

DOI:10.16136/j.joel.2022.01.0172

基于神经网络的双芯谐振光纤色散补偿特性预测分析

熊越, 秦海波, 黄薇*

(天津理工大学 计算机科学与工程学院计算机视觉与系统重点实验室(教育部), 天津 300384)

摘要: 本文针对双芯谐振色散补偿微结构光纤中色散调控与结构参数优化等问题, 提出了一种基于神经网络的光纤轨道角动量模式色散特性预测方法。通过搭建多层神经网络模型, 调节神经网络的隐藏层层数、神经元个数及网络超参数, 得到了较为准确的色散预测结果。本文提出的方法建立了光纤结构与色散特性之间的联系与规律, 与传统光学仿真计算方法相比, 该方法可以更快更高效地找到光纤结构对应的模式色散特性, 对光纤结构的设计和优化有一定的指导作用。

关键词: 神经网络; 轨道角动量模式; 色散补偿; 光学特性预测

中图分类号: TP391.7 **文献标识码:** A **文章编号:** 1005-0086(2022)01-0104-09

Prediction and analysis of dispersion compensation characteristics of a dual-ring resonant fiber based on neural network

XIONG Yue, QIN Haibo, HUANG Wei*

(Key Laboratory of Computer Vision and Systems (Ministry of Education), School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China)

Abstract: Aiming at the problems of dispersion regulation and structural parameter optimization in dual-ring resonant dispersion compensation microstructure fiber, a dispersion characteristic prediction method of orbital angular momentum mode based on neural network is proposed in this paper. By designing a multi-layer neural network model and adjusting the number of hidden layers, neurons and super parameters of the neural network, accurate dispersion prediction results are obtained. This proposed method establishes the relationship between fiber structures and dispersion characteristics. Compared with the traditional optical simulation method, this method can calculate the dispersion characteristics for different fiber structures more quickly and efficiently, which could provide a new approach for the design and optimization of fiber structures.

Key words: neural network; orbital angular momentum mode; dispersion compensation; optical property prediction

1 引言

光纤轨道角动量 (orbital angular momentum, OAM) 模式以其独特的光学特性, 近年来成为了光纤通信领域的研究热点, 并得到了广泛研究^[1,2]。基于 OAM 模式的光纤通信技术迅猛发展, 各类大容量光纤 OAM 通信系统层出不

穷^[3-6]。然而, 目前已报道的 OAM 光纤通信系统传输距离都比较近, 随着传输速率和距离的不断增加, 色散成为了限制通信距离和传输带宽的主要因素。受 OAM 模式的传输稳定特性影响, 传统光纤通信色散补偿技术容易导致 OAM 模式与同阶矢量模式之间发生耦合转换, 难以保证螺旋相位的稳定传输, 因此无法直接应用于光纤 OAM

* E-mail: weihuang@tjut.edu.cn

收稿日期: 2021-03-09 修订日期: 2021-05-28

基金项目: 天津市自然科学基金项目“光纤轨道角动量光束传输色散补偿调控技术研究”(19JCQNJC01500)资助项目

通信系统。

针对 OAM 光纤通信系统的色散补偿技术,不仅需要保证 OAM 模式的长距离稳定传输,还需要解决系统色散的补偿及调控功能。在前期工作中,本文针对 OAM 模式的传输特性,设计了一个双芯谐振色散补偿微结构光纤^[7],该光纤由高折射率双环构成,不仅可以支持 OAM 模式的稳定传输,内外双环之间的模式谐振也带来了很高的色散系数,该光纤在 OAM 通信色散补偿领域有潜在的应用价值。在该光纤设计仿真过程中,本文发现模式之间的谐振耦合特性对色散值有很大的影响,通过调节光纤内包层 2 层空气孔的结构参数,能够极大地影响内外双环模式之间的耦合特性,从而可以调控不同 OAM 模式的色散补偿系数。但是在实际调控设计过程中,为了获取理想的色散特性,需要对光纤结构进行多次反复调节,人工的调节过程伴随着极大的不确定性也充斥着大量的冗余工作,无法针对所需的特定色散系数,快速精准地找到合适的光纤结构参数。

人工神经网络 (artificial neural network, ANN) 作为一种新型智能计算方法,为光学结构与光学特性之间建立起了一座桥梁。随着人工智能和神经网络的发展,越来越多的光学研究人员开始尝试将神经网络与光学设计研究结合起来^[8-11]。LIU 等^[12]将深层神经网络应用于光子器件逆设计,克服了数据不一致导致训练过程缓慢的问题,使深层神经网络能够对包含非唯一性实例的数据集进行有效的训练。TAKASHI 等^[13]利用卷积神经网络来优化二维光子晶体纳米腔,神经网络辅助设计结果比人工优化基底结构优 10 倍。CHUGH 等^[14]结合有限元和机器学习成功预测了不同集成光子器件的模式有效折射率、功率限制因子和耦合长度。何志琴等^[15]提出一种基于神经网络的光纤结构优化设计方法,通过将相邻模式之间的最小折射率差作为弱耦合优化目标,实现了支持多个模式的少模光纤的反向设计。可以得出,将神经网络技术引入光学结构设计,通过预测光学特性、辅助优化光学结构,不仅能提高光学结构的设计效率,对光学研究及极限光学性能结构的研发也具有重要的指导意义。

因此,在前期工作基础上,针对双芯谐振 OAM 色散补偿光纤的色散精准调节及结构参数优化过程中存在的诸多问题,本文提出了一种基于神经网络的双芯谐振 OAM 光纤色散特性预测方法,通过 COMSOL Multiphysics 有限元软件采集了不同包层结构中模式有效折射率及色散值作为网络训练数据,搭建了多层 ANN 模型,通过调

整神经网络的隐藏层层数、神经元个数以及超参数,得到了较为准确的色散预测结果。该工作不仅可以快速准确预测不同包层结构对应的色散系数,进一步对光纤结构优化提供参考,也为光纤通信系统的色散自动反馈调节提供了新的思路。

