

基于人工神经网络和粒子群优化的半导体激光器 参数反向设计方法

冯佩, 李侯*

山东大学信息科学与工程学院, 山东 青岛 266237

摘要 提出一种基于人工神经网络(ANN)和粒子群优化(PSO)的半导体激光器参数反向设计方法。利用由传统数值仿真方法计算出的激光器功率样本数据来训练 ANN,并用此网络预测激光器任意一组参数对应的功率谱,均方差可低至 0.5 mW,用时仅 0.07 s,计算速度提高了约 1800 倍(与相同环境下传统数值算法耗时 125.57 s 相比)。将此网络与 PSO 算法结合,可获得目标功率谱的对应参数,即实现反向设计。经计算获得的反向设计方案不唯一,从而进一步验证了半导体激光器非线性多参数的特点。相同环境下 ANN 结合 PSO 的反向算法(均方差低于 0.04 mW,用时 39.45 s)与传统数值反向方法(均方差为 0.89 mW,用时 192 h)相比,精度提高了 22.25 倍,速度提高了约 17500 倍,说明了该方法的有效性。

关键词 激光器; 人工神经网络; 粒子群优化算法; 激光器输出功率谱; 反向设计

中图分类号 TN242

文献标识码 A

doi: 10.3788/CJL201946.0701001

Semiconductor Laser Parameter Inverse Design Method Based on Artificial Neural Network and Particle Swarm Optimization

Feng Pei, Li Yu*

School of Information Science and Engineering, Shandong University, Qingdao, Shandong 266237, China

Abstract This study proposes a novel semiconductor laser parameter inverse design method based on artificial neural network (ANN) and particle swarm optimization (PSO) algorithm. The ANN is trained using a laser output power as sampling data, which can be calculated by applying the traditional numerical simulation method. The network can be used to predict the power spectrum of the laser for any new values of the selected parameters. The mean square error can be as low as 0.5 mW and the CPU time as low as 0.07 s, which is about 1800 times more efficient than that of the numerical algorithm, which takes 125.57 s CPU time in the same environment. To obtain the design parameters for any target power spectrum, the inverse design can be achieved by combining this network with the PSO algorithm. It is clear from the calculation that the inverse design parameters are not unique, which proves that the semiconductor laser has a nonlinear multi-parameter problem. The combination of ANN and PSO inverse algorithm (with a mean square error of less than 0.4 mW and a CPU time of 39.45 s) demonstrates greater performance based on the same condition when compared with the traditional numerical simulation inverse method (with a mean square error of less than 0.89 mW and CPU time of 192 h). The accuracy and speed of the proposed method are improved by 22.25 times and about 17500 times, respectively.

Key words lasers; artificial neural network; particle swarm optimization algorithm; laser output power spectrum; inverse design

OCIS codes 140.3430; 000.4430; 230.6080

1 引 言

半导体激光器因其具有效率高、稳定性好、寿命

长、体积小等优势而备受关注,被广泛应用于军事、医疗、通信等领域。输出功率谱是激光器的一个重要参考特性,从中可获得激光器的阈值电流、峰值功

收稿日期: 2018-12-25; 修回日期: 2019-03-05; 录用日期: 2019-03-11

基金项目: 国家重点研发计划(2018YFA0209000)、国家自然科学基金(11304181)、山东省自然科学基金(ZR2013FQ018)

* E-mail: li.yu@sdu.edu.cn

率等重要信息,而功率谱是由激光器内部诸多参数共同影响决定的,即一组确定的参数经过数值计算可得出一个功率谱^[1]。从激光器的功率谱中得出其对应的物理参数,这是一个多参量非线性的反向设计问题^[1]。反向设计在科研和生产中有诸多应用^[2-3]。传统的半导体激光器参数反向设计方法存在容易陷入局部最优和计算量庞大等缺陷^[1],因此有必要研究高精度且高速的反向设计方法。近年来,随着人工智能技术的迅速发展,机器学习被用于各个领域^[4-7]。有学者将人工神经网络(ANN)与遗传算法(GA)相结合来解决多参量非线性优化问题^[1,8],但GA计算量会随着待优化参数的增多而增大^[9],这种方法仍然达不到高速的要求。

