

文章编号: 0258-7025(2010)03-0646-06

神经网络在调 Q 激光器优化设计上的应用

杨 阳¹ 程 寅¹ 徐明顺² 王石语¹ 过 振¹ 蔡德芳¹ 李兵斌¹

(¹ 西安电子科技大学技术物理学院, 陕西 西安 710071)
(² 中国兵器工业第二〇五研究所, 陕西 西安 710065)

摘要 通过神经网络(NN)建立了调 Q 激光器的优化设计模型。利用典型的谐振腔参数和抽运参数由速率方程进行数值求解, 获得激光器的输出数据, 形成神经网络的训练样本。通过这些样本对反向传播(BP)神经网络进行训练, 从而建立起一个联接激光器的结构参数和激光器输出性能参数的 BP 神经网络。利用该网络能够由激光器输出参数对激光器结构参数进行预测, 完成激光器的快速设计, 在 Pentium 4 2.4 GHz 的计算机上训练用时为 2.96 s。测试数据显示, 测试值和预测值的峰值功率、光束质量、脉宽的标准差分别为 3.1%, 3.4%, 5.8%。结果表明, 利用 BP 神经网络依据激光器的输出要求参数进行反向设计, 预测出的激光器结构参数和抽运参数误差小, 实验数据能够很好吻合。

关键词 激光技术; 调 Q 激光器; 系统设计; 神经网络; 反向传播网络

中图分类号 TN242 文献标识码 A doi: 10.3788/CJL20103703.0646

Application of Neural Networks in Design of Q-Switched Laser

Yang Yang¹ Cheng Yin¹ Xu Mingshun² Wang Shiyu¹

Guo Zhen¹ Cai Defang¹ Li Bingbin¹

(¹ School of Technical Physics, Xidian University, Xi'an, Shaanxi 710071, China)
(² 205 Institute of Ordnance Industry of China, Xi'an, Shaanxi 710065, China)

Abstract An optimized design model of Q-switched lasers is established with neural networks (NN). Obtain the laser outputs with the numerical solution for the rate equations when given cavity parameters and pumping parameters, and these data will form the training set of neural networks. A back-propagation (BP) neural network is established after being trained based on the relationship between the laser structure parameters, pumping parameters and laser outputs. A quick design of Q-switched laser with the network to predict the laser structure parameters and pumping parameters according to required laser outputs can be made while the training time is 2.96 s for computer configuration of Pentium 4 2.4 GHz. Test data and experimental results show that the design standard deviation of peak output power, beam quality and pulsewidth are respectively 3.1%, 3.4% and 5.8%. The results give good agreement and the errors are small.

Key words laser technique; Q-switched lasers; system design; neural network; back-propagation network

1 引 言

激光二极管(LD)抽运的调 Q 固体激光器(DPL)自 20 世纪 80 年代中后期出现以来^[1], 以高效率、长寿命、高稳定性、高光束质量及结构紧凑等优点引起人们的广泛关注, 成为当今国际激光领域

的研究热点之一。激光二极管抽运调 Q 激光器已经代替传统的灯抽运固体激光器, 成为脉冲固体激光器的主流产品。如何根据实际需要快速设计此类激光器也成为一个问题。当激光器谐振腔参数和抽运参数已知时, 可以依据速率方程

收稿日期: 2009-07-24; 收到修改稿日期: 2009-09-15

基金项目: 国家专项研究基金(9140A02010106DZ01)资助项目。

作者简介: 杨 阳(1984—), 女, 硕士研究生, 主要从事固体激光器设计及神经网络建模方面的研究。

E-mail: robinchyna@yahoo.com.cn

导师简介: 王石语(1966—), 男, 教授, 博士生导师, 主要从事新型光电子器件及大功率高重复频率激光二极管抽运固体激光器方面的研究。E-mail: yshi@mail.xidian.edu.cn

计算出激光器的输出参数,如峰值功率、光束质量和脉冲宽度等(称为正向计算)^[2,3]。但是在实际的激光器设计中,往往需要根据激光器的输出要求来设计谐振腔参数和抽运参数(称为反向计算)。针对激光器的反向计算,目前还没有较好的计算方法可以直接应用。常用的方法是预设激光器的结构参数,通过正向计算获得激光器的正向输出参数,再通过调整谐振腔参数、抽运参数使得计算结果达到要求。这种方法主要依靠经验设置初始参数并凭经验调整,在运算精度和速度上都不太理想。于是本文引入神经网络(NN)来解决这个问题。

神经网络是由大量简单的基本元件——神经元相互连接,通过模拟人的大脑神经处理信息的方式,进行信息并行处理和非线性转换的复杂网络系统^[4]。对于非线性系统,它具有明显的优越性。现已证明一个三层网络即可模拟任意复杂的非线性问题^[5],表明一个由三层神经元构成的前向网络能够

