

doi:10.13756/j.gtxyj.2025.240159.

光电器件研究与应用

丁美琪, 桂林, 王子怡, 等. 基于1D-CNN的射频强度温度传感研究[J]. 光通信研究, 2025(2):240159.

Ding M Q, Gui L, Wang Z Y, et al. Research on RF Intensity Temperature Sensing based on 1D-CNN[J]. Study on Optical Communications, 2025(2): 240159.

基于1D-CNN的射频强度温度传感研究

丁美琪^a, 桂 林^b, 王子怡^a, 尚荻森^a, 钱 敏^a, 李乾坤^a

(上海第二工业大学 a. 智能制造与控制工程学院; b. 计算机与信息工程学院, 上海 201209)

摘要:【目的】文章研究了基于一维卷积神经网络(1D-CNN)的微波光子滤波器(MPF)在射频(RF)强度温度传感中的应用,以提高温度传感的精度和效率。【方法】文章实验搭建了基于马赫-曾德尔干涉仪(MZI)结构的MPF系统,通过改变环境温度,采集了在陷波深度为8.1 dB条件下20~70 °C的RF谱数据,每个温度条件下采集30组数据,然后采用贪心策略设计并优化1D-CNN结构,确定网络层数、卷积核大小、池化核大小以及激活函数类型。利用训练集数据对模型进行训练,并使用测试集数据进行验证,优化模型参数以获得最佳性能。利用其非线性映射能力从RF谱数据中提取特征,实现RF强度与温度变化的高精度解调。最后采用均方根误差(RMSE)作为评价指标,并将1D-CNN的性能与传统算法(最大值法、质心法和高斯拟合法)进行对比,分析其在不同温度条件下的性能。【结果】实验结果表明,基于1D-CNN预测模型的RMSE达到了 10^{-3} 量级,而传统算法的RMSE通常在 10^{-1} 量级。与传统高斯拟合算法相比,基于1D-CNN的算法解调速度提高了2.72倍。1D-CNN在不同温度条件下均表现出较高的稳定性和较低的误差。【结论】1D-CNN在处理复杂的非线性关系和特征提取方面具有显著优势,不仅在计算效率和鲁棒性方面表现优越,还能有效应对噪声和环境的干扰。文章的研究为MPF在RF强度温度传感领域的应用提供了新的思路和方法。

关键词:一维卷积神经网络;微波光子滤波器;光纤传感;温度传感;射频强度

中图分类号:TN256

文献标志码:A

Research on RF Intensity Temperature Sensing based on 1D-CNN

DING Meiqi^a, GUI Lin^b, WANG Ziyi^a, SHANG Disen^a, QIAN Min^a, LI Qiankun^a

(a. School of Intelligent Manufacturing and Control Engineering; b. School of Computer and Information Engineering, Shanghai Polytechnic University, Shanghai 201209, China)

Abstract: 【Objective】In order to improve the accuracy and efficiency of temperature sensing, the application of Microwave Photonic Filter (MPF) based on One-Dimensional Convolutional Neural Network (1D-CNN) in Radio Frequency (RF) intensity temperature sensing is studied. 【Methods】The MPF system based on Mach-Zehnder Interferometer (MZI) structure is built experimentally, and the RF spectral data of 20~70 °C under the condition of notch depth of 8.1 dB are collected by changing the ambient temperature. 30 sets of data are collected under each temperature condition. Then the 1D-CNN structure is designed and optimized by greedy strategy to determine the number of network layers, the size of the convolutional kernel, the size of the pooled kernel and the type of activation function. The model is trained with the training set data and validated with the test set data to optimize the model parameters for optimal performance. Its nonlinear mapping capability is used to extract features from RF spectral data to achieve high-precision demodulation of RF intensity and temperature changes. Finally, the Root Mean Square Error (RMSE) is used as the evaluation index, and the performance of 1D-CNN is compared with the traditional algorithms (maximum-value method, centroid method and Gaussian fitting method) to analyze its performance under different temperature conditions. 【Results】The experimental results show that the RMSE of the prediction model based on 1D-CNN reaches the order of 10^{-3} , while the RMSE of the traditional algorithms is usually in the order of 10^{-1} . Compared with the traditional Gaussian fitting algorithm, the demodulation speed of the 1D-CNN-based algorithm is improved by 2.72 times. 1D-CNN shows high stability and low error under different temperature conditions. 【Conclusion】1D-CNN has significant advantages in dealing with complex nonlinear relationships and feature extraction, not only superior in computational efficiency and robustness, but also effective in dealing with noise and environmental interference. The research in this paper provides new ideas and methods for the application of MPF in the field of RF intensity temperature sensing.