粒子群优化(PSO)算法与GA有很多相似之处,比如二者都是从随机解出发,通过迭代寻找最优解,利用适应度函数来判断是否找到最优解等,但PSO算法没有GA的“交叉”(crossover)和“变异”(mutation)操作,速度更快,精度更高^[1,10]。此外,ANN和PSO算法相结合,可实现高效的激光器参数反向设计。因此,本文以分布式反馈(DFB)激光器为例,提出一种基于ANN和PSO算法的半导体激光器参数反向设计方法。采用MATLAB软件的神经网络工具包创建一个反向传播(BP)神经网络^[8,11],该网络对DFB半导体的样本数据进行学习与训练,成为可替代原有DFB激光器数值仿真过程的神经网络模型,并将此模型与PSO算法结合,实现对器件参数的快速反向设计。

2 设计方法

采用传统的行波模型(TWM)数值仿真算法^[12-13],可获得足够多的半导体激光器样本数据,这些数据经过ANN的训练与学习之后,组成一个固定的网络模型^[14],在该网络中输入一组参数即可迅速得出相应的功率谱。在PSO算法的寻找过程中使用该网络,而非直接采用TWM数值仿真方法来得到功率谱,可避免大量的数值计算,从而提高PSO算法的迭代速度。

2.1 BP神经网络的工作原理

BP网络是一个利用误差反向传播算法对网络进行训练的前向多层网络^[1,15],具有结构简单和可塑性强等优势,已广泛应用于函数逼近^[1]、模式识别及信息分类等领域。

BP网络一般由输入层、输出层和隐含层组成,隐含层可以为一层或多层。本研究以只有一个隐含

层的简单BP网络为例,对BP网络进行简单介绍。图1为具有一个隐含层的BP网络结构示意图,其中*i*、*j*、*k*层分别表示输入层、隐含层和输出层。输入层有*M*个神经元,输出层有*N*个神经元,隐含层有*L*个神经元, $\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_M$ 为输入矢量, $\mathbf{T}_1, \mathbf{T}_2, \dots, \mathbf{T}_N$ 为输出矢量(即期望输出), \mathbf{W}_{ij} 为输入层到隐含层的权值矩阵, \mathbf{W}_{jk} 为隐含层到输出层的权值矩阵,虚线表示误差传播途径,即反向传播。

BP网络根据样本数据学习输入与输出关系的过程称为正向传播过程;实际输出与期望输出的误差按照平方最小的规则从输出层向隐含层反向传播,调整权值矩阵 \mathbf{W}_{jk} ,再向输入层反向传播,调整权值矩阵 \mathbf{W}_{ij} ,这个过程即为误差反向传播过程。对正、反传播过程进行反复调整,从而使网络性能更好、精度更高。




图1 具有一个隐含层的BP网络结构示意图

Fig. 1 Structural diagram of BP network with hidden layer

2.2 PSO算法的基本原理

PSO算法是一种群人工智能算法^[10],其主要思想是模拟鸟类捕食过程。捕食过程即寻找全局最优解的过程,所有粒子都有记忆功能。在一次寻找过程中,每个粒子通过平衡自身寻找过的最优位置 p_{best} (局部最优位置)和粒子群分享信息得到的最优位置 g_{best} (全局最优位置)来决定本次寻找的方向和运动速度,再通过预先设置的适应度函数来判断本次寻找位置的优劣,经过有限次寻找后得到全局最优解。粒子速度和粒子位置可表示为

