

基于神经网络和人工蜂群算法的拉曼光纤放大器设计方案

巩稼民¹, 刘芳^{2*}, 吴艺杰², 张运生¹, 雷舒陶², 朱泽昊²

¹西安邮电大学电子工程学院, 陕西 西安 710121;

²西安邮电大学通信与信息工程学院, 陕西 西安 710121

摘要 介绍了一种将反向传播(BP)神经网络算法与人工蜂群算法相结合的方法,并用该方法对多泵浦拉曼光纤放大器的设计进行了优化。通过研究多层 BP 神经网络中的隐藏层层数和神经节点数,确定了最佳的学习模型,该模型可以精准地反映泵浦波长和泵浦功率与拉曼净增益分布间的映射关系,能代替传统求解拉曼耦合波方程的方法。同时,为了提高增益谱的平坦性,采用人工蜂群算法来优化泵浦参数,得到了最优的泵浦波长和泵浦功率。仿真结果表明,通过将训练好的 BP 神经网络模型加入到人工蜂群算法中,所研究的拉曼放大器达到了期望的增益性能,且其目标值与预测值的最大误差不超过 0.29 dB。该设计方案为拉曼光纤放大器的研究提供了新的思路和方法。

关键词 光通信; 拉曼光纤放大器; 机器学习; BP 神经网络算法; 人工蜂群算法; 拉曼增益

中图分类号 TN929.11

文献标志码 A

doi: 10.3788/AOS202141.2006002

Design of Raman Fiber Amplifier Based on Neural Network and Artificial Bee Colony Algorithm

Gong Jiamin¹, Liu Fang^{2*}, Wu Yijie², Zhang Yunsheng¹, Lei Shutao², Zhu Zehao²

¹School of Electronic Engineering, Xi'an University of Posts and Telecommunications, Xi'an, Shaanxi 710121, China;

²School of Telecommunication and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an, Shaanxi 710121, China

Abstract A method combining a back propagation (BP) neural network algorithm with the artificial bee colony algorithm is introduced, and the design of multi-pump Raman fiber amplifier is optimized by this method. The best learning model is determined by studying the numbers of hidden layers and neural nodes in the multilayer BP neural network, which can accurately reflect the mapping relationships of the pump wavelength and pump power with the distribution of Raman net gain, and can replace the traditional method for solving the Raman coupled wave equation. At the same time, in order to improve the flatness of the gain spectrum, the artificial bee colony algorithm is used to optimize the pump parameters and the optimal pump wavelength and pump power are obtained. The simulation results show that when the trained BP neural network model is added into the artificial bee colony algorithm, the desired gain performance of the studied Raman amplifier is achieved. Moreover, the maximum error between the target value and the predicted value is less than 0.29 dB. This design scheme provides a new method and idea for the study of Raman fiber amplifiers.

Key words optical communications; Raman fiber amplifier; machine learning; BP neural network algorithm; artificial bee colony algorithm; Raman gain

OCIS codes 060.2330; 190.4360; 190.5650

收稿日期: 2021-01-14; 修回日期: 2021-04-14; 录用日期: 2021-05-06

基金项目: 国家自然科学基金(61775180)、国际科技合作计划项目陕西省重点研发计划(2020KWZ-017)

通信作者: *lf15170905229@163.com

1 引言

拉曼放大技术被认为是未来多波段光通信系统中的一种有效的光信号放大解决方案^[1-2]。在密集波分复用(DWDM)系统中,由于拉曼光纤放大器(RFA)具有输出增益高、噪声指数低、响应速度快、非线性失真小等优点^[3-4],因此其在全光通信系统中发挥着重要作用。泵浦光参数选择是 RFA 设计中的一个关键问题^[5-7]。因为涉及两点边界条件的求解,所以描述泵浦光和信号光之间非线性效应的数学模型非常复杂。选择泵浦光功率和波长的传统方法是求解经典拉曼耦合波方程,但拉曼耦合波方程的解析解极其复杂,不能直接计算。常用的数值方法如龙格-库塔法^[8]、打靶法^[9]和平均功率法^[10]被用于求解该方程,但求解过程复杂且耗时,甚至在某些情况下,方程的解不会收敛。2018 年,Chen 等^[11]将机器学习的方法与拉曼放大器的优化设计相结合,将泵浦光的波长和功率作为训练输入,净增益作为训练目标,利用极限学习机(ELM)的学习方法训练了一种有效的单隐层前馈网络模型。与传统求解方法相比,该方法大大缩短了计算时间。2018 年,Zibar 等^[12]构建了三层神经网络,将净增益作为训练输入,泵浦光波长和功率作为训练目标,利用神经网络的学习方法训练了一种多隐层前馈网络模型,

但精度较低,误差高达 0.6 dB。2020 年,Zibar 等^[13]又采用机器学习中逆系统设计方法设计了一种适用于 C 波段和 C+L 波段的两段多隐层前馈神经网络,最大误差的平均值分别为 0.35 dB 和 0.46 dB。由此可见,前人仅对一到三层的神经网络模型进行了研究,所设计的 RFA 网络模型的计算结果不够精确,误差较大。