形成任意复杂的判决区域,可以完成任意的 n 维到 m 维的映射。通过选择典型的输入输出样本数据对确定的神经网络进行的训练和调整,建立调 Q 固体激光器逆向计算模型,由对激光器的输出要求预测激光器的结构参数(谐振腔参数和抽运参数)。

2 理论基础

2.1 调 Q 固体激光器的正向计算模型

采用连续激光二极管端面抽运调 Q Nd:YAG 激光器作为模型。LD 的输出光束经耦合系统后入射 Nd:YAG 晶体;晶体前端面镀有 808 nm 的全透膜,1064 nm 的全反膜,与输出镜一起形成激光谐振腔,输出镜透过率均取为 15%。

对于四能级系统 Nd:YAG 固体激光器,将调 Q 速率方程和光场运动方程相结合,进行模拟计算得出的速率方程为^[2]

$$\begin{cases} \frac{dn(x,y,z,t)}{dt} = p(x,y,z) - \frac{n(x,y,z,t)}{\tau_f} - \frac{c\sigma n(x,y,z,t)}{n_g} S_0(x,y,z,t), & (1) \\ \frac{dN_0(t)}{dt} = \frac{c\sigma}{n_g} \int n(x,y,z,t) S_0(x,y,z,t) dV - \frac{c\delta_0}{2n_g l} N_0(t), & (2) \end{cases}$$

式中 $n(x,y,z,t)$ 为反转粒子数密度; $p(x,y,z)$ 为抽运速率密度; τ_f 为激光上能级荧光寿命; c 为真空中光速; σ 为受激辐射截面; $S_0(x,y,z,t)$ 为基模振荡光子密度; n_g 为增益介质折射率; δ_0 为基模腔内往返损耗率; $N_0(t)$ 为腔内基模振荡光子总数; l 为增益介质长度,积分区域为整个增益介质。

将调 Q 固体激光器的工作过程分为两个阶段:能量储存过程和能量释放过程,对(1),(2)式进行数值求解,可以得到激光器谐振腔的输入参数即抽运功率、抽运光半径和腔长这三者一定时所对应的谐

振腔输出参数:峰值功率、光束质量和脉冲宽度。

2.2 反向传播网络的构造和算法

反向传播(BP)网络是一个前向多层网络。它利用误差反向传播算法对网络进行训练,包含了神经网络理论中最为精华的部分,由于其结构简单、可塑性强,故在函数逼近、模式识别、信息分类及数据压缩等领域得到了广泛的应用^[4]。

3 层神经网络如图 1 所示,其中 f 为传输函数, W 为权值, b 为偏置, s 为敏感性, α 为学习速度, R 和 S 分别为矩阵的行数和列数。




图 1 3 层神经网络

Fig. 1 3 layers of neural networks

BP 算法的输入是一个网络正确行为的样本集合^[6]

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_q, t_q\},$$

式中 p_q 为网络的输入, t_q 为对应的目标输出。每输入一个样本, 便将网络输出与目标输出相比较。该算法将调整网络参数以使均方误差最小化

$$F(x) = E[e^T e] = E[(t^T - a^T)(t - a)], \quad (3)$$

式中 x 为网络权值和偏置值的向量, a 为网络的输出。

第一步是通过网络将输入向前传播

$$\begin{aligned} a^0 &= p \\ a^{m+1} &= f^{m+1}(W^{m+1}a^m + b^{m+1}), \\ m &= 0, 1, \dots, M-1 \\ a &= a^M, \end{aligned} \quad (4)$$

第二步是通过网络将敏感性反向传播

$$\begin{aligned} s^M &= -2\dot{F}^M(n^M)(t - a), \\ s^m &= \dot{F}^m(n^m)(W^{m+1})^T s^{m+1}, \\ m &= M-1, \dots, 2, 1 \end{aligned} \quad (5)$$

第三步使用近似的最速下降法更新权值和偏置值

$$\begin{aligned} W^m(k+1) &= W^m(k) - \alpha s^m (a^{m-1})^T, \\ b^m(k+1) &= b^m(k) - \alpha s^m. \end{aligned} \quad (6)$$

由上可知, BP 网络首先是对每一种输入模式设定一个期望输出值, 然后对网络输入实际的学习记忆模式, 并由输入层经隐层向输出层传播, 此过程为“模式顺传播”。实际输出与期望输出的差即是误差。其按照误差平方最小这一规则, 由输出层向隐层逐层修正连接权值和偏置值, 此过程为“误差逆传播”。随着“模式顺传播”和“误差逆传播”的过程交替反复进行, 不断调整网络的权值和偏置值, 使得误差信号最小, 最终使网络的实际输出逐渐向各自所对应的期望输出逼近^[6]。

3 调 Q 激光器的 BP 网络逆向计算模型

3.1 逆向建模的动态系统

建立一个调 Q 激光器的动态系统的逆模型, 即将调 Q 激光器的输出参数作为网络的输入, 网络的

表 1 网络训练误差

Table 1 Network training errors

n	4	5	6	7	8	9	10	11	12	13
δ	0.3142	0.2875	0.2883	0.1292	0.0847	0.0758	0.0858	0.0808	0.0716	0.0662