$$V_q(t+1) = \omega V_q(t) + c_1 r_1(t) \times [p_{bestq}(t) - x_q(t)] + c_2 r_2(t) \times [g_{bestq}(t) - x_q(t)], \quad (1)$$

$$x_q(t+1) = x_q(t) + V_q(t+1), \quad (2)$$

式中: q 表示微粒, $q=1,2,3,\dots,Y$, Y 为该群体中粒子的总数; t 表示第*t*代; V_q 为粒子的速度; x_q 为粒子的当前位置; ω 为惯性权重; $r_1(t), r_2(t)$ 为介于0和1之间的两个相互独立的随机数; c_1, c_2 为加速常数,通常在0~2之间取值。

2.3 ANN 结合 PSO 的整体方法

将 ANN 与 PSO 结合,由任意给定的输出功率谱曲线反推器件的各参数值,实现对具有多参量非线性特性的半导体激光器的快速反向设计。首先,通过传统 TWM 数值仿真方法计算出足够多的样本数据;其次,用 ANN 训练和学习这些样本数据,从而建立一个基于 TWM 数值仿真方法的神经网络模型;最后,在进行 PSO 的反向设计时,使用该神经网络模型来实现快速迭代,逼近目标输出功率谱曲线,从而获得反向设计参数值。

初始化 PSO 后,在一次寻找过程中,根据设置的待反向参数范围、上一次寻找过程中的 g_{best} 及各 p_{best} 等给每个粒子赋一组参数值,通过选定的网络迅速得出相应参数组合对应的激光器功率谱,以避免反复的传统数值计算导致的计算速度缓慢且存储量大等问题。PSO 算法通过比较该组激光器功率谱和目标功率谱的误差,更新 g_{best} 及各 p_{best} 。若 g_{best} 所对应的功率谱与目标功率谱的均方差(MSE)小于预设的值或迭代次数达到最高,即停止寻找,否则进入下一个寻找过程。反向设计的整个流程如图 2 所示。

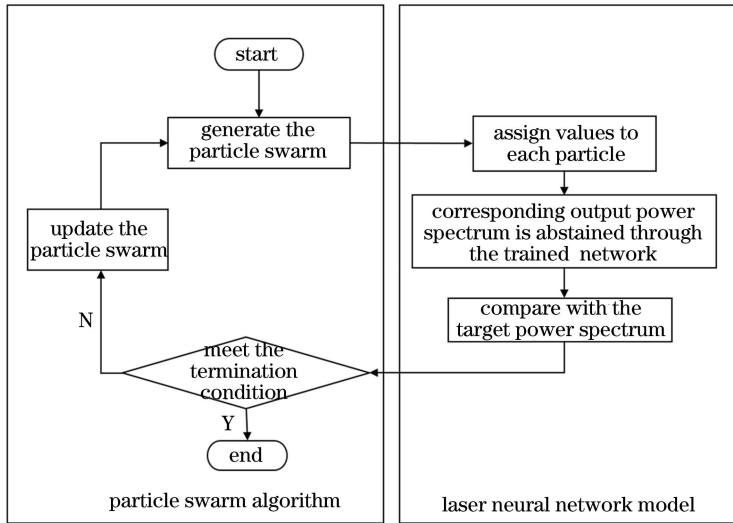


图 2 反向设计过程总体示意图

Fig. 2 Schematic of overall inverse design process

3 建立半导体激光器神经网络模型

要建立半导体激光器数值仿真方法的神经网络模型,首先要对网络进行初始设置,包括层数及每层神经元个数等结构设置和其他基本设置;其次,使该网络对由传统数值算法建立的样本数据进行训练和学习,并对训练好的网络进行测试。

