

基于门控循环单元网络的 FBG 传感网络重叠光谱的 波长检测

江灏^{1,2}, 王尤刚^{1,2}, 陈静^{1,2*}, 黄新宇^{1,2}

¹福州大学电气工程与自动化学院, 福建 福州 350108;

²福州大学电力系统与装置产业研究院, 福建 福州 350108

摘要 针对光纤布拉格光栅(FBG)传感网络中重叠光谱的中心波长解调问题,提出一种基于门控循环单元(GRU)网络的波长检测方法。该方法将 FBG 重叠光谱的波长解调问题转换为模型回归问题,同时考虑到光谱数据的序列特征和频谱特性,采用 GRU 网络实现对光谱数据的特征学习,训练得到相应的波长检测模型,从而实现对重叠光谱的精确快速解调。经实验验证,所提方法能够解决 FBG 传感网络光谱部分重叠或完全重叠条件下的中心波长的精确解调问题,其方均根小于 1 pm 的测试结果占总数的 88.2%。相比现有的解调方式,所提方法在检测精度和稳定性上均有一定的提升,为提高 FBG 传感网络的复用能力提供了新的途径。

关键词 光纤光学; 光纤布拉格光栅; 波长检测; 深度学习; 门控循环单元网络

中图分类号 TN253

文献标志码 A

doi: 10.3788/AOS202040.0706001

Wavelength Detection of Overlapping Spectra in FBG Sensor Network Based on Gated Recurrent Unit Network

Jiang Hao^{1,2}, Wang Yougang^{1,2}, Chen Jing^{1,2*}, Huang Xinyu^{1,2}

¹College of Electrical Engineering and Automation, Fuzhou University, Fuzhou, Fujian 350108, China;

²Research Institute of Power System & Power Equipment, Fuzhou University, Fuzhou, Fujian 350108, China

Abstract A wavelength detection method based on gated recurrent unit (GRU) network was proposed to demodulate the central wavelength of overlapping spectra in fiber Bragg grating (FBG) sensor networks. The proposed method transformed the wavelength demodulation problem of overlapping spectra in FBG into a regression problem and considered the sequence and spectrum characteristics of the spectral data. To learn the spectral data characteristics and train to achieve the corresponding wavelength detection model, the GRU network was used. Thus, the overlapping spectra could be quickly and accurately demodulated. Experimental results show that the proposed method can overcome the precise demodulation problem of the central wavelength for partially or completely overlapping spectra of FBG sensor networks. The test results with root mean square less than 1 pm account for 88.2% of the test results. The detection accuracy and stability of the proposed method provide enhanced results compared with existing demodulation methods. The proposed method provides a novel way to improve the multiplexing capability of FBG sensor networks.

Key words fiber optics; fiber Bragg grating; wavelength detection; deep learning; gated recurrent unit network

OCIS codes 060.3735; 060.4230; 150.1135; 280.4788

1 引 言

光纤布拉格光栅(FBG)传感器作为一种重要的光学传感器,因具有抗电磁干扰强、体积小、耐腐蚀、

灵敏度高及可复用等优势,被广泛用于复杂环境下的压力测试、温度监测及位移测量,目前在医疗诊断、土木工程、电力系统等领域已有诸多应用^[1-4]。多路复用是 FBG 传感器的优点之一,波分复用法

收稿日期: 2019-11-13; 修回日期: 2019-12-01; 录用日期: 2019-12-16

基金项目: 国家自然科学基金(61703106, 61703105)、福建省自然科学基金面上项目(2017J01500)、福建省教育厅中青年科研项目(JAT170107)、福建省高校青年自然科学基金重点项目(JZ160415)

* E-mail: chenjing@fzu.edu.cn

(WDM)作为 FBG 多路复用最为常用的解决方案,要求 FBG 传感网络中的每一个 FBG 拥有各自独立的工作区域,相邻频谱之间互不重叠,否则将导致中心波长的串扰问题,直接影响传感器网络的检测结果^[5-6]。这一要求严重限制了有限频谱带宽条件下的 FBG 复用数量,使得 FBG 传感网络的复用能力受限。

近年来,为了提高 FBG 传感网络的复用能力,尝试允许 FBG 网络中的频谱重叠^[7-8],为避免因重叠光谱造成中心波长串扰而引发的峰值检测失效问题,基于函数优化的新型 FBG 中心波长解调方法被提出。该方法从反射光谱的参数重构角度出发,利用进化算法将波长检测问题转换为模型优化问题^[7]。Shi 等^[9]利用遗传算法(GA)实现了多 FBG 部分或完全重叠情况下的波长解调,GA 通过组合、交叉及变异模拟生物进化的过程来确定最终最优解,该算法耗时较长。差分进化(DE)算法^[10-11]具有较强的全局搜索能力和较快的收敛速度,利用该算法检测 FBG 的重叠光谱,提高了检测性能。粒子群(PSO)算法能够有效地解决复杂的优化问题且不依赖于目标函数,因此被应用于 FBG 传感器波长解调中^[12],但它在求解组合优化问题时容易陷入局部最优。Qi 等^[13]结合了 PSO 和模拟退火(SA)算法来检测 FBG 传感网络中的布拉格中心波长,增强了波长检测的全局寻优能力。为提高波长解调的运行效率,基于峰值匹配分布式估计算法的波长解调方法^[14]被提出,该算法在检测时间上相比 GA、PSO 算法具有明显的提升。这些技术能够准确地检测 FBG 传感器的光谱部分重叠或完全重叠时的中心波长,但是随着传感器数量的增加,进化算法需要更长的处理时间才能达到较高的精度,影响了波长检测的实时性。