Key words: 1D-CNN; MPF; fiber optic sensing; temperature sensing; RF intensity

0 引 言

温度监测作为工业应用和科学研究中的关键技术,对高精度和快速响应的需求日益增加。微波光

子学(Microwave Photonics, MWP)作为现代光通信和传感技术的重要组成部分,因其能够融合微波和光两种信号的优势,具有极高的应用前景^[1-4]。通过MWP技术,能够有效利用光学方法实现微波

收稿日期:2024-07-24; 修回日期:2024-09-20; 纸质出版日期:2025-04-10

作者简介:丁美琪(2000-),女,江苏淮安人。硕士,主要研究方向为微波光子传感。

通信作者:桂林,副教授。E-mail:guilin@sspu.edu.cn

© Editorial Office of Study on Optical Communications. This is an open access article under the CC BY-NC-ND license.

信号的产生、传输、处理和测量,这在光通信、雷达和传感等领域中发挥了重要作用。微波光子滤波器(Microwave Photonic Filter, MPF)作为MWP的重要分支,因其宽频带、低功耗、灵活的可重构性和抗电磁干扰能力^[5],得到广泛应用。现有研究主要依赖于矢量网络分析仪(Vector Network Analyzer, VNA)进行数据采集^[6-7],但高成本和高复杂性限制了其广泛应用。相比之下,对原始数据进行射频(Radio Frequency, RF)强度温度传感解调是一种更为经济且响应迅速的解决方案。

近年来,深度学习在MWP传感领域中取得了显著成果^[8-10]。针对温度引起的RF强度漂移的非线性问题,一维卷积神经网络(One Dimensional-Convolutional Neural Network, 1D-CNN)能提供新的解决思路。本文将1D-CNN引入MPF温度传感系统,通过在低频段对频谱RF强度进行分析,实现了对温度变化的快速和准确监测。研究表明,对于未经处理的原始数据,本文所提模型能够在低频段准确地反映环境温度的变化,其均方根误差(Root Mean Square Error, RMSE)值显著低于传统方法,并且在完成神经网络训练的前提下,解调速度优于传统的拟合法。

1 MZI结构MPF温度传感原理

1.1 MPF温度传感原理

光纤温度传感是基于光纤材料的热光效应和热膨胀效应,当温度发生变化时,光纤的折射率和长度会发生变化^[11-12],从而改变输出频谱的RF强度。这种变化在基于马赫-曾德尔干涉仪(Mach-Zehnder Interferometer, MZI)结构的MPF传感中尤为显著。具体来说,MZI由1个输入光束分离器(耦合器1)、两个平行臂(传感臂和参考臂)和1个输出光束合并器(耦合器2)组成。光束分离器将输入光束分成两束,分别进入两个平行臂。在参考臂加入可调节衰减器(Variable Optical Attenuator, VOA)平衡两臂的光功率差从而调整陷波深度 D ,其中 $D = P_{\max} - P_{\min}$,其单位为dB, P_{\max} 和 P_{\min} 分别为最大和最小RF功率,单位均为dBm。在两臂中,光分别经历不同的路径长度和折射率,导致了光程差和相位差的产生。