因此,本文提出了一种基于机器学习^[14]的新方法,通过研究多层反向传播(BP)神经网络^[15]中的隐藏层层数和隐藏层包含的神经节点数来确定最佳学习模型。一旦模型被学习,给定任意一组泵浦光参数,通过泵浦光参数与净增益分布之间的多层神经网络映射关系,该模型可以直接确定输出的净增益值,从而代替了传统的求解拉曼耦合波方程的方法。同时,为了获得较高的平坦度,利用人工蜂群算法来优化泵浦光参数,得到了最优的泵浦光波长和功率值。

2 理论模型

2.1 拉曼光纤放大器模型

RFA 的放大原理是基于受激拉曼散射效应的。当泵浦光和信号光注入到光纤中且同时传输时,由于光纤的非线性效应,强泵浦光会向部分弱信号光传递能量,因此信号光在此时会被放大^[16-17]。简化后的拉曼耦合波微分方程^[18-19]为

$$\pm \frac{dP_j(z)}{dz} = \sum_{v_i > v_j} \frac{g_R(v_i - v_j)}{K_{\text{eff}} A_{\text{eff}}} P_i(z) P_j(z) - \sum_{v_k < v_j} \frac{v_j}{v_k} \frac{g_R(v_j - v_k)}{K_{\text{eff}} A_{\text{eff}}} P_i(z) P_k(z) - \alpha(v_j) P_j(z) + \gamma(v_j) P_j(z) + 2h v_i \cdot \sum_{v_i > v_j} \frac{g_R(v_i - v_j)}{K_{\text{eff}} A_{\text{eff}}} P_j(z) \cdot \left\{ 1 + \frac{1}{\exp[h(v_i - v_j)/KT] - 1} \right\} \cdot \Delta v, \quad (1)$$

式中: $P_k(z)$ 、 $P_i(z)$ 、 $P_j(z)$ 分别表示第 k 、 i 、 j 路信道中的光信号所对应的功率; v_i 、 v_j 、 v_k 分别为第 i 、 j 、 k 路信道中的光信号所对应的频率; Δv 为不同信道的频移差; $\alpha(v_j)$ 为光信号频率在 v_j 时所对应的光纤损耗系数; K_{eff} 为偏振相关因子; A_{eff} 为光纤有效横截面积; $\gamma(v_j)$ 为瑞利散射系数; $g_R(v_i - v_j)$ 为 i 、 j 两路信号光间的拉曼增益系数; $g_R(v_j - v_k)$ 为 j 、 k 两路信号光间的拉曼增益系数; K 和 h 分别为波尔兹曼常量和普朗克常量; $\{\exp[h(v_i - v_j)/KT] - 1\}^{-1}$ 为玻色-爱因斯坦因子; T 为光纤绝对温度。因为在本文中多泵浦的注入方式均设置为前向,所以(1)式中等号左侧符号取正。

在(1)式中,将等式两边同时从 $z=0$ 积分到

$z=L$,通过数值求解可得到 $P_j(L)$ 。RFA 的净增益可定义为

$$G = 10 \lg \frac{P_j(L)}{P_j(0)}, \quad (2)$$

式中: $P_j(0)$ 、 $P_j(L)$ 分别为第 j 路信号光的初始输入光功率和传输 L 后的光功率。多泵浦拉曼放大器原理图如图 1 所示。

由图 1 可知,放大器的输入端是信号光和泵浦光, $\lambda_1 \sim \lambda_{51}$ 是信号光的波长,范围是 1520 ~ 1570 nm, λ_{p1} 、 λ_{p2} 和 λ_{p3} 是泵浦光波长。在放大过程中,51 路信号光和三个泵浦光一起进入到光纤中传输,在传输过程中受到受激拉曼散射效应的影响,信号光被放大。在滤除泵浦光后,剩余的 51 路信号光进入到波分复用系统的接收机中。

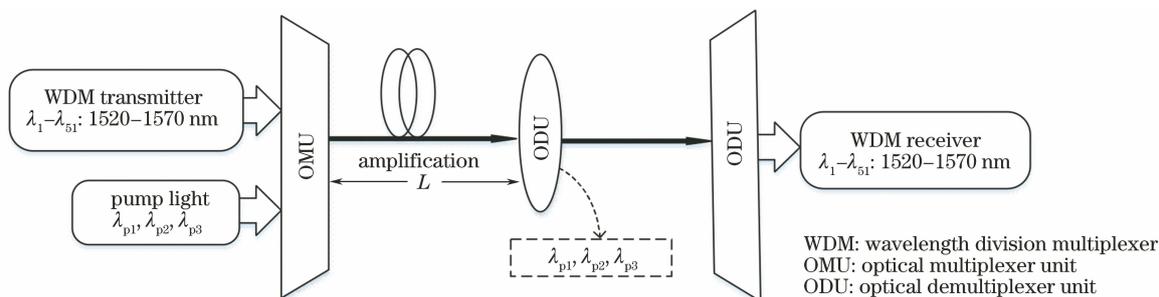


图 1 多泵浦拉曼放大器原理图

Fig. 1 Schematic diagram of multi-pump Raman amplifier

2.2 神经网络算法

利用 BP 神经网络模型来求解 RFA 的净增益, 在指定的系统参数下, 求解过程可以看作是解决多输入多输出的回归问题, 此模型的输入输出关系可表示为

$$G = \Theta(\lambda_p, P_p), \quad (3)$$

式中: $\lambda_p \in \{\lambda_{p1}, \lambda_{p2}, \dots, \lambda_{pn}\}$ 是泵浦光波长; $P_p \in \{P_{p1}, P_{p2}, \dots, P_{pn}\}$ 是泵浦光功率; $G \in \{G_1, G_2, \dots, G_m\}$ 是信号光净增益, 其中 n 和 m 分别是泵浦光个数和信号光个数。 Θ 函数是要构造的 BP 神经网络模型, 在映射关系已知的条件下, 该模型就可以快速计算增益, 而不需要对拉曼耦合方程进行积分。此时, 求解过程被转换为解决多输入多输出的回归问题。为了研究一种快速、准确的方法, 采用 BP 神经网络来构建 RFA 模型。