2 获取训练数据

在前期工作中,设计了一个双芯谐振色散补偿微结构光纤^[7],光纤几何结构横截面示意图如图 1 所示。该光纤由内外高折射率双环和双空气孔包层构成,内外双环之间的模式谐振导致了极高的色散系数,通过调节光纤内包层 2 层空气孔的结构参数,能够极大地影响内外双环模式之间的耦合特性,从而可以调控不同 OAM 模式的色散补偿系数。然而人工调节过程繁琐又耗时,为了获取理想的色散特性,针对所需的特定色散系数,快速精准地找到合适的光纤结构参数,搭建了多层 ANN 模型用于快速寻找光纤结构与色散之间的规律。

在训练神经网络之前,首先建立了数据集,利用 COMSOL Multiphysics 有限元软件采集不同内包层结构中光纤模式对应的有效折射率及色散数据。如图 1 所示,光纤内高折射率环的内外径分别为 r_0 和 r_1 ,外高折射率环的内外径分别为 r_2 、 r_3 ,内包层第一圈空气孔与纤芯距离为 R_1 ,第二圈空气孔与纤芯距离为 R_2 ,内包层空气孔半径为 r_4 ,光纤中心为半径 r_0 的空气孔构成,外包层由 4 层直径为 d 的空气孔构成,第一层空气孔与纤芯距离为 R_3 ,之后每层空气孔之间的距离为 Δ_R 。该光纤包层材料为纯二氧化硅,内外高折射率环的材料为掺杂 SiO_2 ,折射率分别为 n_1 和 n_2 。

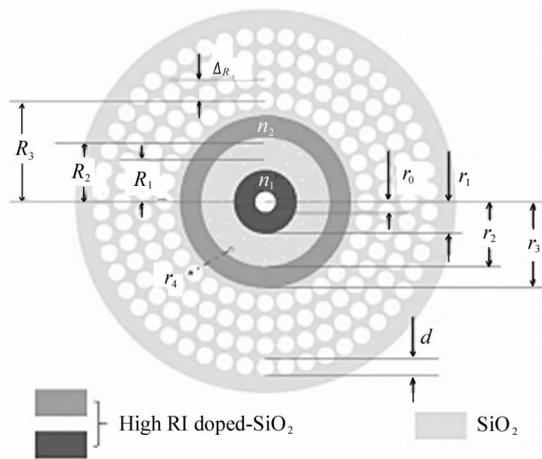


图 1 光纤几何结构横截面示意图^[7]

Fig. 1 Crossection of the designed dual-ring microstructure fiber^[7]

在采集数据过程中,选取光纤结构 $r_0 = 2 \mu\text{m}$, $r_1 = 6 \mu\text{m}$, $R_1 = 8 \mu\text{m}$, $R_2 = 11 \mu\text{m}$, $r_2 = 13 \mu\text{m}$, $r_3 = 16 \mu\text{m}$, $d = 3.4 \mu\text{m}$, $R_3 = 19 \mu\text{m}$, $\Delta_R = 4 \mu\text{m}$, $n_1 - n_0 = 0.03$, $n_2 - n_0 = 0.0267$, 其中 n_0 代表 SiO_2 的材料折射率。针对不同的内包层空气孔半径 r_4 , 使用 Comsol 仿真软件计算得到 EH_{11} 和 HE_{31} 模式的有效折射率。当 r_4 取值为 $0.1 \mu\text{m}$ 、 $0.2 \mu\text{m}$ 和 $0.3 \mu\text{m}$ 时, 计算了 1543 nm 到 1558 nm 波段范围的 EH_{11} 模式和 1540 nm 到 1558 nm 波段范围的 HE_{31} 模式, 波长间隔为 0.3 nm 。当 r_4 取值为 $0.4 \mu\text{m}$ 和 $0.5 \mu\text{m}$ 时, 计算了 1548 nm 到 1558 nm 波段范围的 EH_{11} 模式和 1542 nm 到 1554 nm 波段范围的 HE_{31} 模式, 波长间隔为 0.1 nm 。通过上述仿真计算, 共得到 741 组有效折射率数据。随后通过 Matlab 使用 Sellmeier 色散公式对有效折射率实部数据进行处理, 计算得到相应的色散数据 741 组。

3 构建神经网络模型

ANN 是一种运算模型, 网络中每一层的神经元都能够接收来自上一层神经元输出的信息并进行独立的计算, 然后将计算结果输出至下一层。网络内部能够通过神经元之间的相互联系实现输入到输出状态空间的非线性映射, 从而可以很好地处理一些非线性的问题或任务。本文采用了多层前馈神经网络, 模型示意图如图 2 所示。该网络由输入层, 多层的隐藏层以及输出层构成。输入层节点包含光纤各环半径 (r_0, r_1, r_2, r_3), 内外高折射率环的材料折射率 (n_1, n_2), 外包层空气孔直径 d 和波长 λ , 输出层节点包含模式种类 (mode)、有效折射率 (n_{eff}) 及模式对应的色散值 (D)。

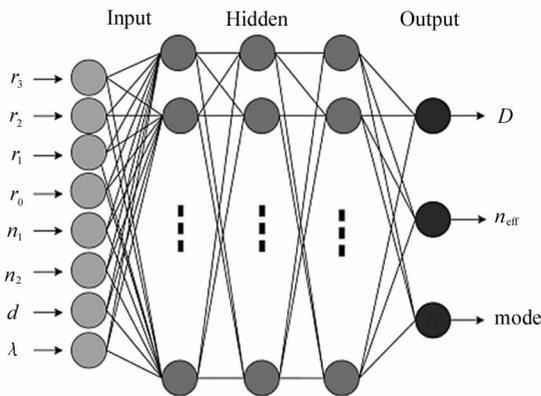


图 2 神经网络模型示意图

Fig. 2 Neural network model

对于输入层, 假设输入向量为 $X \in R^{n \times d}$, 其批量大小为 n , 输入个数为 d 。隐藏层神经元个数设为 h , 隐藏层的输出为 $H \in R^{n \times h}$, 由于隐藏层与输出层是全连接, 可以将隐藏层的权重参数和偏差参数分别设为 $W_h \in R^{d \times h}$ 和 $b_h \in R^{1 \times h}$, 输出层的权重和偏差参数分别为 $W_o \in R^{h \times q}$ 和 $b_o \in R^{1 \times q}$, 则计算其输出层的输出 M 为:

$$H = \phi(XW_h + b_h), \tag{1}$$

$$M = HW_m + b_m, \tag{2}$$

式中, ϕ 表示激活函数, 本文使用的是 ReLU 激活函数, 该函数定义为: $\text{ReLU}(x) = \max(x, 0)$, 相比于其他的激活函数, 例如 Sigmoid 函数和 Tanh 等函数, ReLU 函数有更高效率的梯度下降及反向传播, 从而在一定程度上解决了梯度爆炸和消失等问题, 并且简化了计算的过程, 不受指数函数影响及活跃度的分散性, 使网络具有较低的计算成本。

