光电技术及应用

DOI: 10.16818/j.issn1001－5868.20251013001

基于改进DNN的F-P滤波器温度误差补偿方法

肖蔚然[1],韩晓冉[2,3],张荣达[2,3]*,刘卜玮[2,3],刘鹏鲲[2,3],姚国珍[4]

(1. 国家电投集团河北电力有限公司,石家庄 050000; 2. 东方绿色能源(河北)有限公司,石家庄 050000;
3. 河北省新能源场群智慧控制重点实验室,石家庄 050000; 4. 华北电力大学 电子与通信工程系,河北 保定 071003)

摘 要: 为解决FBG传感系统中F-P滤波器的温度误差问题,文章提出一种基于改进DNN的F-P滤波器温度误差补偿方法。该方法在传统DNN模型的基础上增加了BN层、Dropout层、注意力机制层和残差连接层,提高了DNN模型的性能。利用改进后的DNN模型预测F-P滤波器在不同温度和电压时的波长漂移,再将不同温度下F-P滤波器的波长折算到某一固定温度时的波长,从而消除了温度变化带来的误差。通过搭建实验系统,对所提方法进行实验验证,并与LSTM和LSTM+CNN误差补偿模型预测结果进行对比。实验结果表明,误差补偿后的波长标准差最大为4.7 pm,偏离平均值的最大波动为13.3 pm,相比补偿前,标准差降低了99.96%,最大波动降低了99.93%。利用所提方法可在不添加额外硬件的基础上显著提高FBG传感的精度,减小系统的复杂性和成本。

关键词: DNN; 误差补偿; F-P滤波器; 波长解调; FBG传感

中图分类号: TN911.6 **文章编号:** 1001－5868(2026)01－0186－07

Temperature-Error Compensation Method Based on an Improved Deep Neural Network for F-P Filters

XIAO Weiran[1], HAN Xiaoran[2,3], ZHANG Rongda[2,3], LIU Bowei[2,3], LIU Pengkun[2,3], YAO Guozhen[4]

(1. State Power Investment Corporation Hebei Electric Power Co., Ltd., Shijiazhuang 050000, CHN; 2. Dongfang Green Energy (Hebei) Co., Ltd., Shijiazhuang 050000, CHN; 3. Hebei Province Key Laboratory of Intelligent Control for New Energy Field Cluster, Shijiazhuang 050000, CHN; 4. Dept. of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, CHN)

Abstract: To mitigate the temperature errors in F-P filter in fiber-Bragg-grating (FBG) sensing system, a temperature-error compensation method based on an improved deep neural network (DNN) is proposed for F-P filters. The performance of the DNN model is improved by incorporating a BN layer, a dropout layer, an attention mechanism layer, and a residual connection layer, building on foundation of traditional DNN models. Temperature errors are eliminated using the improved DNN model that predicts the wavelength drift of F-P filters at different temperatures and voltages, and then converts the wavelength of the F-P filters at different temperatures to that at a fixed temperature. An experimental system is developed to experimentally verify the proposed method, and the corresponding results are compared with the prediction results of LSTM and LSTM+CNN error compensation models. The experimental results show that the maximum standard deviation of the wavelength after error compensation is 4.7 pm, and the maximum fluctuation from the average is

收稿日期:2025－10－13.

基金项目:东方绿色能源(河北)有限公司科技项目(20241230034).

*通信作者:张荣达

13.3 pm. Compared with before compensation. The standard deviation and fluctuation phase after compensation are 99.96% and 99.93% lower than those recorded before applying the compensation method. Therefore, the proposed method can be used to significantly improve the accuracy of FBG sensing, without adding additional hardware, while reducing the complexity and cost of the system.