BP 神经网络是一种多层前馈网络, 本质是梯度下降法。不断改变权值和阈值可使得该网络的均方误差最小^[20-21]。在 BP 神经网络模型中, 将泵浦光的波长和功率作为输入, 51 路信号光的拉曼增益值作为输出, 中间的隐藏层视为映射函数, 隐藏层中各

层的神经元节点均为映射函数的权值参数。BP 神经网络的计算过程包括正向计算过程和反向计算过程。在正向计算过程中, 通过逐层处理, 输入模式从输入层经隐藏层转向输出层, 每一层神经元的状态只影响下一层神经元的状态。如果在输出层不能得到期望的输出, 则转入反向计算, 将误差信号沿原来的连接通路返回。在每次训练中自动调整各神经元的权值, 得到最小的误差信号。最终, 该映射函数能够根据输入值精确预测出对应的输出值, 即拉曼增益值。

BP 神经网络模型的具体训练过程分为三步: 1) 训练模型; 2) 测试模型的预测能力; 3) 检测模型的性能。该模型如图 2 所示。本文主要讨论模型中隐藏层的层数及隐藏层内包含的神经节点数对输出净增益的影响, 隐藏层和神经节点分别如图 2 中 C_x 和 R_y 所示, 其中 $x \in \{1, 2, 3, 4, 5\}$, $y \in \{1, 2, \dots, 100\}$, 可建立 500 个模型。同时, 采集了 3000 组数据作为训练集, 模型基于该训练集建立了输入与目标输出间的映射关系, 从而得到一个准确、快速的 BP 网络模型。多泵浦拉曼放大器将泵浦光波长和功率作为

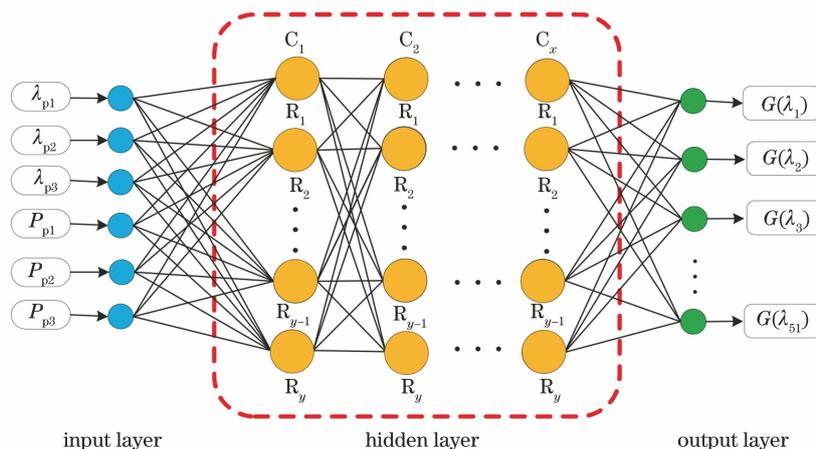


图 2 拉曼放大器的 BP 神经网络模型

Fig. 2 BP neural network model of Raman amplifier

训练输入,净增益作为训练目标。随机设置用于生成净增益谱的泵浦光参数以收集每组输入输出的训练样本。设 $Q = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_N, Y_N)\}$ 为包含 N 组样本的训练集,输入和输出分别为 $X_i(\lambda_{pm}, P_{pm})$ 和 $Y_i = G_m$ 。

2.3 人工蜂群算法

人工蜂群算法是基于蜜蜂采蜜行为的一种种群智能优化算法^[22-24],整个寻优过程的具体步骤如下。

1) 在一个搜索空间中,设蜜源总数为 W , D 为优化问题的维度,则各蜜源第 g 次迭代后的位置为 $X_s^{(g)} = [x_{s,1}^{(g)}, x_{s,2}^{(g)}, \dots, x_{s,D}^{(g)}]$, $s = 1, 2, \dots, W$, 蜜源的适应度函数用 $\text{fit}[X_s^{(g)}]$ 表示。

2) 每一个引领蜂对应一个蜜源,并在其周围搜索得到一个新的蜜源 $v_{i_1 j_1}$, 计算其适应度值:

$$v_{i_1 j_1} = x_{i_1 j_1} + \phi(x_{i_1 j_1} - x_{k_1 j_1}), \quad (4)$$

式中: $x_{i_1 j_1}$ 、 $x_{k_1 j_1}$ 分别为第 i_1 、 k_1 个蜜源的位置; $i_1 = 1, 2, \dots, W$; $k_1 \in \{1, 2, \dots, W\}$ 且 $k_1 \neq i_1$; $j_1 \in \{1, 2, \dots, D\}$; $\phi \in (0, 1)$ 。其余所有变量都将从旧蜜源中继承。比较两个蜜源的适应度函数值,选用适应度值更大的蜜源。