接下来本文使用 Adam 优化器用于在训练过程中优化权重。作为随机梯度下降 (stochastic gradient descent, SGD) 优化器的扩展, Adam 优化器能够代替传统随机梯度下降法以更快的速度更新神经网络的权重, 计算效率高, 需要内存小, 超参数的调整较少, 适用于非固定目标。Adam 算法使用了动量变量 v_t 和 RMSProp 算法中小批量随机梯度按元素平方的指数加权移动平均变量 s_t , 并在时间步 0 将它们中每个元素初始化为 0, 时间步 t 的动量变量 v_t 即小批量随机梯度 g_t 的指数加权移动平均如下:

$$v_t \leftarrow \beta v_{t-1} + (1 - \beta) g_t. \tag{3}$$

随后给定超参数 $0 \leq \beta_2 v_{t-1} + (1 - \beta_1) g_t$, 将元素平方后的项 $g_t \odot g_t$ 做指数加权移动平均得到 s_t 如下:

$$s_t \leftarrow \beta_2 s_{t-1} + (1 - \beta_2) g_t \odot g_t. \tag{4}$$

接着对变量 v_t 和 s_t 作修正偏差为:

$$\bar{v}_t \leftarrow \frac{v_t}{1 - \beta_1}, \tag{5}$$

$$\bar{s}_t \leftarrow \frac{s_t}{1 - \beta_2}. \tag{6}$$

然后, Adam 算法使用以上 \bar{v}_t 和 \bar{s}_t , 重新调整每个元素的学习率:

$$\bar{g}_t \leftarrow \frac{\bar{\eta} v_t}{\sqrt{\bar{s}_t} + \epsilon}, \tag{7}$$

式中, η 是学习率, ϵ 是常数。最后, 使用 \bar{g}_t 迭代自变量:

$$x_t \leftarrow x_{t-1} - \bar{g}_t. \tag{8}$$

神经网络模型在每次迭代后都会根据验证数据集中的输入变量预测输出结果,然后计算预测输出结果与实际结果之间的均方误差值(mean square error, MSE),并根据误差值通过反向传播更新隐藏层的权重,直至 MSE 收敛至可接受范围时,结束训练。

4 训练与预测

本文通过有限元软件计算得到了光纤色散数据集共 741 组,其中 701 组作为训练验证数据集,40 组作为测试数据集。在 701 组训练验证数据集中,随机选取 90% 的数据样本作为训练数据集,用于训练神经网络模型,10% 的数据样本作为验证数据集,用于调整神经网络模型参数并提供无偏评估。40 组测试数据集分为两组,分别是 test1 和 test2,用于评估训练完成后模型的最终性能。

实验数据的处理和神经网络模型的搭建通过 PyTorch 框架完成。为了得到理想的神经网络模型,本文首先通过实验确定隐藏层层数和节点数,训练模型的 epoch 值可以根据实际结果调整。为了避免过拟合,当 MSE 值下降至可接受范围时,模型训练结束。

4.1 调整隐藏层层数

隐藏层位于输入层和输出层之间,多层隐藏层对输入特征进行多层次抽象,将数据线性划分为不同数据。为了获取较好的线性划分效果,本文分别测试了不同隐藏层层数的神经网络模型,并做了以下对比。

首先将隐藏层层数设为两层,每层包含 150 个神经元,epochs 设为 7 500。两层隐藏层神经网络训

练实验结果如图 3 所示。由图 3(a)得出,训练、验证和测试数据集的 MSE 值分别为 0.001 71、0.005 87 和 0.000 174,从图 3(b)中可以看出,存在较多的点偏离 $y=x$ 这条直线,实验结果不是很理想。

在其他参数保持不变的情况下,将隐藏层层数设为 3 层,每层包含 150 个神经元,epochs 设为 7 500。3 层隐藏层神经网络训练结果如图 4 所示。图 4(a)对于训练、验证和测试数据集的 MSE 值分别为 0.000 452、0.000 487 和 0.000 496。从图 4(b)中可以得出,与两层隐藏层的训练结果相比,当隐藏层层数为 3 层的时候,仅有较少的点偏离 $y=x$ 这条直线,并且训练和验证的 MSE 值下降了一个数量级。

本文进一步将隐藏层的层数设为 4 层,每层包含 150 个神经元,epoch 设为 7 500。对于训练、验证和测试数据集的 MSE 值分别为 0.000 8、0.001 426 和 0.001 088,实验结果如图 5(a)所示。从图 5(b)可以明显得出,相对于 3 层隐藏层神经网络模型来说,4 层隐藏层的实验结果较为不理想,存在较多的点偏离 $y=x$ 直线,并且 MSE 值也更大。

最后,本文将隐藏层层数设为 5 层,每层包含 150 个神经元,迭代周期设为 7 500。5 层隐藏层神经网络训练结果如图 6 所示。图 6(a)对于训练、验证和测试数据集的 MSE 值分别为 0.000 544、0.000 483 和 0.000 211。相对更好的实验结果如图 6 (b)所示。

综合以上实验结果,并考虑网络复杂性与运算效率,当隐藏层层数为 3 层时,训练和验证数据集的 MSE 值较小,且偏离 $y=x$ 直线较远的点最少,实验效果较好,因此确定隐藏层层数为 3 层。

