行智能探索,实现了不同规模FBG混叠光谱的皮米量级解调。此外,QHDE算法的底层算子池支持各类变异策略的动态扩展,使算法能够灵活适配不同工况需求。本研究不仅为解决实际工程中混叠光谱的差异化解调难题提供了高效、智能且可扩展的新方法,也为处理其它复杂高维优化问题提供了新的思路。

参考文献:

- [1] Liang Zhihong, Liu Debo, Wang Xin, et al. FBG-based strain monitoring and temperature compensation for composite tank [J]. Aerospace Science and Technology, 2022, 127: 107724-1-107724-14.
- [2] Sheng Wenjuan, Yin Xin, Wen Jianxiang, et al. Accurate and fast calibration for FBG demodulation based on deep learning and ensemble learning [J]. Optics & Laser Technology, 2024, 172: 110476-1-110476-7.
- [3] 黄新敬,程彤遥,马金玉,等. 基于FBG传感器阵列反演结构振动位移的监测方法[J]. 光通信技术, 2024, 48(1): 7-12.
- [4] 陈静,林雅婷,周清旭,等. 基于峰值匹配分布式估计算法的光纤布拉格光栅传感网络重叠光谱的波长解调[J]. 光子学报, 2019, 48(4): 79-86.
- [5] 郭敬东. 基于差分海洋捕食者优化算法的FBG重叠谱解调方法[J]. 应用光学, 2023, 44(6): 1317-1323.
- [6] 尚秋峰,杨根辈. 基于改进的蝠鲼觅食算法的光纤布拉格光栅解调方法[J]. 光子学报, 2021, 50(9): 71-79.
- [7] Qi Yuefeng, Li Cailing, Jiang Peng, et al. Research on demodulation of FBGs sensor network based on PSO-SA algorithm [J]. Optik, 2018, 164: 647-653.
- [8] 钱敏,桂林,连泉轩,等. 面向光纤光栅传感线性拟合度的PSO-GPR算法[J]. 光通信研究, 2024, 44(4): 66-71.
- [9] 鲍克勤,倪蓉,张雪健. 基于优化解调算法的光纤传感器交叉敏感问题研究[J]. 光通信技术, 2020, 44(3): 17-21.
- [10] 尚秋峰,刘峰. 光纤光栅重叠谱解调算法中的参数优化问题研究[J]. 激光杂志, 2023, 44(8): 130-133.
- [11] 张梅,张伟,章鹏,等. 光纤光栅谱形复用解调中粒子群算法的参数优化[J]. 中国激光, 2019, 46(7): 276-283.
- [12] Drake J H, Kheiri A, Özcan E, et al. Recent advances in selection hyper-heuristics [J]. European Journal of Operational Research, 2020, 285(2): 405-428.
- [13] Gölcük İ, Ozsoydan F B. Q-learning and hyper-heuristic based algorithm recommendation for changing environments [J]. Engineering Applications of Artificial Intelligence, 2021, 102: 104284-1-104284-18.
- [14] Zhao Fuqing, Liu Yuebao, Zhu Ningning, et al. A selection hyper-heuristic algorithm with Q-learning mechanism[J]. Applied Soft Computing, 2023, 147: 110815-1-110815-18.