Key words: DNN; error compensation; F-P filter; wavelength demodulation; FBG sensing

0　引言

可调谐法布里-珀罗(Fabry-Perot, F-P)滤波器可对宽谱光进行扫描,广泛应用于光纤布拉格光栅(Fiber Bragg Grating, FBG)传感系统中的波长解调[1]。然而,F-P滤波器的透射波长除了受驱动电压的影响外,还受温度影响[2],这给波长解调带来误差,从而影响传感精度。

为消除F-P滤波器的温度特性对解调精度的影响,现有方法主要分为硬件和软件两大类。硬件方法主要是通过在系统中添加波长参考器件来实现波长校准,例如采用热稳定F-P标准具[3]、参考光栅[4]、气室[5]和复合波长参考[5-6]等。

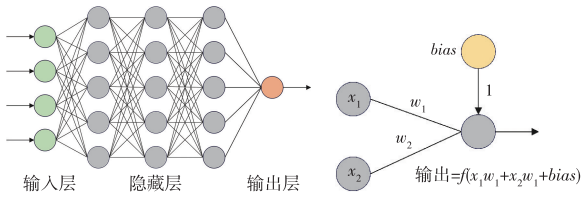
随着人工智能技术的发展,利用机器学习算法进行误差补偿已被应用在FBG波长解调中。目前报道的误差补偿模型包括支持向量回归[7]、长短期记忆网络[8]、变分模态分解[9]、时间卷积网络[10]、AdaBoost算法[11]、卷积神经网络[12]等。这些方法各具特点,但大部分都只在小温度范围内进行了验证,尚需进一步研究以扩展其适用性。

深度神经网络(Deep Neural Network, DNN)因其强大的非线性拟合和特征提取能力[13],已在多个行业得到了广泛应用。本文提出一种基于改进DNN的F-P滤波器温度误差补偿方法。该方法在传统DNN模型的基础上增加了BN层、Dropout层、注意力机制层和残差连接层,以进一步提高DNN模型的性能。利用改进DNN模型预测F-P滤波器在不同温度和电压时的波长漂移,再将不同温度下F-P滤波器的波长折算到某一固定温度时的波长,从而消除温度变化带来的误差。采用该方法后,误差补偿的温度范围扩展到了20℃~50℃,且相比补偿前标准差降低了99.96%,最大波动降低了99.93%。

1　基于改进DNN的误差补偿原理

1.1　DNN模型

DNN模型是由多层神经元构成的神经网络,其核心机制在于借助多个全连接层,实现对复杂数据的多层次特征提取与非线性拟合。DNN的基本构成包括输入层、若干隐藏层和输出层,如图1所示[14]。每层由多个神经元组成,这些神经元通过带权重的连接相互作用。



(a) DNN原理示意图　　(b) DNN的一个网络节点

图1　DNN模型原理

每个神经元接收来自前一层神经元的输入,计算加权和,并采用激活函数引入非线性因素,使得网络能够拟合复杂关系。假设某神经元接收前一层的输入向量为$\boldsymbol{x}=[x_1, x_2, \cdots, x_n]$,则其输出可以表示为:

$$y=f\left(\sum_{i=1}^{n}\omega_i x_i+b\right) \tag{1}$$

式中,x_i是输入值;ω_i是对应的权重,表示输入特征在当前神经元进行的分配;b是偏置项,用于调整神经元的激活阈值;f是激活函数。

在前向传播过程中,输入数据从输入层开始,经过多个隐藏层的处理,最终到达输出层。每一层的神经元接收来自上一层的信号,计算加权和,然后通过激活函数引入非线性特性,生成输出。

在训练过程中,DNN通过反向传播算法计算每个权重对于总损失的影响。基于此影响,通过梯度下降算法更新权重,以减小损失函数的值。权重更新公式为:

$$\omega_{\text{new}}=\omega_{\text{old}}-\eta\frac{\partial L}{\partial\omega_{\text{old}}} \tag{2}$$

式中,ω_{new}是更新前的权重,ω_{old}是更新后的权重,η是学习效率,$\partial L/\partial\omega$是损失函数相对于权重的梯度。

DNN的训练目标是通过最小化损失函数来调整模型参数,当进一步调整模型参数无法显著降低损失函数时,学习过程结束。

1.2 DNN模型的改进

传统的DNN虽然能够有效解决非线性预测问题，但还存在许多其他问题，例如容易过拟合、预测精度不高、权重分配不合理等。针对上述问题，本文对DNN模型进行改进，改进后的数据处理逻辑图如图2所示。在此改进模型中，输入数据首先进入特征提取模块，该模块由三个全连接层构成。每个全连接层后都配有一个BN层进行批归一化和一个Dropout层防止过拟合以增强模型性能，通过逐步降维提取输入数据的深层特征。提取的深层特征被送入注意力机制层和残差连接层，注意力机制层会动态分配特征权重，强化重要特征，弱化次要特征；残差连接层则将原始输入数据与注意力机制层处理后的特征相融合，保留特征中的原始信息，从而有效缓解深层网络的梯度消失问题，加速训练并提高模型性能。最后，通过全连接层和BN层将融合后的特征映射到最终的输出结果。