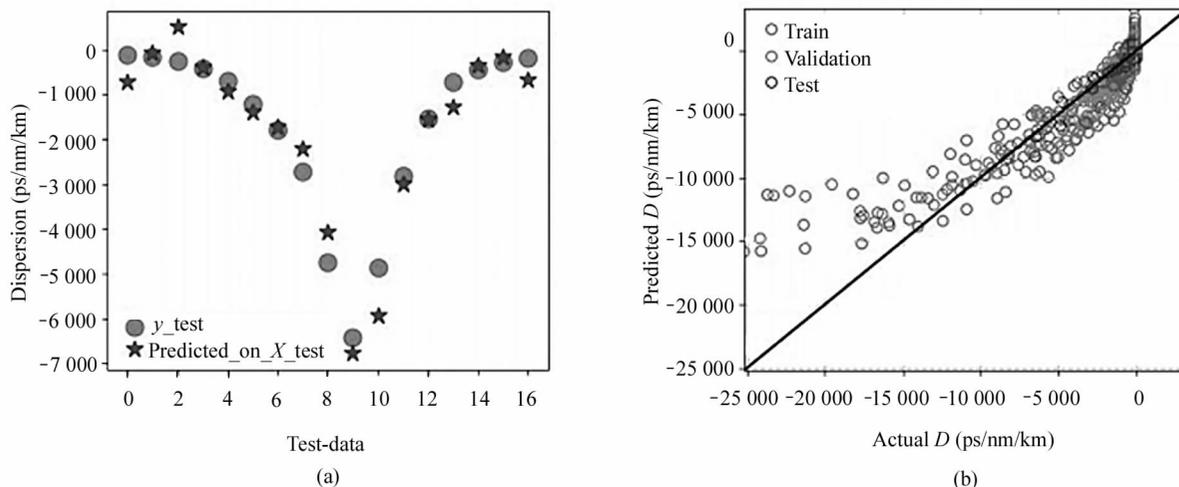


图 3 两层隐藏层神经网络训练结果

Fig. 3 Training results of neural network model with two hidden layers

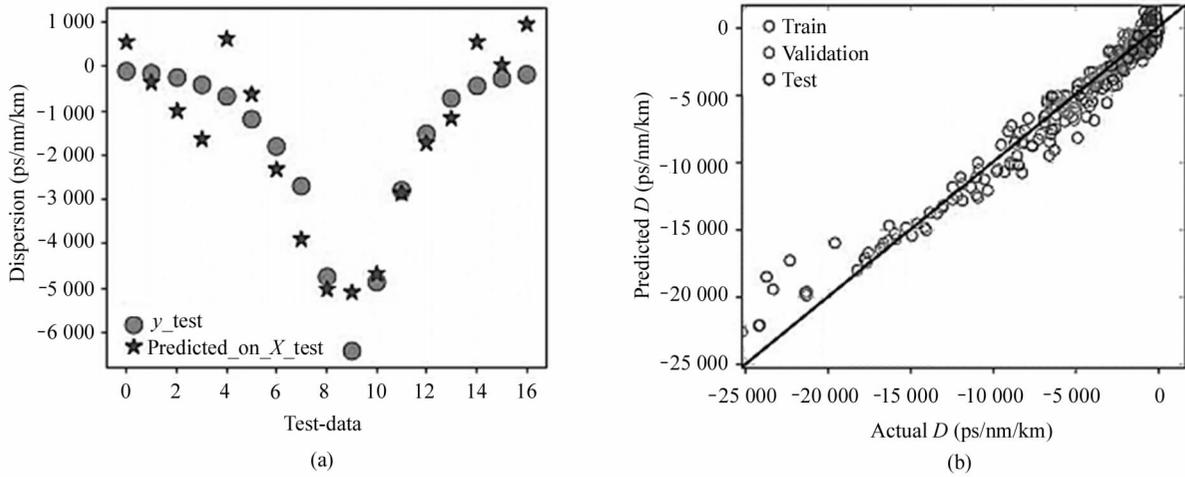


图 4 3层隐藏层神经网络训练结果

Fig. 4 Training resultsof neural network model with three hiddenlayers

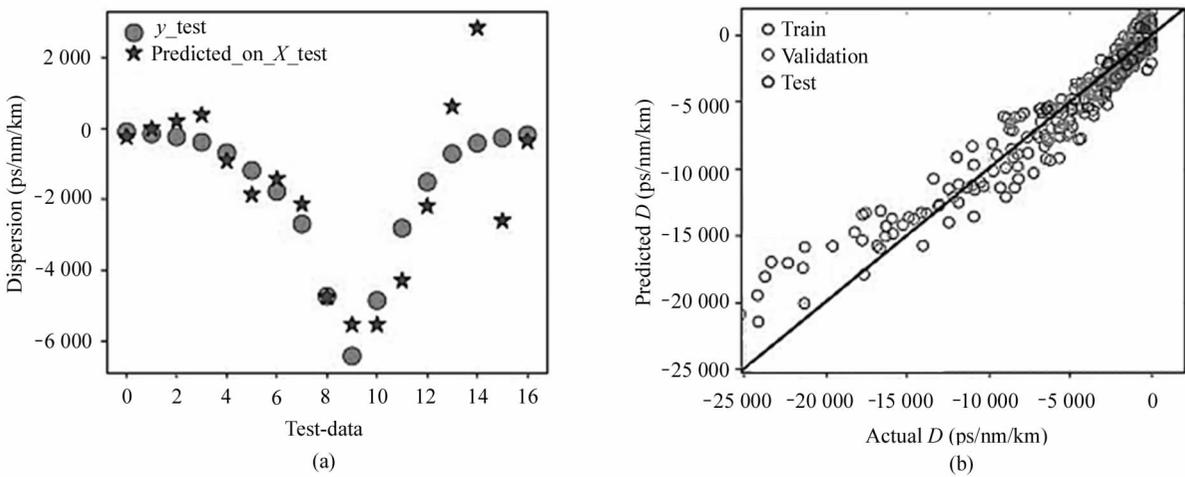


图 5 4层隐藏层神经网络训练结果

Fig. 5 Trainingresults of neural network model with four hidden layers

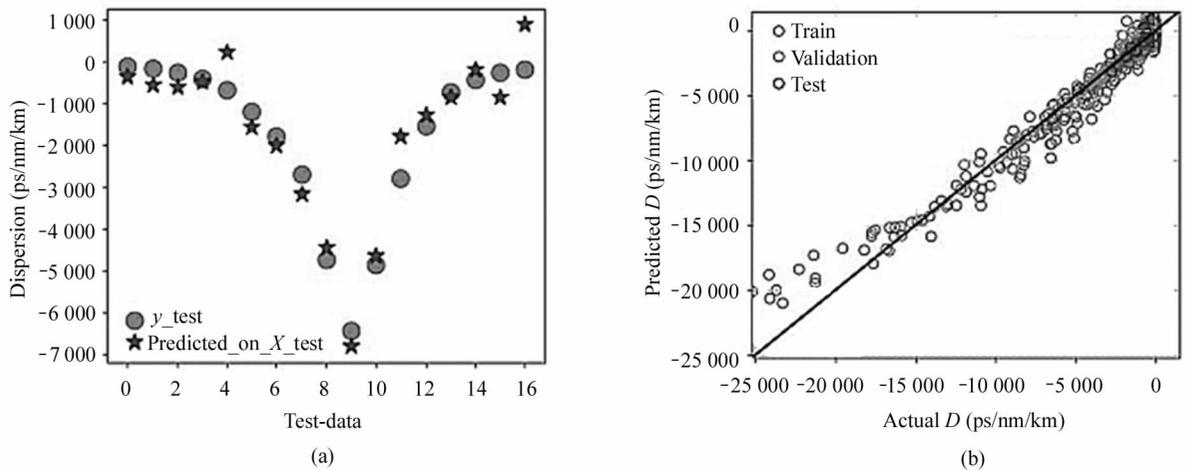


图 6 5层隐藏层神经网络训练结果

Fig. 6 Training resultsof neural networkmodel with fivehidden layers

4.2 调整隐藏层神经元个数

确定隐藏层层数之后,为了探究隐藏层节点数对模型的影响,在上节的基础上,首先将第 1 层和第 2 层隐藏层节点个数固定为 200 和 250,然后将第 3 层隐藏层节点数分别设置为 100、75 和 50 进行测试,不同第 3 隐藏层节点数训练效果如图 7 所示,五角星代表预测值,圆形代表真实值。