为了提高检测速度和检测精度,基于机器学习的方法被引入来解决光谱重叠条件下的解调问题。其基本原理是将波长检测问题转换为非线性回归问题,利用最小二乘支持向量回归机(LS-SVR)^[15]和极限学习机(ELM)^[16]等学习算法对光谱样本进行学习,建立相应的回归模型,利用训练好的模型进行快速解调。传统机器学习方法最大的瓶颈在于光谱特征需要人工提取,稳定性较差,而深度学习是通过多层网络结构实现对数据特征的自动提取。由于光谱特征在频域上具有连续性,在基于深度学习的众多方法之中,循环神经网络(RNN)在有序序列数据的分析中有着独特的优势,在工程实践中被广泛应用。

本文提出一种用于重叠光谱解调的门控循环单元(GRU)网络。GRU 是 RNN 的一种变体^[17]。传统的 RNN 在对长序列学习时,由于梯度消失,会导致对久远数据的学习能力不足,即存在长期依赖问题^[18]。为此 GRU 在传统 RNN 的基础上增加了门控制单元,让 RNN 能够保持长远记忆能力,便于提取数据序列特征。GRU 结构相对简单,学习速度快,是目前 RNN 最为有效的变体之一。利用 GRU 的方法,研究了重叠 FBG 的光谱特性,在对光谱数据的训练过程中,建立了针对 FBG 光谱两两重叠的布拉格中心波长解调模型,通过该模型可以准确高效地识别任意两个重叠的 FBG 光谱的中心波长。相比传统基于进化算法的解调方法,所提方法在处理速度、检测精度及复用能力等方面均有明显的提升。

2 基本原理

2.1 FBG 重叠光谱解调原理

典型的串并联 WDM 光纤布拉格光栅传感网络结构如图 1 所示。宽带光源产生的入射光经 3 dB 光耦合器和一个 1×2 的分束器进入 FBG 传感网络,各 FBG 的反射光经同一路径反向传输至同一耦合器,并由光谱分析仪(OSA)采样设备进行采样,OSA 所获取的光谱采样数据将被传递到计算机(PC)端以待进一步处理。传统的 WDM 要求 FBG 传感网络中的每一个 FBG 拥有各自独立的工作区域,相邻频谱之间互不重叠,这严重限制了传感器网络的复用能力。为了克服这种局限性,所设计的复用模型允许任意两个 FBG 光谱重叠,与传统 WDM 光纤布拉格光栅传感网络相比,在同样的频谱带宽条件下,可以增加 1 倍的 FBG 传感器数,即复用能力提升至原来的 2 倍。

FBG 的光谱重叠情况如图 2 所示,分别为非重叠光谱、部分重叠光谱及完全重叠光谱。在非重叠光谱的情况下,通过光谱的分离可以得到两个 FBG 的反射光谱,但由于 FBG 传感器的中心波长的位移不同,难以区分中心波长归属于这两个 FBG 中的哪一个,从而导致 FBG 与中心波长不匹配的情况;而在重叠光谱情况下,两个反射光谱之间相互影响,传统的峰值检测方法难以处理光谱的串扰,无法准确地区分每个 FBG 的反射光谱的峰值波长,因此串扰和不匹配问题使得波长解调成为了 FBG 传感网络复用能力提升的首要任务。本文将光谱的波长解调问题转换为非线性回归问题,利用 GRU 网络