3.1 神经网络的结构与基本设置

影响激光器输出功率谱的参数有很多,本研究选择其中与温度有关的 7 个待研究参数,即电流注入效率 η_{effc} (无量纲)、热容量倒数 R_i (单位为 K/J)、串联热电阻 R_s (单位为 Ω)、器件温度 K_e (单位为 K)、增益特征温度系数 K_g (单位为 K) 和载流子特征温度系数 K_n (单位为 K)、损耗 l (单位为 cm^{-1})^[12], 作为神经网络的输入矢量 $\mathbf{P} = [\eta_{effc}, R_i, R_s, K_e, K_g, K_n, l]$, 即输入层有 7 个神经元;输出矢量为对应参数经过激光器 TWM 数值仿真得到的输出功率谱 $\mathbf{T} = [y_1, y_2, y_3, \dots, y_{60}]$, 其中 $y_1, y_2, y_3, \dots, y_{60}$ 为不同注入电流下的输出功率, 单位

为 mW, 注入电流范围为 10 ~ 128 mA, 间隔为 2 mA, 即输出层有 60 个神经元。

BP 神经网络的建立, 需要提前设置合适的网络隐含层的层数和每层所包含的神经元个数^[1,8]。若隐含层的层数过少并且每层的神经元数也过少, 则学习效果不佳; 若隐含层的层数过多或每层的神经元数过多, 则不必要的计算量增大。事实证明, 可以用一个隐含层来学习任何问题^[14], 使用金字塔规则来确定隐含层神经元数的初始值^[8]。在该规则中, 当只有一个隐含层时, 若输入层、输出层的神经元数分别为 M 和 N , 则隐含层神经元数 L 可表示为

$$L = \sqrt{MN} \quad (3)$$

本研究中输入层有 7 个神经元, $M = 7$, 输出层有 60 个神经元, $N = 60$, 根据(3)式可算出隐含层的神经元数约为 20, 因此需要建立一个 $7 \times 20 \times 60$ 的初始网络。

3.2 神经网络的训练与学习

要得到足够多的不同参数组合下的半导体激光

器功率谱,需要对激光器的物理过程进行仿真分析。本研究使用传统 TWM 方法对 \mathbf{P} 在各参数取值范围内的随机组合进行仿真分析,得到其对应的输出功率谱,以此输入和输出结果作为神经网络的样本数据^[11-12],共计 500 组。

使用 Levenberg-Marquardt 训练函数对 $7 \times 20 \times 60$ 的网络进行训练^[11],并得到该网络的拟合性能后,对隐含层的神经元个数进行适当优化。通过比较不同结构网络的性能函数、计算精度和速度,选择最合适的结构作为最终的网络结构。表 1 所示为不同结构网络的训练效果,其中 n 表示优化结构的隐含层神经元个数。

表 1 不同网络结构的训练误差对比

Table 1 Comparison of training error between different network structures

n	10	15	20	25	30	35	40
MSE /mW	3.20	1.81	0.55	0.49	0.34	0.28	0.17

从表 1 可看出,隐含层神经元个数越多,训练精度越高,但为了防止出现过拟合的现象^[13],不宜选用精度过高的网络结构,因此本研究选择建立 $7 \times 20 \times 60$ 的网络。用样本数据对网络进行训练,其误差曲线如图 3 所示,其中 MSE 表示均方差。可以看出,计算精度随着学习次数的增大而提高,当迭代次数为 20 时,均方差已接近 1 mW,当迭代次数为 35 时,均方差基本稳定在 0.55 mW。

为验证网络训练效果,从样本数据中随机选择 10 组数据,通过神经网络计算得到相应的输出功率谱,将其与通过传统 TWM 数值仿真得出的功率谱进行比较。图 4 所示为一组随机的功率谱,其中 NN 表示神经网络,两种仿真方法的输入参数同为

表 2 样本数据的 TWM 数值仿真与神经网络得到的部分数据比较

Table 2 Comparison of partial output data between TWM simulation and neural network for sample data

Parameter	Value					
I /mA	28	48	68	88	108	128
W_0 /mW	6.81	12.13	17.11	21.35	23.73	21.32
W_N /mW	7.23	12.55	16.99	21.13	23.90	21.53
E /%	6.0	3.4	0.7	1.0	0.7	0.9