从图 7 散点分布可知,当第 3 层隐藏层节点数为

75 时,实验结果更为准确,五角星预测值与圆形真实值更加接近。随后我们将第 1 层和第 2 层隐藏层节点个数固定为 175 和 250,将第 3 层隐藏层节点分别设置为 100、75 和 50 再次进行测试,不同第 3 隐藏层节点数训练效果如图 8 所示。

从图 8 可以得出,当 3 层隐藏层节点数分别为 175、250 和 75 时,预测值更加接近于真实值,因此选择 175、250 和 75 分别作为 3 层隐藏层节点个数。

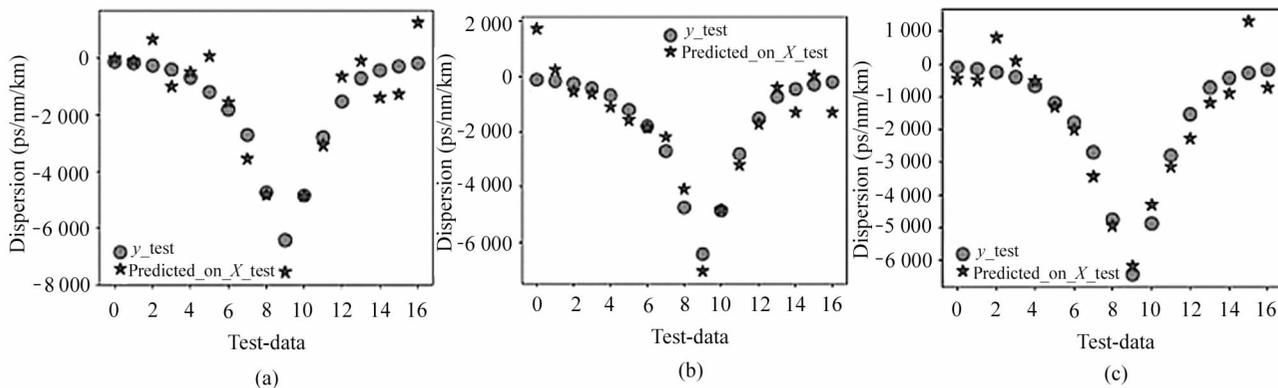


图 7 不同第 3 隐藏层节点数训练效果:(a) 节点数为 100; (b) 节点数为 75; (c) 节点数为 50

Fig. 7 Training resultsof neural networkmodels with differentnumbers of hidden layers nodes:

(a) 100 nodes; (b) 75 nodes; (c) 50 nodes

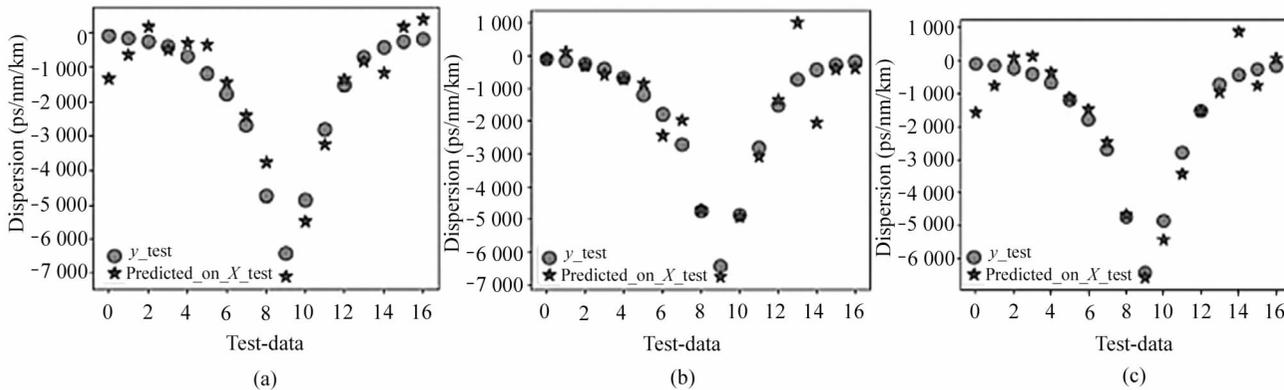


图 8 不同第 3 隐藏层节点数训练效果:(a) 节点数为 100; (b) 节点数为 75; (c) 节点数为 50

Fig. 8 Training resultsof neural networkmodels with differentnumbers of hidden layers nodes:

(a) 100 nodes; (b) 75 nodes; (c) 50 nodes

4.3 测试结果

接下来分别对不同迭代周期进行测试。首先将迭代周期设置为 8 000,使用 test1 作为测试集,实验结果如图 9 所示。

图 9(a)给出的是训练集和验证集之间的 MSE (MSE 给出估计值和真实值之间的均方误差),当 MSE 值较小时,预测值更接近真实值。从图中曲线可以得出,训练数据集的均方误差随着时间的推移而减小。图 9(b)和图 9(c)分别是训练集和验证集的

预测值分布,图 9(d)为色散的预测分布,test1 的 MSE 值为 0.000 403。

接下来本文使用 test2 作为测试集,实验结果如图 10 所示。从图 10(d)显示的预测结果来分析,较多的色散预测值与真实值有一定的偏差,计算得到 test2 的 MSE 值为 0.001 125。

接下来设置迭代周期为 7 500 次,此时神经网络模型对于训练和验证数据集的损失分别降至 0.000 5 和 0.000 6,训练模型后保存模型参数,输入

训练过程中没有使用过的测试数据用于测试模型的性能,对于 test1 实验结果如图 11 所示。

如图 11 所示,色散预测结果与真实值吻合度很高,仅有几个点的数据偏离原数据的幅度较大,计算出的 MSE 为 0.000 315。接下来采用 test2 对该模

型进行预测,实验结果如图 12 所示。可以得出,色散预测结果与 test2 中色散真实值吻合度也很高,计算出的 MSE 为 0.000 620 1。实验结果表明,该训练好的神经网络模型能够准确地完成对光纤结构的色散数据的预测工作。

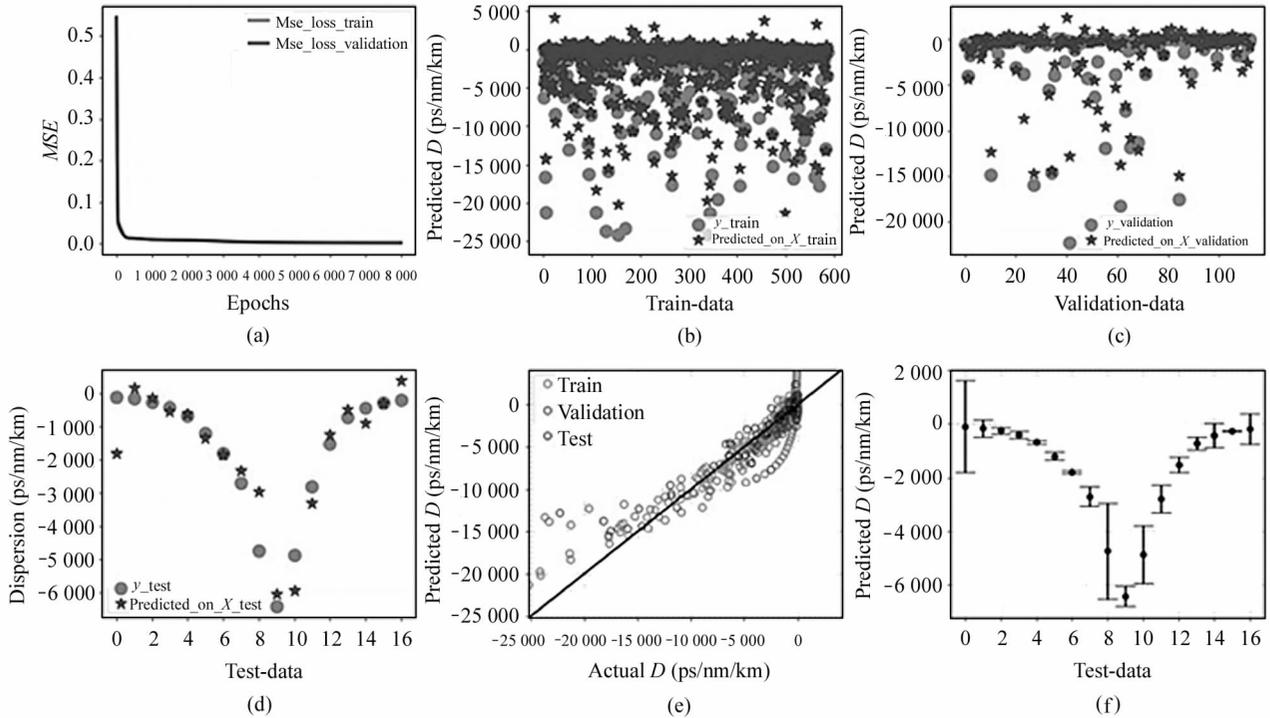


图 9 迭代周期为 8000 时 test1 实验结果

Fig. 9 Test1 experiment results of neural network model with 8000 epochs of training iterations