光程差 ΔL_0 可表示为

$$\Delta L_0 = L_s - L_r, \quad (1)$$

式中: L_s 为传感臂的长度; L_r 为参考臂的长度。

与温度 T 相关的相位差 $\Delta\varphi(T)$ 可表示为

$$\Delta\varphi(T) = \frac{2\pi(n_{\text{eff}}\Delta L(T) + \Delta n L_{\text{heat}})}{\lambda}, \quad (2)$$

式中: n_{eff} 为光纤有效折射率; ΔL 为传感臂的长度变化; Δn 为折射率变化; L_{heat} 为加热光纤的长度; λ 为光波长。当温度变化 ΔT 时, ΔL 和 Δn 可表示为

$$\Delta L(\Delta T) = L_s(\alpha\Delta T), \quad (3)$$

$$\Delta n(\Delta T) = n(\beta\Delta T), \quad (4)$$

式中: α 为热膨胀系数; β 为折射率温度系数; n 为折射率的绝对值。温度变化会引起光纤的长度和折射率的改变,从而导致MZI结构中的相位差发生变化。

在MZI结构中,输出光强 I_{out} 与温度增量 ΔT 和RF频率 f_c 的关系为

$$I_{\text{out}}(f_c, \Delta T) = I_{\text{in}} \left[1 + \cos \left(2\pi f_c \frac{n_{\text{eff}}(L_s - L_r)}{c} + \frac{2\pi(n_{\text{eff}}\Delta L(\Delta T) + \Delta n(\Delta T)L_{\text{heat}})}{\lambda} + \varphi_r \right) \right], \quad (5)$$

式中: c 为真空中的光速; I_{in} 为进入干涉仪的输入光强; φ_r 为光在干涉仪中传输时产生的随机相位。当温度变化时,由于光纤长度差和折射率的变化,引起 f_c 处RF强度的改变,实验中一般选取RF强度为最大值或最小值处的频率。由于非相干光的相位存在较大的随机性,这会导致式(5)中出现随机相位项 φ_r ,使得RF功率的改变也具有很大的随机性,导致数据异常复杂,基于此,可以引入神经网络检测RF强度变化从而推断出温度的变化。

1.2 实验结构

基于MZI结构的MPF温度检测系统装置如图1所示。首先掺铒光纤放大器(Erbium Doped Fiber Amplifier, EDFA)产生功率为+12 dBm、电流为2.1 A、波长为1550 nm的光信号作为系统的输入;接着使用RF信号发生器发出RF信号并将其调制到电/光调制器(Electro Optical Modulators, EOM)上;调制后的微波光子信号进入耦合器1,并被分为等功率的两路信号继续传输,为了增加两臂之间的光程差并实现远距离传输,在传感臂中依次连接3 m和2 km长的单模光纤,并将3 m光纤置于水浴锅加热装置中,从20℃逐渐加热至70℃,采样间隔为5℃。在参考臂加入VOA调整陷波深度为8.1 dB。两束光在耦合器2处重组形成干涉,干涉信号能够精确反映出温度引起的微小变化,如光纤的物理长度变化或折射率的变化;随后通过光电探测器(Photodetectors, PD)进行光/电转换,由电频

谱分析仪(Electrical Spectrum Analyzer, ESA)采集 PD 输出的光信号后得到特定频率的分量,并生成相应的 RF 谱图。




图 1 MZI 结构 MPF 温度检测系统

Figure 1 MZI structure-based MPF temperature detection system

在传感臂 3 m 处的传感光纤受温度变化影响下,系统的折射率和长度发生变化,从而导致传感臂与参考臂之间的光程差和相位差发生变化^[13],将其通过 ESA 扫频后,由 RF 强度直观展现出来。通过对输出 RF 强度的监测和分析,可以实现对温度的精确测量。

2 1D-CNN RF 强度解调算法设计

1D-CNN 由于具备出色的序列数据泛化能力,已在信号处理和模式识别等多个领域得到广泛应用^[14]。但对于神经网络的训练需要有目标值输出,在 MPF 传感中这个问题还未得到很好的解决。本文将二次多项式拟合法与 1D-CNN 相结合,有效克服了传统方法在处理频谱数据时缺少准确 RF 强度真值的问题,从而显著提升了传感器的精度和稳定性。