3) 跟随蜂接收到引领蜂的信息后,随机选取需要更新的蜜源,每个蜜源被选择的概率为

$$p_{i_1} = \frac{\text{fit}(X_{i_1})}{\sum_{i_1=1}^W \text{fit}(X_{i_1})} \quad (5)$$

r 是 $[0, 1]$ 中随机选取的数,当 $p_{i_1} \geq r$ 时,跟随蜂在其对应的蜜源周围按(5)式产生新的蜜源,比较两者的适应度函数值,选用适应度值更大的蜜源。

4) 在所有的引领蜂和跟随蜂完成搜索后,若没有获得更好的蜜源,则与原蜜源对应的引领蜂就要转化为侦查蜂,利用(4)式再随机产生一个新的蜜源。

5) 重复步骤 2)~ 4),直到满足终止条件,输出最好的蜜源位置。

3 仿真结果分析

3.1 参数设置

在仿真实验中,将掺 GeO_2 的光子晶体光纤作为传输光纤^[25],利用三个前向泵浦光分别对 50 nm 带宽内的 51 个信号光进行放大。信号光、泵浦光以及其他仿真参数如表 1 所示。

将采集的 3000 组输入输出数据集作为训练样本,其中输入部分数据是在指定范围内随机产生的;

表 1 RFA 的仿真参数

Table 1 Simulation parameters of RFA

Parameter	Value
Wavelength range of signal light /nm	1520—1570
Signal optical power /mW	0.01
Signal light interval /nm	1
Pump wavelength range /nm	1410—1520
Pump power range /mW	0—500
Signal optical loss coefficient /($\text{dB} \cdot \text{km}^{-1}$)	0.75
Pump loss coefficient /($\text{dB} \cdot \text{km}^{-1}$)	0.9
Fiber length /km	0.12
Effective area of optical fiber / μm^2	15.5
Absolute temperature of optical fiber /K	300
Rayleigh scattering coefficient / m^{-1}	7×10^{-8}
Boltzmann constant /($\text{J} \cdot \text{K}^{-1}$)	1.38×10^{-23}
Planck constant /($\text{J} \cdot \text{s}$)	6.626×10^{-34}

输出部分则是利用龙格-库塔法计算出的数值,其也是仿真实验中的目标值。设置隐藏层层数的范围为 1~5,其对应的隐藏节点数范围为 1~100。在每个实验中,随机将训练数据集分成训练集、验证集和测试集,其所占比例分别为训练数据集总数据的 70%,15%和 15%。同时,采用均方误差(MSE)和 R 值来评价模型的准确度。MSE 表示输出与目标之间的平均平方差,值越小则表明仿真得到的模型越精准。 R 值则是度量预测值和目标值之间的相关性, $R=1$ 表示紧密关系, $R=0$ 表示随机关系。为了验证该方法的有效性,从三个部分进行数值研究。首先,选择 BP 神经网络模型的隐藏层层数和隐藏节点数。然后,为多泵浦 RFA 训练 BP 模型。接着,对多泵浦 RFA 的参数进行优化。最后,利用所得数据来评价该方法的可行性。

3.2 仿真结果分析

在仿真过程中,通过改变隐藏层层数和隐藏层内包含的隐藏节点数来得到不同的 BP 神经网络模型。由于隐藏层层数和隐藏节点数的变化范围分别为 1~5 和 1~100,因此可构造 500 组 BP 模型,并以 MSE 和 R 值为依据来寻找最优模型。图 3 为在不同隐藏层中,MSE 随节点数的变化。图 4 为在不同隐藏层中, R 值随节点数的变化。图 5 为 R 值大于 0.995 时的数据分布, $R=0.995$ 的平面已标出。