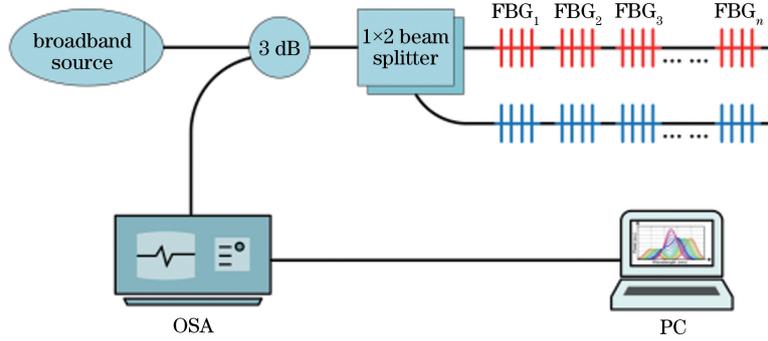


图 1 串并联 WDM 光纤布拉格光栅传感网络结构

Fig. 1 Structure of series-parallel WDM fiber Bragg grating sensor network

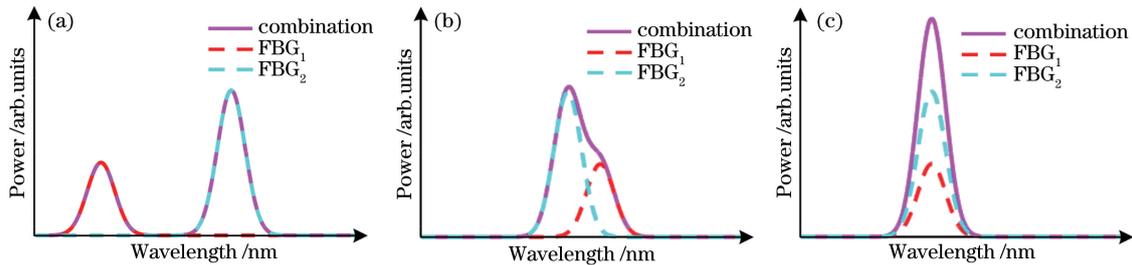


图 2 FBG 反射光谱的重叠类型。(a)非重叠;(b)部分重叠;(c)完全重叠

Fig. 2 Overlapping types of FBG reflection spectra. (a) Non-overlapping; (b) partly-overlapping; (c) fully-overlapping

建立回归模型,通过模型实现对两个 FBG 重叠光谱的波长解调。

假设一个由 n 个 FBG 构成的传感网络,该网络的反射光谱 $R(\lambda)$ 由该网络中每一个 FBG 的反射光谱构成,可表示为

$$R(\lambda) = \sum_{i=1}^n \gamma(\lambda, \lambda_{B_i}), \quad (1)$$

式中: λ_{B_i} 为第 i 个 FBG 的布拉格中心波长; n 为传感网络中 FBG 的个数; $\gamma(\cdot)$ 为单个 FBG 的谱函数。

根据设计的复用模型可知,FBG 反射光谱允许两两重叠,由 n 个 FBG 构成的 FBG 传感网络的光谱带宽可分为 n 个工作区域,则每一个工作区域中可增加至两个 FBG 传感器,则可以设 R_j 为第 j 个 FBG 对的实测光谱。此时 $R(\lambda)$ 可表示为

$$R(\lambda) = \sum_{j=1}^n R_j(\lambda) = \sum_{j=1}^n \Gamma_j(\lambda, \lambda_{B1}, \lambda_{B2}), \quad (2)$$

式中: $\Gamma_j(\lambda, \lambda_{B1}, \lambda_{B2})$ 为第 j 个 FBG 对光谱函数的理论值。实际上,波长检测问题就是从反射光谱 $R_j(\lambda)$ 中提取出 $\lambda_{B1}, \lambda_{B2}$, 因此若能获得反函数 Γ_j^{-1} , 就可以得到 $\lambda_{B1}, \lambda_{B2}$ 。

$$(\lambda_{B1}, \lambda_{B2})_j = \Gamma_j^{-1}[R_j(\lambda)]. \quad (3)$$

由(3)式可知,波长检测问题可以看作是反射光谱反函数的构造,通过函数的方法可解决光谱重叠

条件下的串扰波长解调问题。然而,反函数不能给出显式公式,数值方法难以直接求解,因此采用机器学习方法来训练反函数模型。

基于上述理论分析,采用 GRU 网络构建反函数模型,如图 3 所示。用 GRU 网络实现 FBG 波长解调的过程主要分为两个阶段,即离线学习和在线检测。首先是离线学习阶段,为了实现 FBG 的波长解调,在模型训练过程中考虑了波长的序列特征和频谱特征,将 FBG 传感器网络的反射光谱的序列平均分割成 m 段, d_1, d_2, \dots, d_m 。每一个被分割后的频谱序列按照一定顺序依次送入 GRU 的存储块进行特征学习。训练数据集 D 表示为

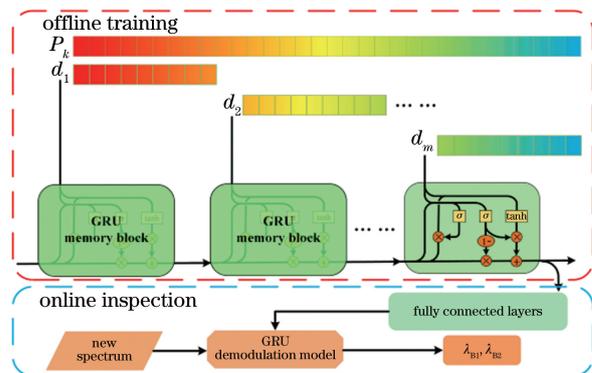


图 3 GRU 模型的波长解调架构

Fig. 3 Wavelength demodulation architecture of GRU model

$$D = (P_1, T_1), \dots, (P_k, T_k), \dots, (P_N, T_N), \quad (4)$$

式中:第 k 个 FBG 对的光谱 $P_k \in R^l$, R 为所有 FBG 对的集合, l 为采样点个数; $T_k = (\lambda_{B1}, \lambda_{B2})_k$, 为相对应的两个 FBG 的布拉格波长。训练数据集可通过反射光谱的理论模型生成大量的训练数据, 而后在在线检测阶段, 通过训练好的解调模型便可实现对输入 FBG 重叠光谱布拉格波长的快速精确解调, 从而实现在线检测。