首先,使用 1.2 节所述系统采集不同温度条件下的 MPF RF 强度数据,共采集 n_o 组数据,每组数据由 m 个元素构成,包括温度 $T_j, j=1, 2, \dots, n_o$, 和对应的 RF 强度 $I_i, i=1, 2, 3, \dots, m$ 。使用二次多项式模型来拟合温度 T 与 RF 强度 I 之间的关系,并利用最小二乘法来确定 a, b 和 c 3 个系数,最后计算出每个温度 T_j 对应的拟合 RF 强度值 \hat{I}_i :

$$\hat{I}_i = aT_j^2 + bT_j + c. \quad (6)$$

将拟合后的 RF 强度值 \hat{I}_i 作为神经网络的训练目标值,首先采集的原始数据到达卷积层,用于提取频谱峰峰值部分 RF 强度数据的特征,通过大小为 k 的卷积核 w_k 与 RF 谱采集的原始 RF 强度序列 I_i 进行卷积,卷积后的输出 y_i 为

$$y_i = I * w = \sum_{s=1}^k x_{i+s} \cdot w_s, s = 1, 2, \dots, k. \quad (7)$$

从 RF 谱中采集的原始数据通常包含非线性因素,而卷积运算只能对其加权求和进行线性运算,所

以通过具体模型训练选择 ReLU 激活函数用于对卷积后的数据进行非线性处理。

采用最大池化对其进行降低特征维度处理,输出信号 $y_{pool}(y_i)$ 为

$$y_{pool}(y_i) = \max(y_{pi}, y_{pi+1}, \dots, y_{pi+p}), \quad (8)$$

式中, p 为池化核大小,假定 $p=2$, 则 $y_{pool}(y_i) = \max(y_{2i}, y_{2i+1})$ 。

之后用全连接层进行权值计算,对提取的特征进行处理和 RF 强度的预测:

$$\hat{y}_i = W \cdot I' + d, \quad (9)$$

式中: W 为权重矩阵; I' 为输入特征; d 为偏置。

最后采用 RMSE 函数评估模型性能,根据其值进行参数调整训练:

$$RMSE = \frac{1}{M} \sum_{i=1}^N (I_i - \hat{y}_i)^2, \quad (10)$$

式中: N 为序号,为点个数的最大值; \hat{y}_i 为 1D-CNN 训练输出的 RF 强度值; M 为样本数。

在设计 1D-CNN 时,贪心策略通过其简单性和高效性,能够在较短时间内找到相对较好的解决方案。贪心策略^[15]的主要思想就是控制变量法,通过改变网络结构中的某一项参数而固定其他参数,选择当前状态下的最佳选项,期望最终得到全局最优解。首先需要构建 1D-CNN 的初始结构,包括网络层数、卷积核大小、池化核大小、激活函数类型以及池化方式的选择等。待网络模型得到该条件下评价指标 RMSE 最小即可确定该项参数的值。通过此项思维对每一种参数进行寻优,最终确定整个 1D-CNN 的最优结构。具体的贪心策略参数寻优方法如图 2 所示。