从图 3 中可以发现,随着隐藏层层数的增加,MSE 的数值逐渐减小并趋于平稳,这表明模型的准

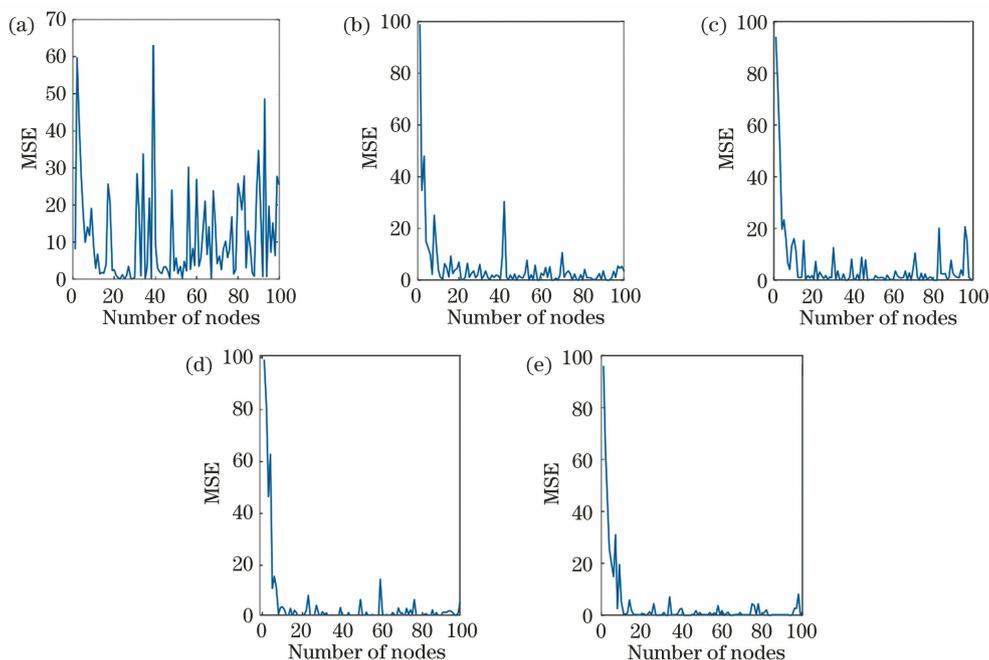


图 3 在不同隐藏层中, MSE 随节点数的变化。(a)第一隐藏层;(b)第二隐藏层;(c)第三隐藏层;(d)第四隐藏层;(e)第五隐藏层

Fig. 3 Variations of MSE with number of nodes in different hidden layers. (a) The first hidden layer; (b) the second hidden layer; (c) the third hidden layer; (d) the fourth hidden layer; (e) the fifth hidden layer

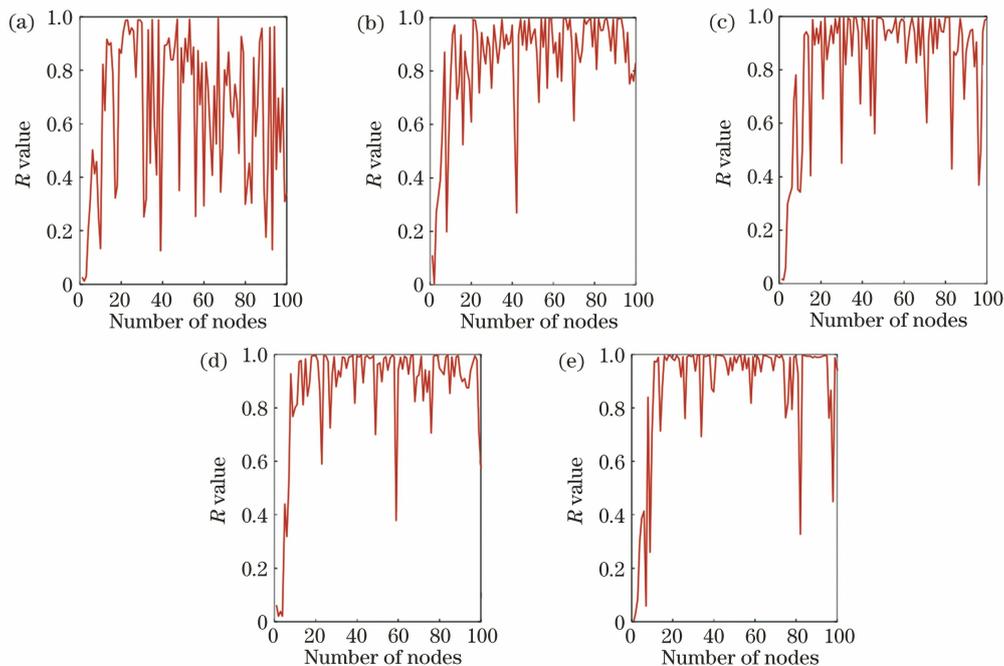


图 4 在不同隐藏层中, R 值随节点数的变化。(a)第一隐藏层;(b)第二隐藏层;(c)第三隐藏层;(d)第四隐藏层;(e)第五隐藏层

Fig. 4 Variations of R value with number of nodes in different hidden layers. (a) The first hidden layer; (b) the second hidden layer; (c) the third hidden layer; (d) the fourth hidden layer; (e) the fifth hidden layer

确性与隐藏层层数相关。对于特定的隐藏层,随着神经元个数的增加, MSE 的数值先急剧减小,之后呈锯齿状分布,这是因为 BP 神经网络算法的本质

是梯度下降法。从图 4 中可以发现,随着隐藏层层数的增加, R 值不断增大,锯齿形结构的数量减少。从图 5 中可以发现, R 值大于 0.995 的数据点在一

层隐藏层中是没有的,随着隐藏层层数的增加, R 值大于 0.995 的数据点逐渐密集且数据值变化不大。

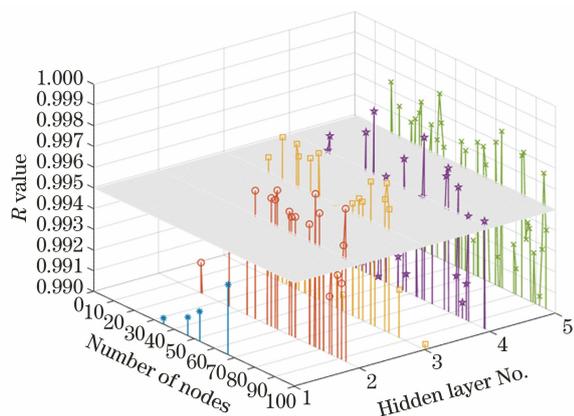


图 5 当 R 值大于 0.995 时,不同隐藏层中的数据分布
Fig. 5 Data distributions in different hidden layers when R value is greater than 0.995