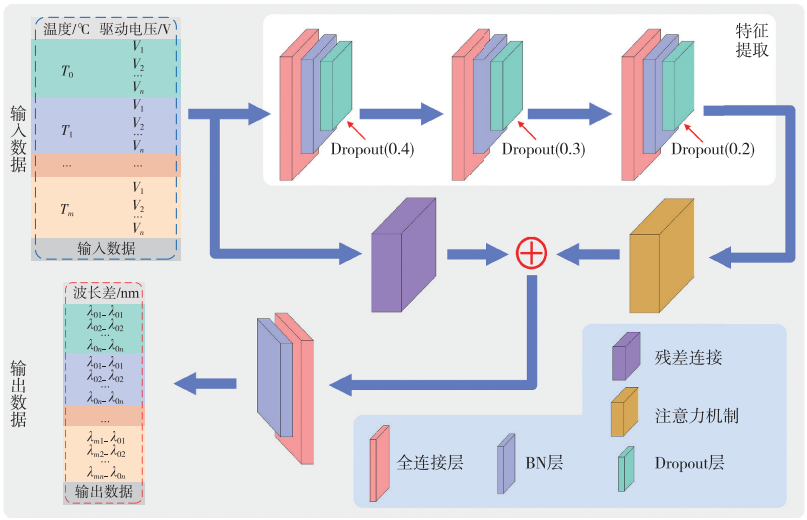


图2 DNN数据处理逻辑图

1.3 温度误差补偿方法

F-P滤波器的透射波长同时受温度和驱动电压的影响。在不同温度下，相同的电压变化对应基本相同的波长变化。在不同电压下，相同的温度变化也对应基本相同的波长变化。因此，可将温度和电压对波长的影响分离开，即透射波长可由公式(3)表示：

$$\lambda_{TV}=\lambda_{T_1V_1}+\Delta\lambda_V+\Delta\lambda_T \tag{3}$$

式中，$\lambda_{T_1V_1}$表示F-P滤波器在电压为V_1、温度为T_1时的初始波长，$\Delta\lambda_V$和$\Delta\lambda_T$分别表示电压导致的波长变化和温度导致的波长变化。

利用改进的DNN模型预测公式(3)中的$\Delta\lambda_T$，然后从公式(3)中将其减掉。去掉$\Delta\lambda_T$后，相当于将在环境温度为T时测得的波长λ_{TV}折算为环境温度为T_1时的波长λ_{T_1V}，即可消除温度对波长的影响。

2 实验测试与分析

2.1 实验系统搭建

为验证所提方法的有效性，搭建如图3所示的实验测试系统。系统主要由宽谱光源、F-P滤波器、F-P标准具、FBG温度传感器、光电探测器和采集卡等组成。

宽谱光源发出的光通过三角波驱动的F-P滤波器后，转变为扫描光。该扫描光通过1×3耦合器后分为三部分：第一部分进入相对波长参考通道，此通道中的F-P标准具可提供多个等光频间隔的相对波长参考；第二部分进入光谱仪，以获得F-P滤波器的透射谱；第三部分经环形器后进入三个FBG温度传感器，其反射光再经环形器进入光电探测器。第一路和第三路光信号通过光电探测器后转换为电信号，由数据采集卡采集得到光谱。F-P滤波器驱动器产生三角波驱动F-P滤波器进行光谱扫描，同时三角波被送入采集卡。在同步信号的作用下，与F-P标准具和FBG的光谱同步被转化为数字量。

实验利用F-P标准具对FBG进行波长解调，并将解调结果与所提方法进行对比。此外，利用光谱仪采集温度变化时F-P滤波器的光谱，分析F-P滤波器受温度影响产生的误差。