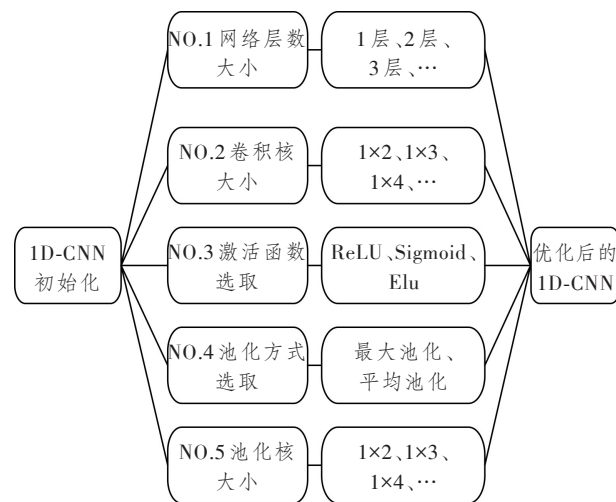


图 2 贪心策略处理方法

Figure 2 Greedy strategy approach

在陷波深度为 8.1 dB 的条件下,最大、最小 RF 强度 1D-CNN 结构的初始参数如表 1 所示。

表 1 8.1 dB 陷波深度的初始网络结构

Table 1 Initial network structure of 8.1 dB notch depth

RF 强度	层数	卷积核大小	激活函数	池化方式	池化核大小
最大值处	1	1×2	ReLU	最大池化	1×2
最小值处	1	1×2	ReLU	最大池化	1×2

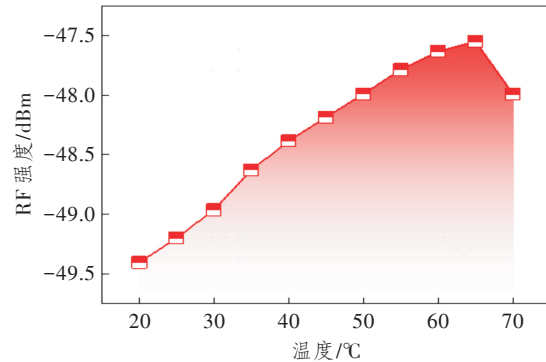
在 1.2 节所述的基于 MZI 结构的 MPF 温度检测系统中采样 330 组 RF 谱数据。首先将 RF 谱数据进行归一化处理,标准化到 0~1 之间,基于 Pytorch 构建 1D-CNN 模型,使用 Adam 优化器对网络结构进行调整,学习率设定为 0.001,迭代 400 次。对于模型训练样本的构建,通过分析频谱数据发现 RF 强度二次拟合结果最接近 1,所以采用自标记学习法,选用二次多项式拟合结果作为 1D-CNN 训练集目标值输出。所构建的 1D-CNN 为多输入多输出结构,输入 25~70 °C 温度下 330×751 的 RF 谱数据,对不同陷波深度下的实验数据进行训练,训练集与测试集的比例为 8:2。为了避免网络结构在一次输出结果中可能出现的偶然性,实验中进行了 5 次循环训练,以获得相同条件下的 RF 强度预测值,取其 5 次 RMSE 的平均值作为模型的评价指标。

3 实验结果分析

本文实验采用 1.2 节所述结构,首先使用 EDFA 发射功率为 +12 dBm 的连续波(Continuous Wave, CW)光信号,其辐射出的光信号中心波长为 1 550 nm; RF 信号模块生成调制幅度为 4 V、频率范围为 159.79~159.91 MHz、扫频时间为 30 s 的 RF 信号;使用 EOM 将微波信号加载到光波上,形成微波光子信号。该信号和光载波随后一同传输至 MZI 结构,其中直流电源输出 1 V 偏置电压,以提高调制的效率。ESA 扫描频率范围为 159.78~159.92 MHz,带宽为 5 kHz。在实验过程中室温保持在 25 °C,水浴锅温度为 20~70 °C,采样间隔为 5 °C,每个温度条件下采集 30 组。

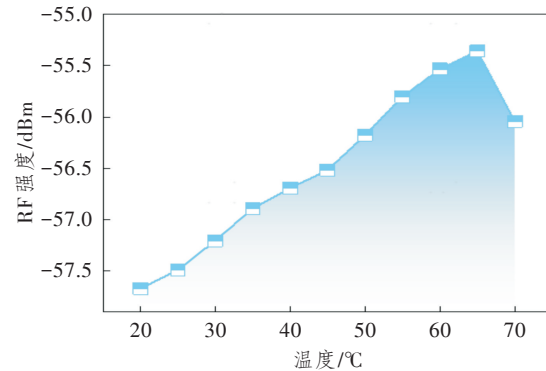
由图 3 可知,不同温度条件下采集到的 RF 谱谱线存在较大差异,随着温度的升高,RF 谱的 RF 强度最大值点整体都向上漂移,这也表明温度是影响 MPF 传感的重要因素,因此可以通过分析频谱中的 RF 强度最大值点来获取温度传感数据。特别需要注