同时, R 值范围在 0.95~0.995 内的数据点的数量也在明显增多。由此可见,增加 BP 模型隐藏层数可以降低网络误差,提高模型的精确度。

由图 3~5 的数据,可以得到每个隐藏层中最优模型的 MSE 和 R 值,如图 6 所示。

从图 6 中可以看出,随着隐藏层层数的增加, MSE 减小,最小值为 0.0313,而训练、验证和测试的 R 值增大,接近 R 值的极限最大值,说明含有 5 层隐藏层的 BP 模型是最优的。通过仿真数据可知,当 BP 神经网络的隐藏层个数为 5,且对应的每层的结点数为 42 时,模型的精度最高,误差最小。最优 BP 神经网络结构图如图 7 所示。

利用图 7 所示的结构对 3000 组数据集进行训练,即可得到最优 BP 模型的训练结果,如图 8 所示,图中横轴 X 表示目标值,纵轴 Y 表示模型预测值。

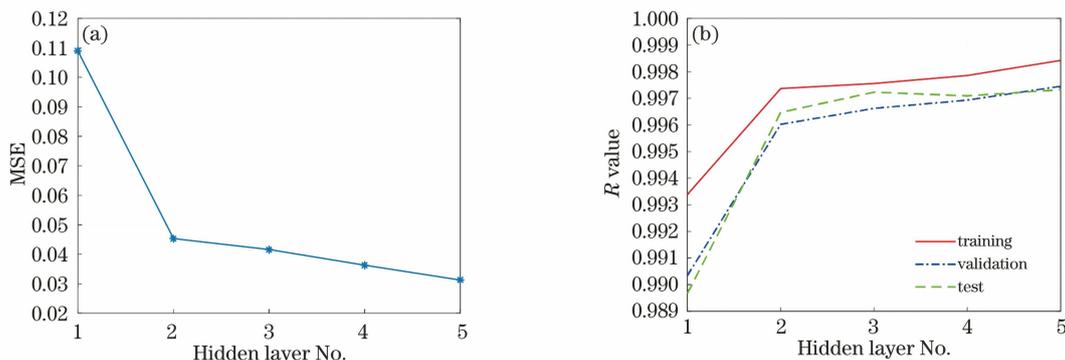


图 6 最优模型的 MSE 和 R 值。(a)MSE 随隐藏层层数的变化;(b)训练、验证和测试集的 R 值随隐藏层层数的变化
Fig. 6 MSE and R value of optimal model. (a) Variation of MSE with number of hidden layers;
(b) variation of R values of training, validation and test sets with number of hidden layers

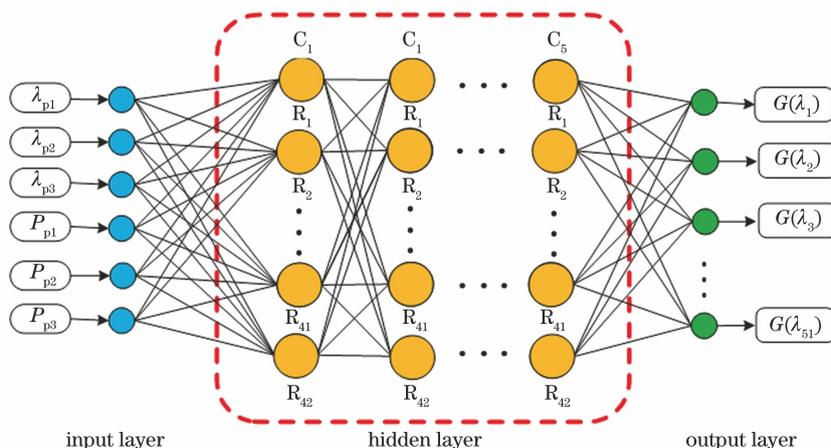


图 7 最优 BP 神经网络的结构图

Fig. 7 Structural diagram of the optimal BP neural network

从图 8 中可以发现,利用最优 BP 神经网络结构测出的训练集、验证集、测试集的 R 值分别为 0.99842、0.99745 和 0.99732。同时,3000 组数据很好地拟