2.2 GRU 基本原理

FBG 的反射光谱是一非线性的有序长序列信号, 而 RNN 具有带自反馈的神经元结构, 这样的反馈机制使得 RNN 有了记忆的能力, 从而能够很好地处理任意有序长序列数据。但是随着神经网络的层数增加, 梯度消失问题会导致传统 RNN 对久远数据的学习能力下降, 即长期依赖问题。为此引入“门”控制结构以增强对全局记忆的控制能力, 以此来解决长期依赖的问题, GRU 便是这种结构类型的变体。

相比于传统 RNN, GRU 结构中增加了“重置门”和“更新门”结构。图 4 为 GRU 单元的内部结构图, 其中 r_t 为重置门, z_t 为更新门, h_t 和 h_{t-1} 分别为 t 时刻和 $t-1$ 时刻对 GRU 单元状态的描述, x_t 为 t 时刻的输入, \tilde{h}_t 为 t 时刻的候选状态, σ 和 \tanh 分别为 Sigmoid 函数和双曲正切函数。

$$\sigma(s) = \frac{1}{1 + \exp(-s)}, \quad (5)$$

$$\tanh(s) = \frac{\sinh(s)}{\cosh(s)} = \frac{\exp(s) - \exp(-s)}{\exp(s) + \exp(-s)}, \quad (6)$$

式中: s 为函数自变量。下面对 GRU 的门结构的工作原理进行详细阐述。

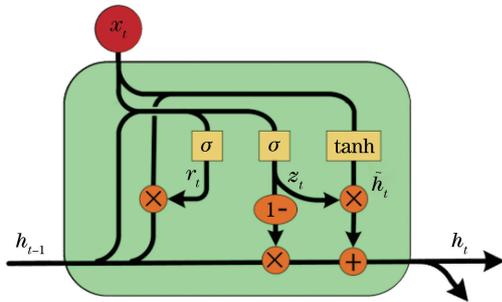


图 4 GRU 网络的单元结构

Fig. 4 Unit structure of GRU network

1) 重置门 r_t : 重置门的作用是决定当前时刻的候选状态 \tilde{h}_t 对上一时刻的状态 h_{t-1} 的依赖程度, 即用来控制上一时刻的状态 h_{t-1} 有多少被保留至当前候选状态 \tilde{h}_t 中。 r_t 的计算公式为

$$r_t = \sigma(\mathbf{W}_r x_t + \mathbf{U}_r h_{t-1} + \mathbf{b}_r), \quad (7)$$

式中: \mathbf{W}_r 为输入 x_t 与当前状态 h_t 之间的权重矩阵; \mathbf{U}_r 为历史状态 h_{t-1} 与当前状态 h_t 的权重矩阵; \mathbf{b}_r 为偏差向量。候选状态 \tilde{h}_t 的取值主要由两个部分组成, 一部分来自于当前时刻的输入 x_t , 另一部分来自于上一时刻的状态 h_{t-1} 。 \tilde{h}_t 的计算公式为

$$\tilde{h}_t = \tanh[\mathbf{W}_c x_t + \mathbf{U}_c (r_t * h_{t-1}) + \mathbf{b}_c]. \quad (8)$$

由(7)和(8)式可知, r_t 的取值范围在 $0 \sim 1$ 之间, 若考虑两种极端情况, 当 $r_t = 0$ 时, 当前时刻的候选状态 \tilde{h}_t 只与当前时刻的输入 x_t 有关, 而与上一时刻的状态 h_{t-1} 无关; 当 $r_t = 1$ 时, 候选状态 \tilde{h}_t 与输入 x_t 和上一时刻的状态 h_{t-1} 均有关, 并且上一时刻的状态 h_{t-1} 全部被保留至候选状态中。

2) 更新门 z_t : 更新门的作用是决定当前时刻的输出状态 h_t 由多少历史信息和新信息构成, 即当前时刻的输出状态 h_t 从上一时刻的状态 h_{t-1} 保留了多少历史信息, 并从当前时刻的候选状态 \tilde{h}_t 中更新了多少新信息。 z_t 的计算公式为

$$z_t = \sigma(\mathbf{W}_z x_t + \mathbf{U}_z h_{t-1} + \mathbf{b}_z). \quad (9)$$

当前时刻的输出状态 h_t 为

$$h_t = z_t * h_{t-1} + (1 - z_t) * \tilde{h}_t. \quad (10)$$

由(9)和(10)式可知, z_t 的取值范围在 $0 \sim 1$ 之间, 同样考虑两种极端情况, 当 $z_t = 0$ 时, 当前时刻的输出状态 h_t 仅由候选状态 \tilde{h}_t 更新得到, 而与历史信息 h_{t-1} 无关; 当 $z_t = 1$ 时, 当前时刻的输出状态 h_t 完全继承了历史信息, 而无新信息的更新加入。