意的是,在 70 °C 条件下,RF 强度最值都产生了突变,这是系统的不稳定性造成的,因此引入 1D-CNN 与最值法、高斯拟合法和多项式拟合法进行性能对比。



(a) RF 强度最大值变化

(a) Maximal RF intensity change



(b) RF 强度最小值变化

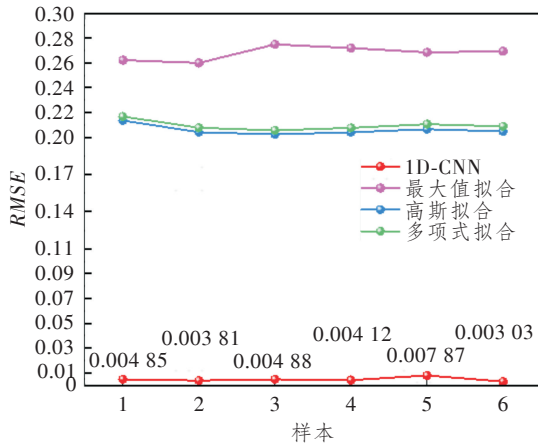
(b) Minimum RF intensity change

图 3 RF 强度最值随温度变化曲线

Figure 3 RF intensity maximums as a function of temperature

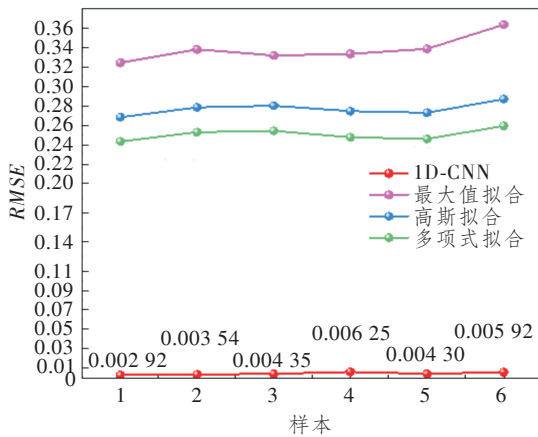
采用 1.2 节所述实验系统和 1D-CNN 结构优化方法,该神经网络参数如表 1 所示,采用贪心策略得到 8.1 dB 陷波深度下的最大、最小 RF 强度最优 1D-CNN 网络结构。由分析结果可知,RF 强度最大值与最小值所对应的最优网络结构相同,说明本结构的神经网络泛化能力较好;网络仅包含 1 层,网络层数越少,模型的复杂度越低;此外,卷积核与池化核较小,可以精确地捕捉 RF 谱序列中的短期局部模式和微小变化,提高模型的非线性和层次性;为了避免运行结果的偶然性,对 1D-CNN 循环运行 5 次,记录每次测试集的 RMSE 并计算平均误差,结果表明,基于 1D-CNN 预测模型的 RMSE 能达到 4×10^{-3} 。

图 4 所示为传统算法与 1D-CNN 测试集的 6 个样本对应的评估指标 RMSE。



(a) RF 强度最大值

(a) Maximum value of RF intensity



(b) RF 强度最小值

(b) Minimum value of RF intensity

图4 8.1 dB 陷波深度下 RF 强度最值不同算法 RMSE 比较

Figure 4 Comparison of RMSE algorithms for RF intensity maximum at a notch depth of 8.1 dB