为进一步测试网络性能,用传统 TWM 数值仿真方法根据 10 组新产生的 \mathbf{P} 参数计算功率谱,并与通过本文网络计算得到的相应输出功率谱进行比较。图 5 所示为一组随机的输出功率谱,其中两组功率谱的输入参数均为 $\mathbf{P} = [0.78, 8.81 \times 10^8, 18.90, 335.89, 96.16, 147.30, 33.25]$,部分输出功率数值如表 3 所示, W_T 表示测试数据输出功率值,




图 3 训练误差曲线

Fig. 3 Training error curve




图 4 样本数据的 TWM 数值仿真与神经网络得到的输出功率谱

Fig. 4 Output power spectra obtained by TWM numerical simulation and neural network for sample data

$\mathbf{P} = [0.623, 9.28 \times 10^8, 18.687, 302.397, 127.210, 37.667, 26.120]$ 。部分输出功率数值如表 2 所示,其中 I 表示注入电流, W_0 表示原始数据输出功率值, W_N 表示将该组参数输入训练好的网络后的输出功率, E 表示神经网络输出功率与 TWM 输出功率的相对误差。从图 4 及表 2 可以看出,TWM 输出功率谱与同样参数下经本文网络计算得到的输出功率谱拟合效果很好,平均相对误差仅为 2%。

W_N 表示该测试组参数输入训练好的网络后的输出功率, E 表示神经网络输出功率与 TWM 输出功率的相对误差。从图 5 和表 3 可看出,测试数值输出功率谱与同样参数下经网络计算得到的输出功率谱拟合效果很好,平均相对误差约为 2.3%,说明神经网络不仅能实现对样本数据的拟合,而且能够总结出输入与输出数据之间的内在物理关联信息,进而

解决其他的未知问题。

经上述两种对比后发现,神经网络对激光器传统数值仿真算法拟合效果好,精度高,每组功率谱的均方差约为 0.5 mW,且相同环境下用传统 TWM 数值算法计算出一组参数对应的功率谱用时 125.57 s,而所提网络的用时仅 0.07 s,提高了约 1800 倍。由于使用激光器神经网络模型可精确拟合传统 TWM 数值仿真方法,且速度更快,因此,在后续 PSO 反向设计中利用所提网络取代传统 TWM 数值仿真算法,以快速、精确地得出一组参数对应的功率谱,从而加快整个反向设计过程。

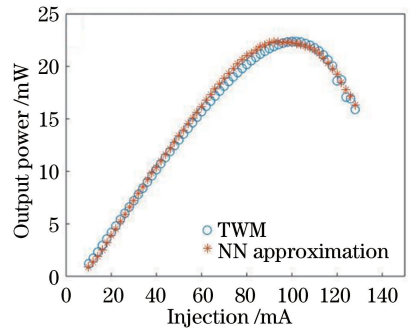


图 5 测试数据的 TWM 仿真与神经网络得到的输出功率谱对比图

Fig. 5 Comparison of output power spectra obtained by TWM simulation and neural network for test data

表 3 测试数据的 TWM 仿真输出与神经网络输出的部分数据比较

Table 3 Comparison of partial output data between TWM simulation and neural network for test data

Parameter	Value					
I / mA	28	48	68	88	108	128
W_T / mW	6.61	12.45	17.67	21.46	22.01	15.91
W_N / mW	6.57	12.78	18.33	22.06	21.78	16.35
$E / \%$	0.6	2.7	3.7	2.8	1.0	2.8