正是由于门控制结构的更新机制, GRU 才能够高效地实现对久远信息的记忆保存, 克服传统 RNN 的长期依赖问题, 并在有序长序列数据的预测回归分析中脱颖而出。

3 实验结果

实验采用功率为 100 mW、半峰全宽 (FWHM) 为 50 nm 的宽带光源, 光源通过 3 dB 光耦合器进入 FBG 传感网络, FBG 反射光谱反向传输至同一耦合器, 并由 OSA 进行采样。OSA 的采样范围设置为 1550 ~ 1552 nm, 带宽为 2 nm, 分辨率设置为 10 pm, 对应得到采样数为 200 的光谱数据。考虑到温度对 FBG 的干扰, 实验在恒温环境下进行数据采集, 光谱数据被送至 PC 端 (Intel Core i7-6850K CPU, NVIDIA GeForce GTX 1080 Ti GPU, 16 GB RAM) 进行 GRU 波长解调模型的训练学习和检

测。由于本实验主要关注在两个 FBG 相互重叠的解调问题,因此采用两个 FBG 进行实验,且 FBG₁ 和 FBG₂ 使用相同的工作区域。实验所采用的 FBG 传感器的 FWHM 为 0.2 nm,FBG 原始中心波长均为 1551 nm,反射率为 0.95。通过给 FBG 施加不同的应力产生不同的重叠情况,为降低噪声影响,采集到的数据使用 Savitzky-Golay 差分有限长单位冲激响应(FIR)滤波器进行平滑处理。为了从重叠光谱中区分出每个 FBG 的中心波长,使用衰减器让 FBG₁ 的峰值反射率比 FBG₂ 低 3 dB。实验中使用布拉格中心波长的测量方均根(RMS)作为性能的评价指标。

3.1 模型训练与性能测试

由于 GRU 解调模型需要事先采集数据样本进行模型训练与测试,为获得足够的样本数据,一方面通过随机施加应力采集 1000 个样本数据,另一方面结合所采集的数据通过仿真手段将样本数据扩充到 11000 个供实验使用,并从中抽取 1000 个样本数据作为本实验的测试样本。GRU 算法模型采用 Keras 框架实现,其中 Keras 的底层库采用 TensorFlow。模型的输入是 1550~1552 nm 范围的光谱数据(200 个点),模型的输出是 FBG₁ 与 FBG₂ 的中心波长值(2 个输出值)。GRU 的隐藏单元数设为 600,批次大小设为 64,采用 8000 个样本

进行训练,最大迭代次数设为 1000,训练过程如图 5 所示。随着迭代次数的增加,模型精度逐渐提高,900 epoch 之后虽然训练误差持续下降,但趋于饱和,并在 986 epoch 时获得最优的解调模型,其训练误差和测试误差分别是 0.7604 pm 和 0.8325 pm。总训练时长为 3111 s。模型一旦训练好,无需重复训练即可用于对光谱数据的解调。采用已训练好的 GRU 模型对两个 FBG 重叠光谱的 1000 个测试样本进行检测,测试样本中存在不同重叠程度的光谱数据,1000 个样本的总检测时间为 0.4051 s,RMS 为 0.8325 pm,测试结果中 88.2% 的测试 RMS 小于 1 pm,可见 GRU 解调模型可以很好地实现对不同重叠程度光谱的布拉格中心波长的解调。

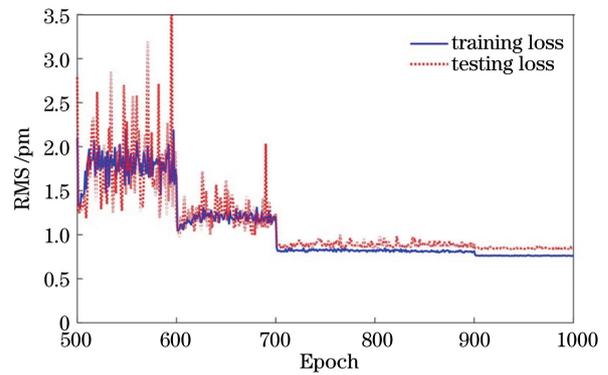


图 5 GRU 模型的训练过程

Fig. 5 Training process of GRU model

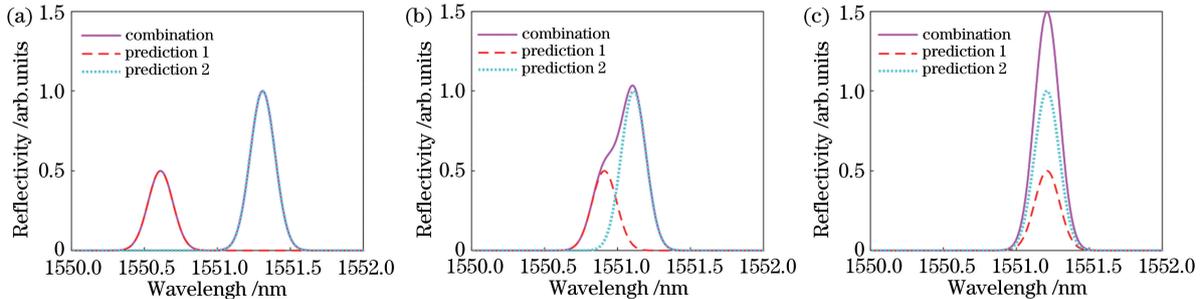


图 6 三种典型的重叠光谱波长检测案例。(a)非重叠;(b)部分重叠;(c)完全重叠

Fig. 6 Three typical cases of overlapping spectral wavelength detection. (a) Non-overlapping; (b) partly-overlapping; (c) fully-overlapping