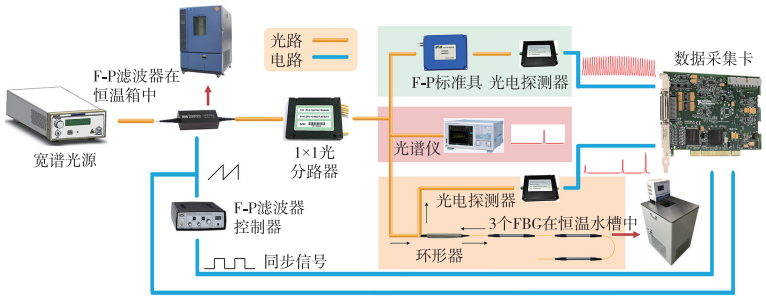


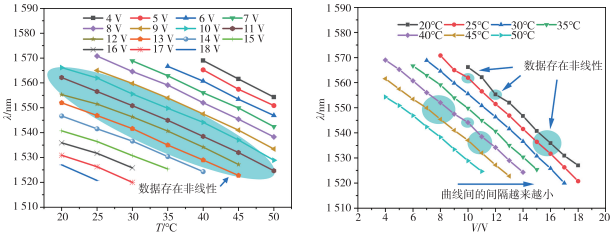
图 3　实验测试系统

2.2　温度误差分析

首先对 F-P 滤波器输出波长受温度影响的特性进行实验测试，然后对 FBG 波长解调的误差进行分析。在测试过程中，向 F-P 滤波器输入宽谱光，利用光谱仪测量其在不同温度和电压时的输出波长。具体实验步骤如下：将 F-P 滤波器放置在恒温箱中，首先保持 F-P 滤波器的驱动电压不变，改变恒温箱的温度，由 20℃升高至 50℃，步进为 0.5℃，用光谱仪记录 F-P 滤波器透射谱波长随温度的变化情况；然后，改变驱动电压并重复上述过程，得到不同温度和电压时对应的波长。由于 F-P 滤波器透射波长改变一个自由光谱范围内对应的电压为 18 V，基于此设置驱动电压的变化范围为 4～18 V，步进为 0.5 V。最终，得到 20℃～50℃和 4～18 V 范围内的 F-P 滤波器的透射波长。图 4 给出了电压不同时波长和温度的关系，以及温度不同时波长和电压的关系。为了更清晰地呈现结果，仅选取了温度间隔为 5℃、电压间隔为 1 V 时的数据进行展示。

由图 4 可以看出，温度对 F-P 滤波器的透射波长有明显的影响，且表现出多种非线性特性。例如，波长-温度关系曲线或波长-电压关系曲线都呈现一定的弯曲形态，且在不同温度下的波长-电压曲线间的间隔不同，随着温度降低间隔变小。因此，通过线性拟合进而用传统的数学方法进行误差补偿可能引入较大的误差。

DNN 模型具有多层感知机的层级结构与非线性激活机制，通过数据驱动的方式可以从图 4 所示的样本中自主学习特征间的非线性依赖关系，从而有效处理上述温度和波长间的非线性关系。同时，DNN 模型还具有非常强的泛化能力，主要体现在对测试数据中非步进点的处理上。本文测试数据的电压步进为 0.5 V，温度步进为 0.5℃。对于非步进点数据，传统的数学方法只能通过线性插值进行处理，而这类数据可能不满足线性关系，导致误差的产生。相反，DNN 模型通过多层非线性映射和特征学习，能捕捉温度连续变化时波长的细微趋势，从而提高非步进点数据的预测的准确性。同时，对于超出训练区间的外推预测，其趋势贴合度也优于传统的数学方法。



（a）波长-温度关系　　（b）波长-电压关系

图 4　波长和温度及电压的关系

当对 FBG 进行波长解调时，如果不考虑温度对 F-P 滤波器的影响，则认为 F-P 控制器的驱动电压与透射波长有固定关系。利用这一关系可计算出 FBG 的波长，其原理示意图如图 5 所示。