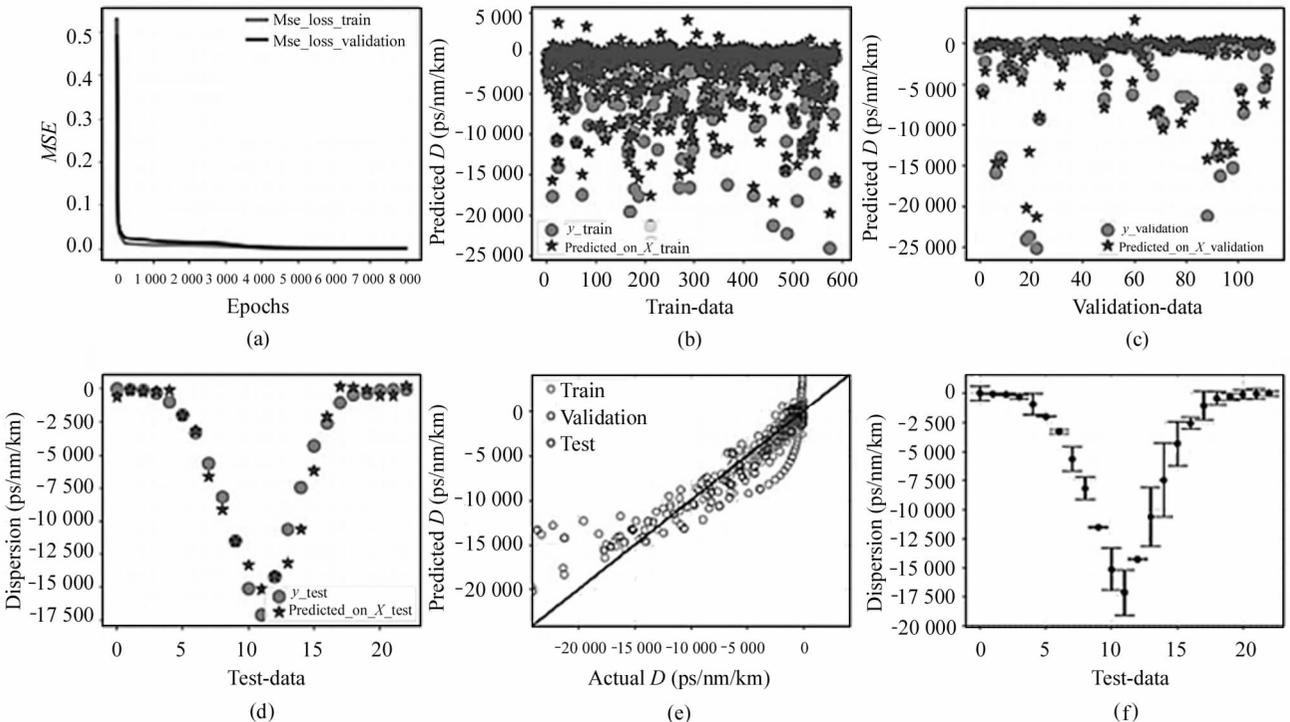


图 10 迭代周期为 8000 时 test2 实验结果

Fig. 10 Test2 experiment results of neural network model with 8000 epochs of training iterations

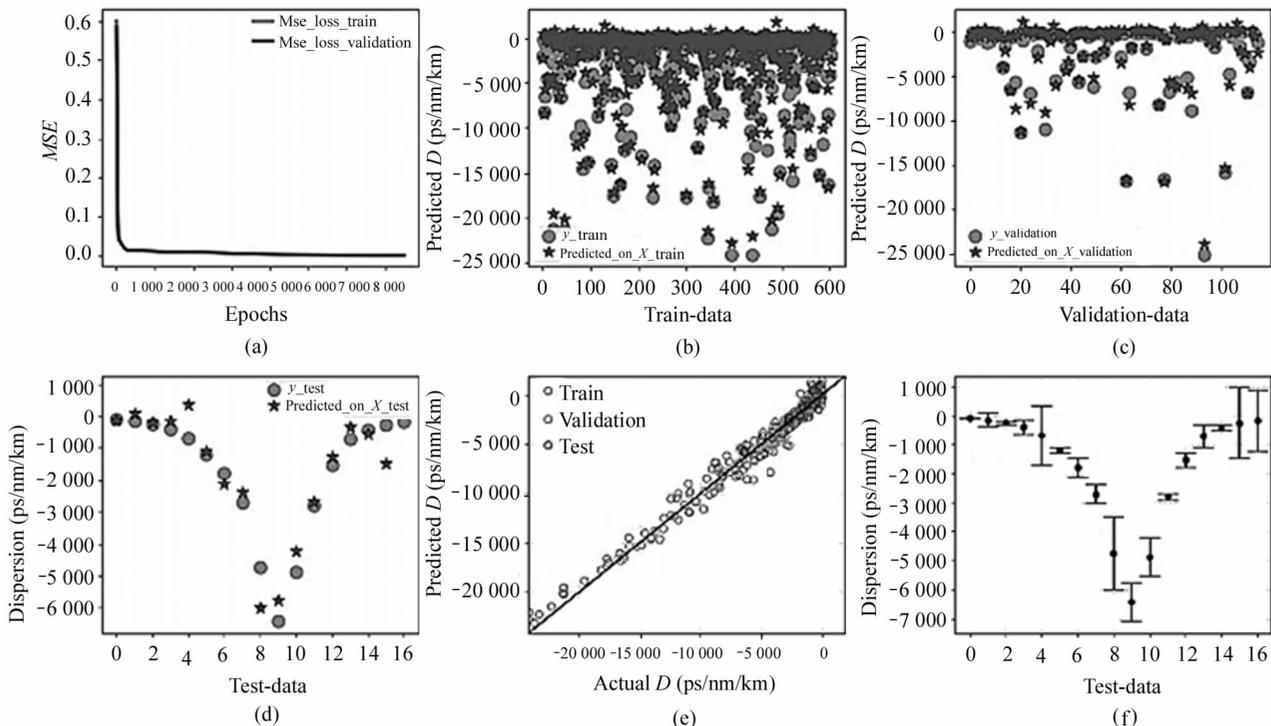


图 11 迭代周期为 7500 时 test1 实验结果

Fig. 11 Test1experiment results of neural network model with 7500 epochs of training iterations