表 1 典型重叠光谱的波长检测结果

Table 1 Wavelength detection results of typical overlapping spectra

Case	λ_{B1}/nm	λ_{B2}/nm	Wavelength interval $\Delta\lambda/\text{nm}$	RMS/pm
Non-overlapping	1550.5996	1551.2996	-0.7000	0.2629
Partly-overlapping	1550.8997	1551.0999	-0.2002	0.4158
Fully-overlapping	1551.2004	1551.1992	0.0012	0.6338

图 6 与表 1 为测试样本中的三个典型案例的波长检测结果,可以看出三种情况均能通过 GRU 模

型检测出重叠光谱的布拉格中心波长,随着重叠率的增加,测试的 RMS 也开始增大,其中非重叠情况

下的检测效果最好, RMS 为 0.2629 pm, 完全重叠情况下的检测效果最差, RMS 为 0.6338 pm, 但仍保持在 1 pm 的检测要求内。

3.2 GRU 参数讨论

为了分析不同 GRU 参数对检测性能的影响, 针对训练集的样本个数、每一次训练神经网络送入模型的样本数(批次大小)、GRU 隐藏层数(隐藏单元个数)分别进行了实验, 测试了不同参数的改变对检测精度和训练时间的影响。

考虑训练集样本数对检测性能的影响, 固定 GRU 隐藏单元数为 500、批次大小为 64、测试集样本数为 1000, 分别测试了样本数由 3000 变化至 10000(间隔 1000)时对检测性能的影响。测试结果如图 7 所示, 随着训练样本数的增加, RMS 减小, 在样本数为 8000 左右趋近于饱和, 训练时间呈线性增加。训练样本数的变化会影响检测精度与训练效率, 但不会改变模型的结构, 不会影响检测效率。样本数少, 所需训练时间成本低, 但会导致网络的泛化能力不足; 而过多的样本会导致网络出现过拟合的情况且需要花费大量的训练时间。

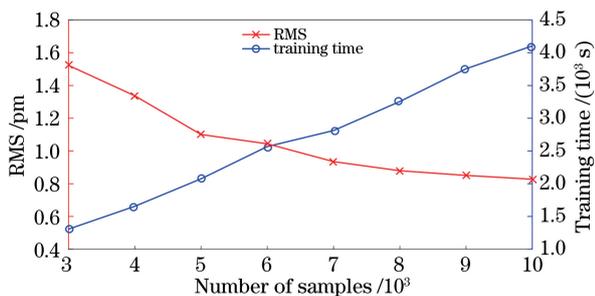


图 7 训练样本数对检测性能的影响

Fig. 7 Effect of training samples on detection performance

为了选取合适的 GRU 网络训练批次大小, 固定 GRU 隐藏单元数为 500、训练集样本数为 8000、测试集样本数为 1000, 在批次大小由 8 变化至 256 (间隔 2 倍) 时进行模型训练。图 8 为批次大小的改变对检测性能影响的测试结果, 可以看出: 批次大小与 RMS 呈线性正相关关系, 与训练时间呈非线性负相关关系; 随着批次大小的增大, 所需训练时间随之下降且下降速率逐渐降低, 小批次需要较长的训练时间, 效率不高, 而大批次可以加快网络的训练速度, 缩短训练时间, 但大批次会使网络的学习能力降低, 同时也会占用更多的计算机内存资源; 在批次大小为 64 时为时间曲线的“肘部”, 训练时间为 3193.22 s, 且此时的 RMS 为 0.9192 pm (< 1 pm) 满足 FBG 波长解调精度要求, 故选取大小为 64 的批

次作为 GRU 模型的最优参数。

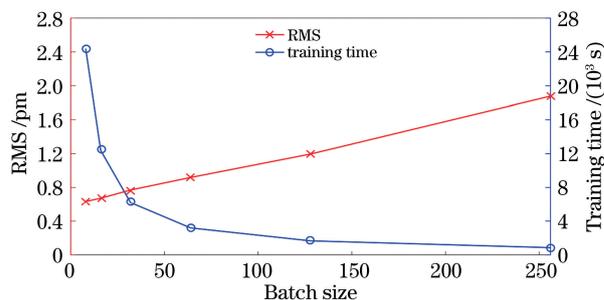


图 8 批次大小对检测性能的影响

Fig. 8 Effect of batch size on detection performance

进一步分析隐含层单元个数对 GRU 网络特征学习效果的影响。固定批次大小为 64、训练集样本数为 8000、测试集样本数为 1000, 分别讨论隐藏单元个数由 10 变化至 800 时对检测性能的影响。测试结果如图 9 所示, 可以看出: 随着隐藏单元数的增加, RMS 不断下降, 精度不断提高; 同时模型也愈加复杂, 所需的训练时间成本也不断增加, 若单元个数太少会让网络的非线性表达能力下降, 使得检测精度难以满足要求; 在单元个数为 600 时, 训练时间出现剧增的趋势, 而此时的 RMS 为 0.8325 pm, 已经满足检测误差小于 1 pm 的精度要求, 故无需再增加隐藏单元数。