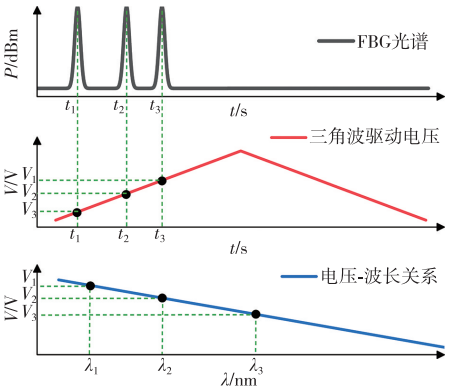


图 5　利用 F-P 滤波器进行波长解调原理示意图

采用上述方法，在不进行温度补偿的情况下对 FBG 的波长进行解调。实验中，将三个 FBG 放在温度为 20℃的恒温水浴槽中，因此其中心波长基本保持不变，三个 FBG 在 20℃时波长分别约为 1 536.2 nm，1 550.7 nm 和 1 557.9 nm。将恒温箱的温度由 20℃

逐步升高至50℃,步进为5℃,并在每个温度点温度稳定后保持5分钟左右。测得的三个FBG的波长受温度影响带来的漂移如图6所示。可以看出,温度由20℃升高至50℃后,FBG1波长漂移了大约36 nm,整个温度范围内波长的标准差为11.694 nm,偏离平均值的最大波动为19.146 nm。此外,FBG2和FBG3的波长已经超出了F-P滤波器的波长范围。由于三个FBG放在恒温水浴槽中,其中心波长基本保持不变,但由于F-P滤波器的温度变化,按照图5所示方法计算得到的FBG的波长仍表现出持续漂移。

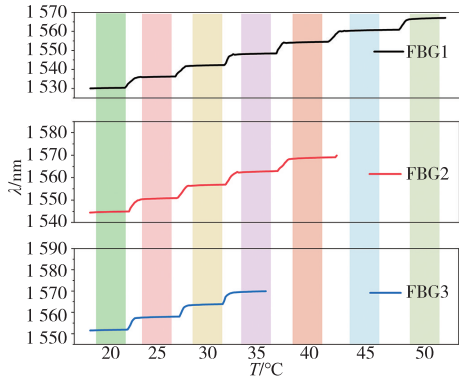


图6 补偿前的FBG波长

2.3 利用改进DNN进行误差预测

为验证所提方法的有效性,利用实验采集的F-P滤波器的温度-电压-波长数据构建数据集。在数据采集过程中,温度由20℃升高至50℃,步进为0.5℃,共获得61个温度值;F-P滤波器的驱动电压变化范围为4~18 V,步进为0.5 V,共获得29个电压值。按照上述方法,理论上采集1 769(61×29)组数据,但由于F-P滤波器工作的波长范围约为1 520~1 570 nm,部分电压和温度对应的波长超出了此范围。例如,当温度和电压分别为30℃和7 V时测得的波长为1 568.856 nm。若保持电压为7 V不变并继续减小温度,波长将超过F-P滤波器的波长范围,因此采集的有效数据共1 240组。模型的输入为F-P滤波器的温度T_1至T_m和驱动电压为V_1至V_n,此处$m=61$,$n=29$。模型的输出为上述温度和电压对应的波长减去温度为T_1、驱动电压分别为V_1至V_n时对应的波长得到的波长差,即温度影响带来的波长波动$\Delta\lambda_T$。数据集的构成如图7所示,其中的λ_{mn}表示温度为T_m、电压为V_n时F-P滤波器的波长。

公式(1)给出了当输入为1维向量时DNN模型中某神经元的输出表达式,本实验的输入为温度和电压两个特征向量,此时公式(1)的形式变换为公式(4)所示的形式,即:

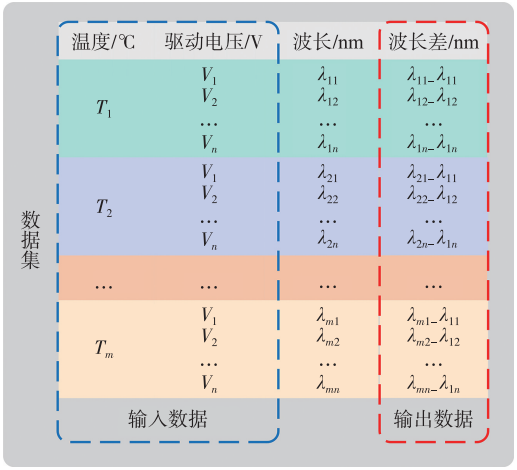


图7 数据集

$$y=f\left[\sum_{i=1}^{m\times n}(\omega_{1i}V_i+\omega_{2i}T_i)+b\right] \tag{4}$$