4 PSO 算法的反向设计

使用 MATLAB 软件自带的 PSO 算法工具箱,针对本研究的激光器参数反向设计问题,设置 PSO 算法的常规参数,如显示频率为 10 次,粒子维数为 7 (有 7 个待优化参数),粒子数目 Y 为 24 个,最大迭代次数为 300 次,其余参数如加速常数、惯性权重等均使用默认值^[10]。根据激光器的特性,选定上述 7 个待反向参数的范围 $\eta_{\text{effc}} \in [0.4, 1], R_i \in [10^7, 10^9], R_s \in [0.5, 20], K_e \in [300, 360], K_g \in [10, 150], K_n \in [10, 150], l \in [0, 50]$ 。

在 PSO 一次寻找过程中,根据设置的各反向参数范围以及上次迭代的结果,按(1)~(2)式给每个粒子赋参数值,这些参数通过之前训练好的神经网络可迅速得出其对应的功率谱,与目标功率谱进行均方差比较,当均方差小于设定的目标精度或达到最大迭代次数时,即停止迭代,否则进入下一个寻找过程。PSO 算法的迭代曲线如图 6 所示,可以看出,随着迭代次数的增加, g_{best} 逐渐向目标靠拢,即误差逐渐降低,当达到最大迭代次数时,均方差低于 0.04 mW,用时 39.45 s。

与传统数值反向方法(即不使用网络模型,而使用 TWM 计算 P 参数随机取值的输出功率谱,并使用迭代来逼近目标功率谱的方法)相比^[12-13],本研究

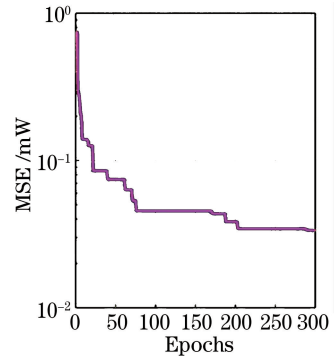


图 6 PSO 算法的寻找过程

Fig. 6 Schematic of searching process in PSO algorithm

验证了 ANN 结合 PSO 算法的有效性。本研究采用两种方法对同一组目标功率谱进行反向,效果如图 7 所示。图 7(a)所示为目标功率谱、数值反向功率谱与两组本文反向方法产生的功率谱的对比,图 7(b)所示为三组反向功率谱与目标功率谱的偏差。图 7 中四组谱线的部分输出功率数值如表 4 所示,其中 W_s 为数值方法反向输出功率值, W_1 表示第一个反向组的输出功率值, W_2 表示第二个反向组的输出功率值。

从图 7 和表 4 可看出,本文方法的两组功率谱与目标功率谱的拟合效果很好,均方差均小于 0.2 mW,而传统数值反向功率谱的拟合效果较差,偏差大,计算时间也较长。

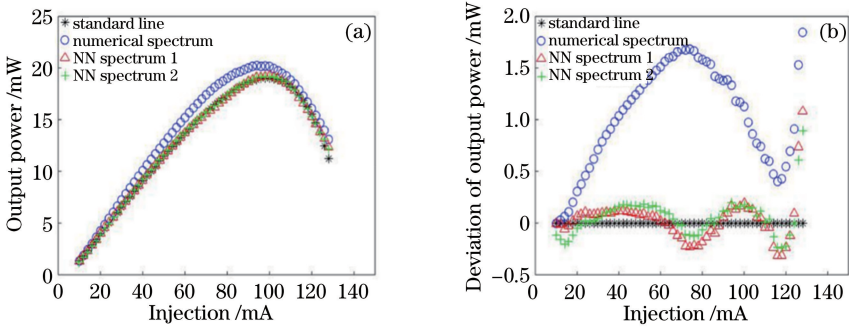


图 7 反向设计功率谱与目标功率谱的对比。(a)两组反向设计功率谱、数值反向功率谱与目标功率谱的对比；
(b) 两组反向设计功率谱、数值反向功率谱与目标功率谱的偏差

Fig. 7 Comparison between inverse design power spectra and target power spectrum. (a) Comparison among two sets of inverse design power spectra, numerical inverse power spectrum, and target power spectrum; (b) deviation of two sets of inverse design power spectra and numerical inverse power spectrum compared with target power spectrum