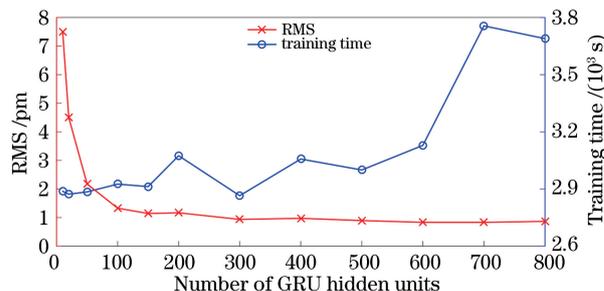


图 9 GRU 隐藏单元个数对检测性能的影响

Fig. 9 Effect of numbers of GRU hidden units on detection performance

3.3 对比测试

为了进一步验证所提方法的有效性, 在相同实验条件下, 将所提基于 GRU 的 FBG 重叠光谱的布拉格中心波长检测方法与已有文献中的解调方法对同一个测试集进行实验对比。其中包含 DE 算法^[10-11]、PSO 算法^[14]、LS-SVR^[15]。对于 DE 与 PSO, 种群大小设置为 20, 迭代次数为 200, 考虑到进化算法的随机性, 取 20 次运行的 RMS 和测试时间的平均值作为最终结果。对于 LS-SVR, 采用与 GRU 模型相同的训练集。

图 10 和表 2 分别为 4 种方法累积概率分布图

和检测性能比较。从图 10 可以看出:使用 GRU 方法的测试结果中的检测误差有 88.2% 在 1 μm 以下,LS-SVR、DE、PSO 方法对应的在 1 μm 以内的累积概率分别为 74.9%、26.7%、26.4%,与以往的机器学习方法相比,在更高的精度要求下,GRU 方法具有更高的累积概率和更低的错误率;LS-SVR 的检测方式在 RMS 小于 0.24 μm 和高于 2.46 μm 时,累积概率均高于 GRU 方法,尽管 LS-SVR 方法在极低 RMS 的占比较高,但不具有广适性,且其训练时间是 GRU 方法的 5.5 倍,学习效率不高;GRU 的累积概率曲线明显高于 DE 和 PSO,说明 GRU 方法在统计特性上优于 DE 和 PSO 方法。从表 2 还可以看到,当允许误差增至 3 μm 时,LS-SVR 检测方法的累积密度高于 GRU 方法 0.019,这说明在不同的误差允许范围内,GRU 与其他的检测方法各有优劣,而基于 GRU 的方式更适合更高精度要求的应用场合。其中一个主要原因是机器学习方法的检测误差在很大程度上取决于模型的泛化能力,一旦模型训练完成,检测误差的方差不会有很大的变化,比进化算法有更高的稳定性;另一方面是进化算法不仅有随机不确定性,而且容易陷入局部最优解,最终影响结果的正确性。

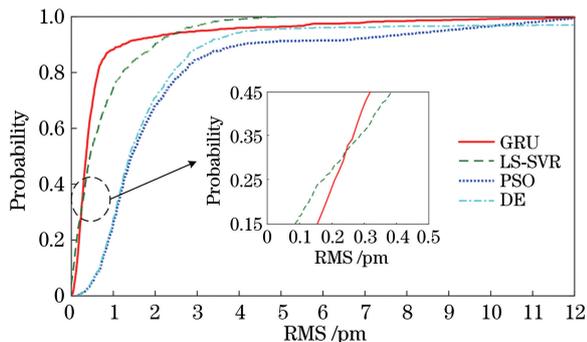


图 10 不同方法的 RMS 累积概率分布

Fig. 10 Cumulative probability distribution of RMS for different methods

表 2 不同方法的性能比较

Table 2 Performance comparison of different methods

Methods	Training time / s	RMS / μm	Cumulative	Cumulative
			probability of RMS less than 1 μm	probability of RMS less than 3 μm
GRU	3128.7	0.8325	0.882	0.949
LS-SVR	17290.0	1.2063	0.749	0.968
DE		1.9122	0.267	0.887
PSO		2.4037	0.264	0.846

4 结 论

提出一种基于 GRU 模型的 FBG 布拉格中心波长检测方法。利用门控循环单元网络对反射光谱的序列特征及频谱特性进行训练学习,进而得到波长解调的函数模型,实现对 FBG 光谱重叠条件下的中心波长的精确解调,提高了有限频谱带宽条件下的 FBG 复用数量。实验表明,在高精度的要求下,所提方法相比以往的机器学习方法,具有更高的检测精度。不同于进化算法的寻优计算过程,所提方法只需一次训练就可以得到满意的解调模型,提高了实时检测效率,同时还避免了进化算法的随机不确定性,检测结果更加精确且稳定。所提方法为提升 FBG 传感网络的复用能力提供了一种新的解决方案。