式中,ω_1和ω_2分别是电压向量和温度向量对应的权重;V和T分别为电压向量和温度向量,每个向量中包含$m\times n$个元素,如公式(5)和(6)所示:

$$V=[\overbrace{\overbrace{V_1,V_2,\cdots,V_n}^{n\text{个}},\overbrace{V_1,V_2,\cdots,V_n}^{n\text{个}},\overbrace{V_1,V_2,\cdots,V_n}^{n\text{个}}}^{m\text{组}}] \tag{5}$$

$$T=[\overbrace{\overbrace{T_1,T_1,\cdots,T_1}^{n\text{个}},\overbrace{T_2,T_2,\cdots,T_2}^{n\text{个}},\overbrace{T_m,T_m,\cdots,T_m}^{n\text{个}}}^{m\text{组}}] \tag{6}$$

数据集按照8:2的比例随机划分为训练集和测试集,并利用训练集对模型进行训练。训练模型时采用的损失函数为MAE,优化器为Adam,设置的学习率为0.001,隐藏层节点数分别为256,128和64。为了验证模型的泛化性能,分别采用测试集和训练集对模型的预测性能进行测试,预测结果的平均绝对误差(Mean Absolute Error, MAE)、绝对误差标准差(Standard Deviation of Absolute Errors, SDAE)和最大绝对误差(Maximum Absolute Error, MaxAE)如表1所示。由表1可知,采用训练集和测试集的表现接近,说明模型的泛化性能良好。

表1 模型泛化性能测试

指标	训练集	测试集	差距
MAE	6.288 0	6.432 0	0.144 0
SDAE	4.569 2	4.649 0	0.079 8
MaxAE	14.964 8	18.832	3.867 2

为了对比不用模型的预测能力,还建立了长短期记忆网络(Long Short-Term Memory, LSTM)、

LSTM+卷积神经网络（Convolutional Neural Networks，CNN）的温度误差补偿模型，对比三种方法预测输出的MAE，SDAE和MaxAE。三种模型采用测试集预测的绝对误差如图8所示，可以看出，所提出的DNN模型的MAE，SDAE和MaxAE分别为6.432 pm，4.649 pm和18.832 pm，性能均优于其他两种模型。

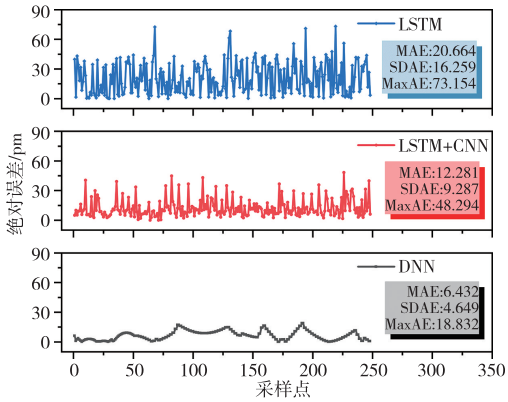


图8　预测绝对误差

2.4　误差补偿实验及结果分析

2.4.1　误差补偿实验

利用所提方法对三个FBG的波长进行误差补偿，同时还利用图3所示系统中的F-P标准具（波长温度稳定性：±0.235 GHz）对FBG的波长进行解调以便于对比。补偿后的FBG波长以及采用F-P标准具解调的波长及统计结果分别如图9和表2所示。