由图可知,在对 MZI 反 RF 谱 RF 强度解调时,1D-CNN 算法的 RMSE 值远低于传统算法。在 3 种传统算法中,RF 强度最大值处高斯拟合法与多项式拟合法的 RMSE 优于最值法;RF 强度最小值处多项式拟合法的 RMSE 优于最值法与高斯拟合法。相比之下,1D-CNN 的性能最好,在 8.1 dB 陷波深度 RF 强度最值的处理中,RMSE 的均值都能达到 10^{-3} 量级以下,相较于传统算法,误差降低了两个量级,进一步证明了 1D-CNN 在处理 MZI 结构温度传感反 RF 谱 RF 强度值方面的优越性。实验结果表明,1D-CNN 不仅能够在 MZI 结构的微波光子传感中保持稳定性,还能显著降低误差,展示了其在温度传感应用中的有效性和可靠性。

1D-CNN 模型能够显著降低 RMSE,主要是因其较强的特征提取能力和非线性处理能力,通过

卷积操作,有效捕捉信号的局部特征和时序信息,非线性激活函数引入了对复杂信号的高阶特征捕捉能力;深度学习的优化过程和数据驱动的训练方法,使得 CNN 能在受噪声影响的 MWP 信号环境下自动学习最优特征表示,传统算法通常是基于固定的数学模型或假设,缺乏自适应能力,无法灵活应对不同的信号和噪声条件,这限制了其性能。但 1D-CNN 也存在一定的局限性,相较于传统算法,需要大量的标注数据来训练模型,并且模型的可解释性较低。

除此之外,本文还对比了不同算法对 RF 强度的解调时间,如表 2 所示,使用最大值法拟合解调所使用的时间最短,使用高斯拟合解调时间最长,1D-CNN 的解调速度与高斯拟合解调速度相比提高了 2.72 倍,证明 1D-CNN 在 MZI 结构温度传感中也有较高的解调效率。

表 2 不同算法的解调时间

Table 2 Demodulation time of different algorithms

算法名称	解调时间/s
最值法	4.07
高斯拟合法	19.92
多项式拟合法	6.01
1D-CNN 法	5.36

4 结束语

本文重点研究了采用 MZI 结构的 MPF 在温度传感方面的应用,并提出了一种与 1D-CNN 结合的创新方法;探讨了温度变化如何影响光纤的折射率,从而影响 RF 强度的变化。研究表明,1D-CNN 在处理复杂非线性关系和特征提取方面具有显著优势。实验结果表明,通过贪心策略得到的最优 1D-CNN 模型在 RMSE 上显著优于传统算法,达到了 10^{-3} 量级。相比于传统高斯拟合算法,1D-CNN 的解调速度提高了 2.72 倍,证明 1D-CNN 不仅能够有效应对噪声和环境干扰,还能在不同温度变化下保持高精度的解调性能,显示了其在计算效率和鲁棒性方面的优越性。

本文的研究为 MPF 在温度传感领域的应用开辟了新的思路和方法,引入 1D-CNN 不仅提高了系统的传感精度和效率,还为未来的传感技术进步提供了坚实的基础。

参考文献:

- [1] 郑狄, 邹喜华, 潘炜, 等. 基于微波光子的光纤传感解调技术(特邀)[J]. 光通信研究, 2018(6): 21-30.