参 考 文 献

- [1] Wang Y L, Shi B, Zhang T L, et al. Introduction to an FBG-based inclinometer and its application to landslide monitoring[J]. Journal of Civil Structural Health Monitoring, 2015, 5(5): 645-653.
- [2] Xiao H, Zhang Y N, Shen L Y, et al. Research on curvature serialization in the curve reconstruction algorithm based on fiber Bragg gratings[J]. Chinese Journal of Scientific Instrument, 2016, 17(5): 993-999.
肖海, 章亚男, 沈林勇, 等. 光纤光栅曲线重建算法中的曲率连续化研究[J]. 仪器仪表学报, 2016, 17(5): 993-999.
- [3] Lyu G H, Zhou B N, Wang C Z, et al. Fiber grating displacement sensor based on elliptical mechanical amplification structure [J]. Acta Photonica Sinica, 2018, 47(11): 1106002.
吕国辉, 周泊宁, 王朝钲, 等. 基于椭圆位移放大结构的光纤光栅位移传感器[J]. 光子学报, 2018, 47(11): 1106002.
- [4] Chen Q, Li Q M, Cong H X, et al. On-line temperature monitoring for GIS disconnecting switch contacts based on multipoint-distributed fiber Bragg grating [J]. Transactions of China Electrotechnical Society, 2015, 30(12): 298-306.
陈强, 李庆民, 丛浩熹, 等. 基于多点分布式光纤光栅的 GIS 隔离开关触头温度在线监测技术[J]. 电工技术学报, 2015, 30(12): 298-306.
- [5] Li D S, Sui Q M, Jia L. Simulation of fiber Bragg grating sensing networks using code division multiplexing and wavelength division multiplexing [J]. Acta Optica Sinica, 2010(s1): s100212.
李东升, 隋青美, 贾磊. 基于码分复用和波分复用的

- 光纤布拉格光栅传感网络仿真研究[J]. 光学学报, 2010(s1): s100212.
- [6] Childs P. An FBG sensing system utilizing both WDM and a novel harmonic division scheme [J]. *Journal of Lightwave Technology*, 2005, 23(1): 348-354.
- [7] Gong J M, MacAlpine J M K, Chan C C, et al. A novel wavelength detection technique for fiber Bragg grating sensors [J]. *IEEE Photonics Technology Letters*, 2002, 14(5): 678-680.
- [8] Hu Y, Mo W Q, Dong K F, et al. Using maximum spectrum of continuous wavelet transform for demodulation of an overlapped spectrum in a fiber Bragg grating sensor network [J]. *Applied Optics*, 2016, 55(17): 4670-4675.
- [9] Shi C Z, Chan C C, Jin W, et al. Improving the performance of a FBG sensor network using a genetic algorithm [J]. *Sensors and Actuators A: Physical*, 2003, 107(1): 57-61.
- [10] Jiang H, Chen J, Liu T D, et al. A novel wavelength detection technique of overlapping spectra in the serial WDM FBG sensor network [J]. *Sensors and Actuators A: Physical*, 2013, 198: 31-34.
- [11] Liu D, Tang K, Yang Z Y, et al. A fiber Bragg grating sensor network using an improved differential evolution algorithm [J]. *IEEE Photonics Technology Letters*, 2011, 23(19): 1385-1387.
- [12] Ding H, Wu X N, Liang J Q, et al. Application of PSO algorithm in wavelength detection of FBG sensors [J]. *Spectroscopy and Spectral Analysis*, 2010, 30(2): 563-566.
丁晖, 吴相楠, 梁建奇, 等. 粒子群优化算法在光纤光栅传感器波长解调中的应用[J]. *光谱学与光谱分析*, 2010, 30(2): 563-566.
- [13] Qi Y F, Li C L, Jiang P, et al. Research on demodulation of FBGs sensor network based on PSO-SA algorithm [J]. *Optik*, 2018, 164: 647-653.
- [14] Chen J, Lin Y T, Zhou Q X, et al. Wavelength demodulation of a spectrally overlapped fiber Bragg grating sensor network based on peak match estimation of distribution algorithm [J]. *Acta Photonica Sinica*, 2019, 48(4): 0406002.
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): 0406002.
- [15] Chen J, Jiang H, Liu T D, et al. Wavelength detection in FBG sensor networks using least squares support vector regression [J]. *Journal of Optics*, 2014, 16(4): 045402.
- [16] Jiang H, Chen J, Liu T D. Wavelength detection in spectrally overlapped FBG sensor network using extreme learning machine [J]. *IEEE Photonics Technology Letters*, 2014, 26(20): 2031-2034.
- [17] Cho K, van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [J/OL]. (2014-09-03) [2019-11-13]. <https://arxiv.org/abs/1406.1078>.
- [18] Wang X, Wu J, Liu C, et al. Exploring LSTM based recurrent neural network for failure timeseries prediction [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44(4): 772-784.
王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. *北京航空航天大学学报*, 2018, 44(4): 772-784.