合到了一条直线上,说明模型预测值 Y 与目标值 X 几乎是相等的,即拟合精度高,误差小。当训练过程完成后,接下来的任务是找到泵浦光波长和泵浦光

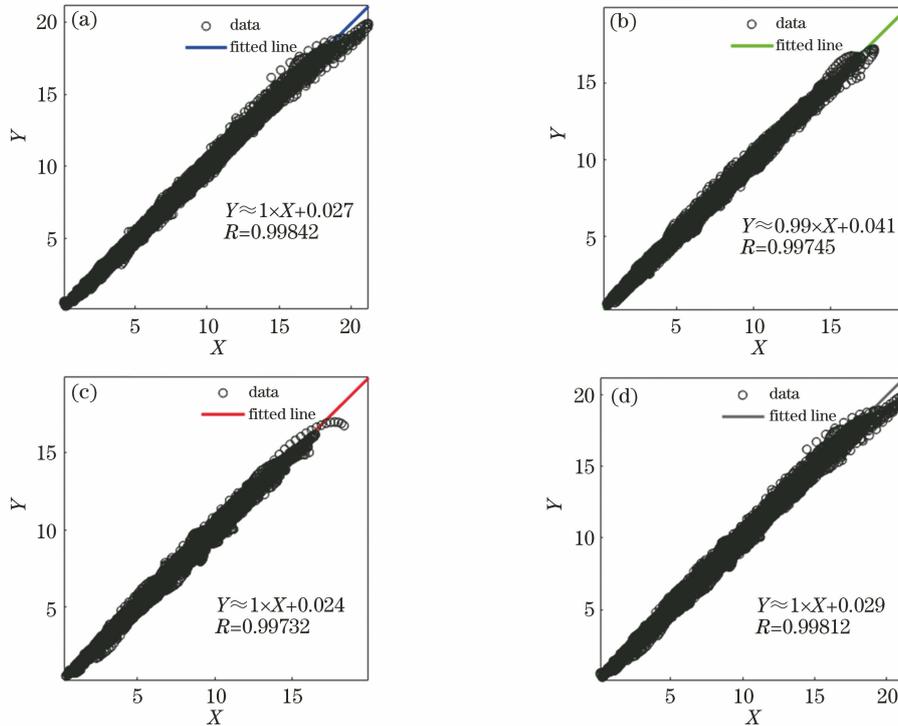


图 8 在不同数据集中,最优 BP 模型的训练结果。(a)训练集;(b)验证集;(c)测试集;(d)完整数据集
 Fig. 8 Training results of the optimal BP model in different datasets. (a) Training set; (b) validation set;
 (c) test set; (d) complete dataset

功率的最佳组合。将训练良好的 BP 模型加入到人工蜂群算法的优化过程中。利用所提方法列举出了目标增益为 2.25 dB~7.03 dB 的例子。

优化后的泵浦参数、增益、最大增益与最小增益间的差值 ΔG 及净增益与目标增益间的误差如表 2 所示。

表 2 优化后的泵浦光参数、增益、 ΔG 及净增益与目标增益间的误差

Table 2 Optimized pump light parameters, gain, ΔG and error between net gain and target gain

Pump light parameter		Gain /dB	ΔG /dB	Error /dB
λ_p /nm	P_p /W			
1415.45,1454.62,1503.72	0.1000,0.0658,0.1232	2.25	0.1486	0.2566
1419.31,1455.41,1505.02	0.1572,0.0996,0.1825	3.47	0.1771	0.2279
1409.29,1450.75,1502.72	0.3548,0.1014,0.2033	4.27	0.1515	0.2894
1416.09,1450.69,1502.02	0.2950,0.1375,0.2786	5.21	0.1652	0.1489
1418.64,1449.26,1498.75	0.2792,0.1802,0.3056	6.19	0.2044	0.2134
1420.83,1448.79,1496.94	0.2810,0.2154,0.3237	7.03	0.2344	0.2872

为了评估预测的增益性能,以三泵浦 RFA 为例,在相同的中央处理器(CPU)环境下进行了对比仿真实验。将四阶龙格-库塔法计算出的值作为目标增益,将最佳 BP 模型预测的值作为预测增益。将所提出的优化 BP 模型与传统的求解拉曼耦合波方程的方法进行比较,从表 2 中可以看出,预测的净增益与目标增益非常接近,最大误差不超过 0.29 dB。

4 结 论

提出了一种基于机器学习的多泵浦拉曼光纤放

大器优化方法。利用机器学习中的 BP 神经网络技术为净增益的计算提供了一种快速、直接和精确的方法,而不需要求解复杂的拉曼耦合方程。在满足增益及平坦度要求的前提下,将训练后的 BP 模型加入到人工蜂群算法中,以进一步提高整体优化效率。仿真结果表明,在加入三个泵浦光的情况下,利用最优 BP 模型,所研究的拉曼放大器达到了期望的增益性能,其目标值与预测值的最大误差不超过 0.29 dB。与传统方法相比,该模型提高了拉曼放大的计算效率,为拉曼放大器的研究提供了新的思路