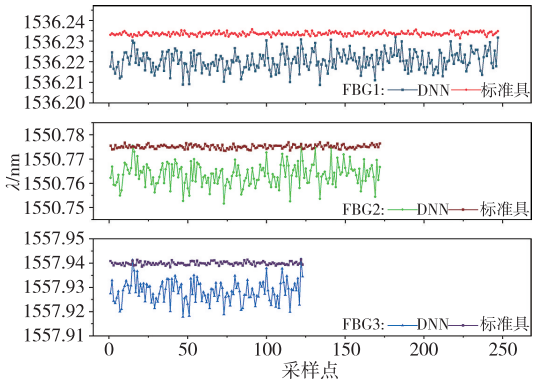


图9　补偿后FBG波长

表2　误差补偿后和采用F-P标准具获得的波长统计结果

FBG编号	DNN			F-P标准具		
	均值/nm	标准差/pm	最大波动/nm	均值/nm	标准差/nm	最大波动/nm
1	1 536.221	0.004 6	0.011 4	1 536.234	0.000 8	0.004 3
2	1 550.764	0.004 6	0.012 5	1 550.775	0.000 8	0.003 1
3	1 557.929	0.004 7	0.013 3	1 557.940	0.000 7	0.003 7

由图9可知，采用所提方法获得的三个FBG波长平均值都小于F-P标准具解调的波长平均值，最大差异为13 pm。这一现象是由于利用F-P标准具测得的FBG波长更接近其真实波长，而通过所提方法进行误差补偿后得到的波长相当于利用F-P滤波器在20℃时测得的波长，这个波长并不一定反映FBG的真实波长，两者之间存在一个固定的差值。经过误差补偿后的波长标准差最大为4.7 pm，偏离平均值的最大波动为13.3 pm，相比补偿前标准差降低了99.96%，最大波动降低了99.93%。误差补偿后的FBG波长变化明显小于补偿前，说明误差补偿效果明显。

2.4.2　消融实验

本文对DNN模型进行了改进，通过添加注意力机制层以强化重要特征，并添加残差连接层以缓解梯度消失问题，从而提高模型的性能。为了验证模型改进的效果，针对注意力机制和残差连接分别进行了消融实验，实验结果如表3所示。

由表3可知，当对改进的DNN模型进行训练时，模型收敛至最佳性能所需的训练次数为54，验证损失为0.000 346。相较之下，去掉注意力机制层或残差连接层后，模型收敛至最佳性能所需的训练次数显著增加，且验证损失显著增大。同时，当对改进的DNN模型进行训练时，第10次训练时的验证损失为0.002 538，已经优于去掉残差连接层时的验证损失；第27次训练时的验证损失为0.001 291，已经优于去掉注意力机制层时的验证损失。通过以上消融实验表明，注意力机制层和残差连接层可有效提高模型的性能。

表3　消融实验结果

注意力机制	残差训练	训练次数	验证损失
√	√	54	0.000 346
	√	186	0.001 525
√		101	0.003 556

3　结论

针对FBG传感系统中F-P滤波器的温度特性引入波长误差，本文提出一种基于改进DNN的温度误差补偿方法。在传统DNN模型的基础上，通过增加BN层、Dropout层、注意力机制层和残差连接层对模型进行改进，进一步提高了DNN模型的性能。利用改进DNN模型，可以有效预测不同温度和电压下的波长漂移量，并通过折算消除波长漂移引入的误差，

从而提高波长解调精度。为检验所提方法的有效性,搭建实验测试系统,采集了20℃～50℃范围内的F-P滤波器的温度-电压-波长数据对模型进行验证,并将改进DNN模型与LSTM和LSTM＋CNN模型的预测结果进行了比较。同时,利用所提方法对FBG的波长进行误差补偿。实验结果表明,在20℃～50℃的温度范围内,所提方法的MAE,SDAE和MaxAE分别为6.432 pm,4.649 pm和18.832 pm。误差补偿后的波长标准差最大为4.7 pm,偏离平均值的最大波动为13.3 pm,相比补偿前标准差降低了99.96%,最大波动降低了99.93%。由此可见,利用所提方法可实现20℃～50℃范围内的温度误差补偿,在不添加额外硬件的基础上显著提高FBG传感的精度,并减小系统的复杂性和成本。

参考文献:

[1] Dante A, Bacurau R M, Spengler A W, et al. A temperature-independent interrogation technique for FBG sensors using monolithic multilayer piezoelectric actuators[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(11): 2476-2484.

[2] Hao H, Lin H, Chen J, et al. Enhanced laser self-mixing interferometry based on tunable Fabry-Perot Filter[J]. Optics & Laser Technology, 2021, 135: 106666.