表 4 目标功率谱与反向设计功率谱的部分数据比较

Table 4 Comparison of partial data between target power spectrum and inverse design power spectra

Parameter	Value					
I / mA	28	48	68	88	108	128
W_T / mW	6.01	10.49	15.34	18.44	18.72	11.24
W_S / mW	6.63	12.20	17.00	19.83	19.24	13.08
W_1 / mW	6.61	11.06	15.22	18.41	18.55	12.32
W_2 / mW	6.04	11.13	15.33	18.49	18.61	12.13

相同环境下本文方法的均方差低于 0.04 mW, 用时 39.45 s, 而传统数值反向方法的均方差为 0.89 mW, 用时 192 h, 精度提高 22.25 倍, 速度约提高 17500 倍, 说明了本文方法的可行性。

图 7 中两组基于 ANN 与 PSO 的反向方法得来的参数与目标功率谱对应参数如表 5 所示, 其中 S_T 表示目标功率谱, S_1 表示第一组反向功率谱, S_2 表示第二组反向功率谱。

表 5 目标功率谱与反向设计功率谱的参数比较

Table 5 Comparison of parameters between target power spectrum and two sets of inverse design power spectra

Parameter	η_{effc}	$R_1 / (\text{K} \cdot \text{J}^{-1})$	R_s / Ω	K_e / K	K_g / K	K_n / K	l / cm^{-1}
S_T	0.59	6.69×10^8	15.19	304.58	105.91	18.25	23.80
S_1	0.80	7.68×10^8	15.69	317.85	94.08	69.98	46.22
S_2	0.78	7.08×10^8	20.00	325.61	96.49	108.73	45.31

由表 5 可知, 一组目标功率谱可以反向得到不同的参数组合, 证明了半导体激光器工作过程是一个多参量非线性问题^[1], 即多种参数组合都可以对应同一组目标功率谱; 这也进一步说明了神经网络不仅能够对原始数据进行拟合, 而且能够学习到激光器物理运行过程的内在机理, 具有强大的学习功能, 是可以用来解决未知问题的一种智能工具。

学习, 在 PSO 的一次寻找过程中, 使用神经网络模型代替传统 TWM 数值仿真算法, 对不同粒子携带的参数组进行快速而准确的计算, 得出功率谱。在 PSO 算法进行了有限次迭代后, 可以找到最接近目标功率谱的一组功率谱对应的参数, 即为反向设计的参数。用该方法对一组目标功率谱进行多次反向, 可以得到不同参数组合。激光器参数反向问题是一个多参量非线性问题, 说明了训练后的神经网络具备半导体激光器内在的相关物理信息。

5 结 论

提出一种半导体激光器参数反向设计方法, 将 ANN 和 PSO 算法相结合应用于激光器参数的反向设计中, 对激光器的设计有一定的参考意义。在此方法中, 首先用激光器的传统数值方法计算得到大量样本数据, 用这些样本数据对 ANN 进行训练与

参 考 文 献

[1] Xiao G Z, Long X W, Zhang B, *et al.* A novel global optimization method to design laser parameters with artificial neural network and genetic algorithm [J].