和方法。

参 考 文 献

- [1] Chang D I, Pelouch W, Perrier P, et al. 150×120 Gb/s unrepeatered transmission over 409.6 km of large effective area fiber with commercial Raman DWDM system[J]. *Optics Express*, 2014, 22(25): 31057-31062.
- [2] Chi R H, Zhou Y P, Li L Y. Research status and development analysis of multicore fiber amplifier[J]. *Laser & Optoelectronics Progress*, 2019, 56(19): 190005.
迟荣华, 周燕萍, 李立亚. 多芯光纤放大器研究现状及发展分析[J]. *激光与光电子学进展*, 2019, 56(19): 190005.
- [3] Borraccini G, Straullu S, Ferrari A, et al. Flexible and autonomous multi-band Raman amplifiers[C]//2020 IEEE Photonics Conference (IPC), September 28-October 1, 2020, Vancouver, BC, Canada. New York: IEEE Press, 2020: 1-2.
- [4] Curri V, Carena A. Merit of Raman pumping in uniform and uncompensated links supporting NyWDM transmission [J]. *Journal of Lightwave Technology*, 2016, 34(2): 554-565.
- [5] Khalaf A A M, Mustafa F M. Raman amplifier performance under new wavelength ranges [J]. *Journal of Optical Communications*, 2016, 37(1): 9-21.
- [6] Chi R H, Yuan Y, Wang F, et al. Application of Bi-directionally pumped Raman amplifier in $100 \text{ Gbit} \cdot \text{s}^{-1}$ ultra-long distance transmission system[J]. *Laser & Optoelectronics Progress*, 2019, 56(6): 060601.
迟荣华, 袁渊, 王飞, 等. 双向抽运拉曼放大器在 $100 \text{ Gbit} \cdot \text{s}^{-1}$ 超长距传输系统中的应用[J]. *激光与光电子学进展*, 2019, 56(6): 060601.
- [7] Chen J, Qiu X J, Yin C Y, et al. Efficient design of gain-flattened multi-pump Raman fiber amplifiers using least squares support vector regression [J]. *Journal of Optics*, 2018, 20(2): 025702.
- [8] Feng J Q, Sun S Y. The principle and application of the fourth-order Runge-Kutta method [J]. *Mathematics Learning and Research*, 2017(17): 3-5.
冯建强, 孙诗一. 四阶龙格-库塔法的原理及其应用[J]. *数学学习与研究*, 2017(17): 3-5.
- [9] An L. Shooting method in the application of ordinary difference equations boundary value problem [J]. *Science Mosaic*, 2011(5): 247-249.
安乐. 打靶法在常微分方程边值问题中的一些应用[J]. *科技广场*, 2011(5): 247-249.
- [10] Ania-Castañón J D, Pustovskikh A A, Kobtsev S M, et al. Simple design method for gain-flattened three-pump Raman amplifiers [J]. *Optical and Quantum Electronics*, 2007, 39(3): 213-220.
- [11] Chen J, Jiang H. Optimal design of gain-flattened Raman fiber amplifiers using a hybrid approach combining randomized neural networks and differential evolution algorithm [J]. *IEEE Photonics Journal*, 2018, 10(2): 1-15.
- [12] Zibar D, Ferrari A, Curri V, et al. Machine learning-based Raman amplifier design [EB/OL]. (2018-10-31) [2021-01-10]. <https://arxiv.org/abs/1811.10381>.
- [13] Zibar D, Brusin A M R, de Moura U C, et al. Inverse system design using machine learning: the Raman amplifier case [J]. *Journal of Lightwave Technology*, 2020, 38(4): 736-753.
- [14] Morais R M. On the suitability, requisites, and challenges of machine learning [J]. *Journal of Optical Communications and Networking*, 2021, 13(1): A1-A12.
- [15] Chai Z J, Ouyang Z H, Yue J. An improved prediction model of grey BP neural network [J]. *Ordnance Industry Automation*, 2020, 39(10): 84-88, 96.
柴志君, 欧阳中辉, 岳炯. 一种改进的灰色 BP 神经网络预测模型[J]. *兵工自动化*, 2020, 39(10): 84-88, 96.
- [16] Shpolyanskiy Y A, Kozlov S A, Bepalov V G. Stimulated Raman scattering and four wave mixing with self-phase and cross-phase modulation of intense fs laser pulses[C]//Technical Digest. Summaries of Papers Presented at the Quantum Electronics and Laser Science Conference, May 23-28, 1992, Baltimore, MD, USA. New York: IEEE Press, 1992: 128.
- [17] Wen S, Chi S E. Distributed erbium-doped fiber amplifiers with stimulated Raman scattering [J]. *IEEE Photonics Technology Letters*, 1992, 4(2): 189-192.
- [18] Gong J M. The effect of SRS on signal power in single mode silica fiber in DWDM optical communication system with equally spaced channels [J]. *Chinese Journal of Lasers B*, 1999, B8(6): 51-54.
- [19] Gong J M, Fang Q, Liu J, et al. Analytical model of non-dispersion-limited transient stimulated Raman scattering in single-mode silica fiber in WDM optical communication system [J]. *Chinese Journal of Lasers*, 2000(2): 175-181.
- [20] Yu B L, Duan X, Wu Y. Establishment and application of data prediction model based on BP neural network [J]. *Computer & Digital Engineering*, 2016, 44(3): 482-486, 545.

- 喻宝祿, 段迅, 吴云. BP 神经网络数据预测模型的建立及应用[J]. 计算机与数字工程, 2016, 44(3): 482-486, 545.
- [21] Wu W, Feng G R, Li Z X, et al. Deterministic convergence of an online gradient method for BP neural networks [J]. IEEE Transactions on Neural Networks, 2005, 16(3): 533-540.
- [22] Liu K, Wang C F, Liu S Y. Artificial bee colony algorithm combined with previous successful search experience[J]. IEEE Access, 2019, 7: 34318-34332.
- [23] Chen J, Zhou Q X, Lin Y T, et al. Optimization design of multi-pump Raman fiber amplifiers based on artificial bee colony algorithm [J]. Acta Optica Sinica, 2018, 38(6): 0606002.
- 陈静, 周清旭, 林雅婷, 等. 基于人工蜂群算法的多抽运拉曼光纤放大器优化设计[J]. 光学学报, 2018, 38(6): 0606002.
- [24] Akhlaghi M, Emami F. Fuzzy adaptive modified PSO-algorithm assisted to design of photonic crystal fiber Raman amplifier [J]. Journal of the Optical Society of Korea, 2013, 17(3): 237-241.
- [25] Bottacini M, Poli F, Cucinotta A, et al. Modeling of photonic crystal fiber Raman amplifiers [J]. Journal of Lightwave Technology, 2004, 22(7): 1707-1713.