[3] 陆行知, 董明利, 张 旭, 等. 基于F-P标准具非线性波长校准的FBG传感系统解调方法[J]. 电子测量与仪器学报, 2023, 37(7): 26-32.
Lu Xingzhi, Dong Mingli, Zhang Xu, et al. Demodulation method of FBG sensing system based on F-P standard with nonlinear wavelength calibration [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 26-32.

[4] 王 鹏, 赵 洪, 刘 杰, 等. 基于可调谐F-P滤波器的FBG波长解调系统的动态实时校准方法[J]. 光学学报, 2015, 35(8): 0806006.
Wang Peng, Zhao Hong, Liu Jie, et al. Dynamic real-time calibration method for fiber Bragg grating wavelength demodulation system based on tunable Fabry-Perot filter[J]. Acta Optica Sinica, 2015, 35(8): 0806006.

[5] 江俊峰, 何 盼, 刘铁根, 等. 基于复合波长参考的温度稳定光纤光栅传感解调研究[J]. 光学学报, 2015, 35(10): 74-79.
Jiang Junfeng, He Pan, Liu Tiegen, et al. Research of temperature-stable fiber Bragg grating sensing demodulation based on composite wavelength references [J]. Acta Optica Sinica, 2015, 35(10): 74-79.

[6] Yao G, Yin Y, Li Y, et al. High-precision and wide-wavelength range FBG demodulation method based on spectrum correction and data fusion[J]. Optics Express, 2021, 29(16): 24846-24860.

[7] 刘颖刚, 李 飞, 袁宇博, 等. 基于SSA-SVR算法的光纤光栅波长解调方法[J]. 光子学报, 2025, 54(1): 0106001.
Liu Yinggang, Li Fei, Yuan Yubo, et al. FBG wavelength demodulation method based on support vector regression optimized by sparrow search algorithm [J]. Acta Photonica Sinica, 2025, 54(1): 0106001.

[8] 盛文娟, 胡 俊, 彭刚定. 基于注意力机制和长短期记忆网络的F-P滤波器温漂误差修正[J]. 光学学报, 2023, 43(22): 2205001.
Sheng Wenjuan, Hu Jun, Peng Gangding. Temperature drift error correction of F-P filter based on attention mechanism and LSTM network [J]. Acta Optica Sinica, 2023, 43(22): 2205001.

[9] Sheng W, Zhan J, Wen J, et al. Drift calibration method of Fabry-Perot filters using two-stage decomposition and hybrid modeling[J]. Optics Express, 2023, 31(6): 9657-9668.

[10] Yin X, Sheng W. Tunable filter temperature drift error research using the TCN model [C]//2023 4th International Conference on Advanced Electrical and Energy Systems (AEES), 2024: 98-101.

[11] 盛文娟, 赖振谱, 杨 宁, 等. 基于改进AdaBoost算法的可调谐F-P滤波器温漂补偿方法[J]. 光学学报, 2023, 43(3): 0306004.
Sheng Wenjuan, Lai Zhenpu, Yang Ning, et al. Temperature drift compensation method for tunable F-P filter based on improved AdaBoost algorithm[J]. Acta Optica Sinica, 2023, 43(3): 0306004.

[12] 任嘉楠, 焦 点, 杨 铎, 等. 一种基于CNN的混叠光谱解调算法及FPGA实现[J]. 半导体光电, 2024, 45(2): 295-302.
Ren Jianan, Jiao Dian, Yang Duo, et al. CNN-based overlapping spectral demodulation algorithm and its FPGA implementation [J]. Semiconductor Optoelectronics, 2024, 45(2): 295-302.

[13] Elbrächter D, Perekrestenko D, Grohs P, et al. Deep neural network approximation theory [J]. IEEE Transactions on Information Theory, 2021, 67(5): 2581-2623.

[14] Weeber C. Development of a cost optimal predictive maintenance strategy[J]. Junior Management Science, 2024, 9(3): 1805-1835.

作者简介:

肖蔚然(1972—),女,山东省淄博市人,高级工程师,主要从事风电、光伏等新能源发电技术的研究工作;

张荣达(1989—),男,工程师,主要从事电力自动化方面的研究工作。