- Chinese Journal of Lasers, 2010, 37(5): 1203-1208.
肖光宗, 龙兴武, 张斌, 等. 基于人工神经网络和遗传算法的激光器参数全局优化方法[J]. 中国激光, 2010, 37(5): 1203-1208.
- [2] Peurifoy J, Shen Y C, Jing L, *et al.* Nanophotonic particle simulation and inverse design using artificial neural networks[J]. Science Advances, 2018, 4(6): eaar4206.
- [3] Piggott A Y, Lu J, Lagoudakis K G, *et al.* Inverse design and demonstration of a compact and broadband on-chip wavelength demultiplexer [J]. Nature Photonics, 2015, 9(6): 374-377.
- [4] Hanakata P Z, Cubuk E D, Campbell D K, *et al.* Accelerated search and design of stretchable graphene kirigami using machine learning[J]. Physical Review Letters, 2018, 121(25): 255304.
- [5] Vargas-Hernández R A, Sous J, Berciu M, *et al.* Extrapolating quantum observables with machine learning: inferring multiple phase transitions from properties of a single phase [J]. Physical Review Letters, 2018, 121(25): 255702.
- [6] Qian M Y, Yu Y L. Tactile sensing of fiber Bragg grating based on back propagation neural network [J]. Chinese Journal of Lasers, 2017, 44 (8): 0806001.
钱牧云, 余有龙. 基于逆传播神经网络的光纤布拉格光栅触觉传感 [J]. 中国激光, 2017, 44 (8): 0806001.
- [7] Wang S S, Huang K, Li M, *et al.* Quantitative optical detection method of hemoglobin based on BP neural network [J]. Acta Optica Sinica, 2018, 38 (7): 0717002.
王姗姗, 黄凯, 李铭, 等. 基于 BP 神经网络的血红蛋白定量光学检测方法 [J]. 光学学报, 2018, 38 (7): 0717002.
- [8] Wang Y S, Xu H G. Fast convergent algorithm-BP for training neural network [J]. Journal of Jilin University (Engineering and Technology Edition), 2003, 33(4): 79-84.
王赞松, 许洪国. 快速收敛的 BP 神经网络算法 [J]. 吉林大学学报(工学版), 2003, 33(4): 79-84.
- [9] Froemming N S, Henkelman G. Optimizing core-shell nanoparticle catalysts with a genetic algorithm [J]. The Journal of Chemical Physics, 2009, 131 (23): 234103.
- [10] Xiong T L, Kong X J, Lei X H, *et al.* Temperature control optimization for semiconductor laser diode based on particle swarm optimization[J]. Optics & Optoelectronic Technology, 2013, 11(5): 10-12, 32.
熊天林, 孔小健, 雷选华, 等. 基于粒子群算法的半导体激光器温度控制优化 [J]. 光学与光电技术, 2013, 11(5): 10-12, 32.
- [11] Shi J J, Li Q Y, Zhang Q, *et al.* Forecast system for blasting vibration velocity peak based on Matlab and BP neural network[J]. Explosion and Shock Waves, 2017, 37(6): 1087-1092.
施建俊, 李庆亚, 张琪, 等. 基于 Matlab 和 BP 神经网络的爆破振动预测系统 [J]. 爆炸与冲击, 2017, 37(6): 1087-1092.
- [12] Li Y, Xi Y P, Li X, *et al.* Design and analysis of single mode Fabry-Perot lasers with high speed modulation capability[J]. Optics Express, 2011, 19 (13): 12131-12140.
- [13] Davis M G, O'Dowd R F. A transfer matrix-based analysis of multielectrode DFB lasers [J]. IEEE Photonics Technology Letters, 1991, 3(7): 603-605.
- [14] Hagan M T, Demuth H B, Beale M, *et al.* Neural network design[M]. Dai K, Transl. 2nd ed. Beijing: China Machine Press, 2002: 201-205, 210-211, 229-231, 248-250.
Martin T. Hagan, Howard B. Demuth, Mark Beale. 神经网络设计[M]. 戴葵, 译. 2 版. 北京: 机械工业出版社, 2002: 201-205, 210-211, 229-231, 248-250.
- [15] Yang Y, Cheng Y, Xu M S, *et al.* Application of neural networks in design of Q-switched laser [J]. Chinese Journal of Lasers, 2010, 37(3): 646-651.
杨阳, 程寅, 徐明顺, 等. 神经网络在调 Q 激光器优化设计上的应用 [J]. 中国激光, 2010, 37(3): 646-651.