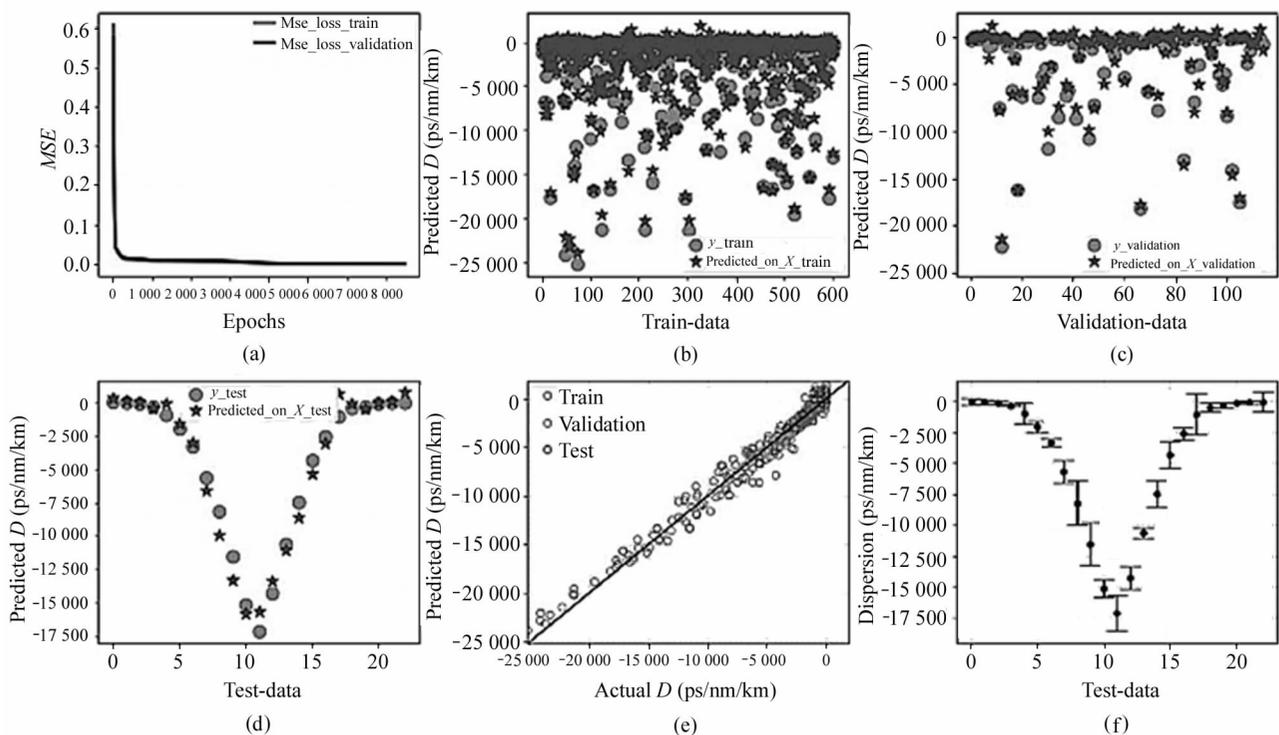


图 12 迭代周期为 7500 时 test2 实验结果

Fig. 12 Test2 experiment resultsof neural networkmodel with 7500 epochs of training iterations

5 结 论

为了提高 OAM 色散补偿光纤色散调控及结构

参数优化的计算效率,本文提出了基于神经网络的光纤色散特性预测方法。首先利用有限元仿真软件计算获取了数据集,并设计搭建了神经网络模型,通

过调节神经网络的隐藏层层数、神经元个数以及超参数,得到了较为准确的色散预测网络模型。与传统光学计算方法相比,训练好的神经网络模型能够以更高的效率对不同光纤结构的有效折射率以及色散进行准确地预测,并且可以结合其他优化算法对光纤结构进行进一步的优化和改进,对新型光学器件及极限光学性能结构的研发具有重要的意义。

参考文献:

- [1] WILLNER A E, Huang H, Yan H, et al. Optical communications using orbital angular momentum beams [J]. *Advances in Optics and Photonics*, 2015, 7(1): 66-106.
- [2] NEJAD R M, ALLAHVERDYAN K, VAITY P, et al. Mode division multiplexing using orbital angular momentum modes over 1.4 km ring core fiber[J]. *Journal of Lightwave Technology*, 2016, 34(18): 4252-4258.
- [3] ZHU L, WANG A, CHEN S, et al. Orbital angular momentum mode multiplexed transmission in heterogeneous few-mode and multi-mode fiber network. *Optics Letters*, 2018, 43(8): 1894-1897.
- [4] ZHU G, HU Z, WU X, et al. Scalable mode division multiplexed transmission over a 10 km ring-core fiber using high-order orbital angular momentum modes. *Optics Express*, 2018, 26(2): 594-604.
- [5] INGERSLEV K, GREGG P, GALILI M, et al. 12 mode, WDM, MIMO-free orbital angular momentum transmission. *Optics Express*, 2018, 26(16): 20225-20232.
- [6] WANG F, XIAO P P. Design and performance of fiber with hybrid shape air holes for OAM mode transmission[J]. *Journal of Optoelectronics · Laser*, 2020, 31(3): 254-261.
王霏,肖平平.具有混合形状空气孔的OAM传输光纤设计研究[J].*光电子·激光*, 2020, 31(3): 254-261.
- [7] HUANG W, QIN H B, XIONG Y, et al. Mechanism and characteristics of a tunable dispersion compensating dual-ring microstructure fiber for different orbital angular momentum modes[J]. *Journal of the Optical Society of America A*, 2021, 38(2): 229-236.
- [8] DA SILVA FERREIRA A, MALHEIROS-SILVEIRA G N, HERNANDEZ-FIGUEROA H E. Computing optical properties of photonic crystals by using multilayer perceptron and extreme learning machine[J]. *Journal of Lightwave Technology*, 2018, 36(18): 4066-4073.
- [9] CHUGH S, GULISTAN A, GHOSH S, et al. Machine learning approach for computing optical properties of a photonic crystal fiber[J]. *Optics Express*, 2019, 27(25): 36414-36425.
- [10] ZHOU Y, CHEN R, CHEN W J, et al. Optical analog computing devices designed by deep neural network[J]. *Optics Communications*, 2020, 458: 124674.
- [11] MA Z H, YU L. Parameter extraction and inverse design of semiconductor lasers based on the deep learning and particle swarm optimization method[J]. *Optics Express*, 2020, 28(15): 21971-21981.
- [12] LIU D J, TAN Y X, KHORAM E, et al. Training deep neural networks for the inverse design of nanophotonic structures[J]. *American Chemical Society Photonics*, 2018, 5(4): 1365-1369.
- [13] TAKASHI A, SUSUMU N. Optimization of photonic crystal nanocavities based on deep learning[J]. *Optics Express*, 2018, 26(25): 32704-32717.
- [14] CHUGH S, GHOSH S, GULISTAN A, et al. Machine learning regression approach to the nanophotonic waveguide analyses[J]. *Journal of Lightwave Technology*, 2019, 37(24): 6080-6089.
- [15] HE Z Q, DU J B, CHEN X Y, et al. Machine learning aided inverse design for few-mode fiber weak-coupling optimization[J]. *Optics Express*, 2020, 28(15): 21668-21681.

作者简介:

黄薇 (1988—),女,博士研究生,副教授,硕士生导师,主要从事基于机器学习与优化算法的光学结构预测与设计方面的工作。