- Zheng D, Zou X H, Pan W, et al. Advances of Optical Fiber Sensing Interrogation Techniques based on Microwave Photonics[J]. Study on Optical Communications, 2018(6): 21–30.
- [2] 张修文, 郑狄, 邹喜华, 等. 面向密集光纤布拉格光栅传感网络的微波光子解调技术研究[J]. 光学学报, 2023, 43(22): 108–115.
- Zhang X W, Zheng D, Zou X H, et al. Microwave Photonic Demodulation Technology for Dense Fiber Bragg Grating Sensor Network[J]. Acta Optica Sinica, 2023, 43(22): 108–115.
- [3] Zhou J, Xia L, Cheng R, et al. Radio-frequency Unbalanced M-Z Interferometer for Wavelength Interrogation of Fiber Bragg Grating Sensors[J]. Optics Letters, 2016, 41(2): 313–316.
- [4] 姬迪, 胡志涛, 王柱天, 等. 基于U波段光波产生频率可调谐的微波载波[J]. 光通信研究, 2024(2): 220054.
- Ji D, Hu Z T, Wang Z T, et al. Generation of Frequency-tunable Microwave Carriers based on the U-band Lightwave Carrier[J]. Study on Optical Communications, 2024(2): 220054.
- [5] 李乾坤, 丁美琪, 桂林, 等. 基于微波光子滤波器射频强度的叶绿素检测研究[J]. 中国激光, 2023, 50(21): 229–239.
- Li Q K, Ding M Q, Gui L, et al. Chlorophyll Detection based on Radio Frequency Intensity of a Microwave Photonic Filter[J]. Chinese Journal of Lasers, 2023, 50(21): 229–239.
- [6] 陈权, 王光英, 易振钊, 等. 基于光循环移频环的可重构微波光子滤波器[J]. 光子学报, 2024, 53(11): 1106001.
- Chen Q, Wang G Y, Yi Z Z, et al. Reconfigurable Microwave Photonic Filter based on Optical Cyclic Frequency Shift Loop [J]. Acta Photonica Sinica, 2024, 53(11): 1106001.
- [7] 徐作为. 基于微波光子学的光纤传感技术研究[D]. 武汉: 华中科技大学, 2022.
- Xu Z W. Research on Optical Fiber Sensing Technology based on Microwave Photonics[D]. Wuhan, China: Huazhong University of Science and Technology, 2022.
- [8] 罗成明. 机器学习辅助的高性能微波光子滤波解调技术研究[D]. 成都: 西南交通大学, 2022.
- Luo C M. Research on High Performance Microwave Photon Filtering and Demodulation Technology Assisted by Machine Learning[D]. Chengdu, China: Southwest Jiaotong University, 2022.
- [9] Tian X, Yan Y, Chen Y, et al. Deep Learning Enhanced Time-domain Microwave Photonic Sensor[J]. Journal of Lightwave Technology, 2023, 41(23): 7075–7082.
- [10] 郭虹, 邓鹏程, 杨慧. 深度学习在光纤通信系统损伤补偿中的应用[J]. 光通信研究, 2024(2): 220075.
- Guo H, Deng P C, Yang H. Application of Deep Learning in Impairments Compensation of Optical Fiber Communication[J]. Study on Optical Communications, 2024(2): 220075.
- [11] Tian X, Wang Y, Zhu D, et al. Radio-frequency Intensity Interrogation for Temperature Measurement[J]. IEEE Photonics Technology Letters, 2022, 34(18): 973–976.
- [12] 姚文俊, 曹洪强, 邓鹤鸣, 等. 输电线路输送容量动态增容研究[J]. 中南民族大学学报(自然科学版), 2020, 39(5): 512–516.
- Yao W J, Cao H Q, Deng H M, et al. Study on Dynamic Control Method for Increasing Transmission Capacity of Lines[J]. Journal of South-Central University for Nationalities(Natural Science Edition), 2020, 39(5): 512–516.
- [13] 朱雨霜, 桂林, 朱玉绚. 基于最大射频强度判别法的温度传感波长解调研究[J]. 光学学报, 2019, 39(7): 365–370.
- Zhu Y S, Gui L, Zhu Y X. Temperature Sensing for Wavelength Demodulation based on Recognition by Maximum Intensity of Radio Frequency[J]. Acta Optica Sinica, 2019, 39(7): 365–370.
- [14] 李明春, 李明. 基于注意力机制的无线网络优化研究[J]. 光通信研究, 2024(4): 230146.
- Li M C, Li M. Research on Wireless Network Optimization based on Attention Mechanism [J]. Study on Optical Communications, 2024(4): 230146.
- [15] 李德. 基于深度学习的弱光栅阵列波长解调算法研究[D]. 武汉: 武汉理工大学, 2020.
- Li D. Research on Wavelength Demodulation Algorithm of Weak Grating Array based on Deep Learning [D]. Wuhan, China: Wuhan University of Technology, 2020.