表 2 表明, 经过 500 次训练后(训练函数为 trainlm), 隐层神经元为 9 的 BP 网络对函数的逼近

输出对应激光器的结构参数。用 BP 网络建立模型的过程如图 2 所示。

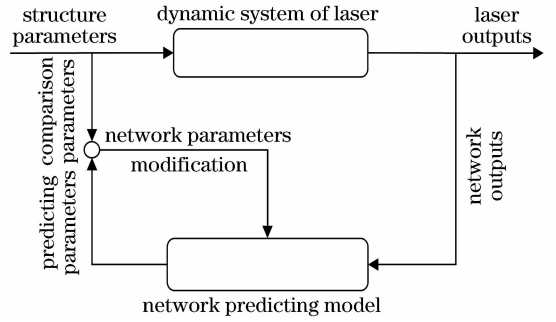


图 2 建立激光器设计逆向模型的过程

Fig. 2 Illustration of process of setting up the reversed model of laser design

3.2 设计步骤

3.2.1 输入输出向量的设计

调 Q 激光器腔内损耗和输出镜反射率一定的情况下, 其性能参数峰值功率 (P_{\max})、光束质量 (M^2)、脉冲宽度 (T_p) 主要受其结构参数抽运功率 (P_{in})、腔长 (L)、抽运半径 (τ_p) 的影响。前三者为神经网络的输入, 后三者为输出。

3.2.2 BP 网络的设计

根据 BP 网络的设计网络, 一般的预测问题都可以通过单隐层的 BP 网络实现。隐层神经元不能过少, 否则网络精度会很低; 也不能过多, 否则会增加网络连接权数目, 增加计算量, 容易出现隐层单元的冗余现象^[6]。同时训练精度也不宜过高, 否则可能出现过拟合现象, 反而降低了神经网络的预测精度^[7], 这里定为 10^{-4} 。

由于输入向量有 3 个元素, 根据 Kolmogorov 定理可知, 网络隐层确定的神经元根据参考公式 $n_1 = \sqrt{n+m} + a$ ^[8], 其中 m 为输出神经元数, n 为输入单元数, a 为 1~10 之间的常数, 判断隐层神经元应该在 4~13 之间。

由表 1 可知, 设计隐层神经元 n 分别为 4~13 个的神经网络, 得到网络误差 δ , 观察其性能。通过比较对训练样本的训练结果, 选择收敛最快、精度最高的网络拓扑结构。

效果最好, 且经过 100 代就达到了预期误差, 神经元的进一步增加反而导致误差变大, 说明开始出现过

表 2 样本数据
Table 2 Paramters of samples

	Peak output power /kW	Beam quality	Laser pulse width /ns	Pumping power /W	Cavity length /mm	Pumping beam radius /mm
1	77.007	2.089	6.300	29.940	75.000	0.519
2	88.154	2.089	6.300	33.333	75.000	0.539
3	76.516	2.100	5.880	27.073	70.000	0.486
4	53.690	2.096	6.432	20.000	67.000	0.442
5	42.177	2.088	6.240	16.667	65.000	0.424
6	28.758	2.058	6.600	11.670	55.000	0.388
7	20.328	2.026	5.874	8.469	44.500	0.367
8	13.593	1.938	5.676	5.832	31.531	0.343
9	97.354	1.849	5.988	26.162	62.375	0.441
10	100.493	1.643	5.520	22.586	57.500	0.393
11	116.286	1.360	5.683	20.510	52.625	0.353
12	104.116	1.202	5.683	17.549	52.625	0.327
13	47.169	1.130	6.115	8.829	50.960	0.262
14	56.930	1.478	6.132	12.045	51.100	0.308
15	49.713	1.603	6.115	11.638	50.960	0.317
16	51.909	1.821	5.940	14.144	55.000	0.356
17	13.593	1.938	5.676	5.832	31.531	0.343
18	102.999	2.046	8.222	47.218	84.700	0.657
19	53.690	2.096	6.432	20.000	67.000	0.442
20	101.021	2.075	6.600	40.261	78.571	0.592
21	87.498	2.040	8.505	43.561	88.594	0.649
22	97.700	2.117	4.723	26.698	65.600	0.484
23	91.659	2.126	4.539	26.667	63.048	0.459
24	80.316	2.079	7.543	33.282	78.571	0.551
25	69.302	2.044	8.505	35.788	88.594	0.601
26	80.252	2.041	8.533	40.665	88.889	0.633
27	47.051	2.039	9.600	26.764	88.889	0.546
28	45.706	2.108	5.295	14.588	55.160	0.387
29	49.664	2.072	7.543	23.249	78.571	0.494
30	13.487	1.252	5.443	3.237	22.680	0.246

拟合。虽然神经元为 13 的误差更小,但是从减少计算量和防止过拟合现象出发,在此将网络隐层的神经元数目设定为 9。

神经网络结构如图 3 所示。




图 3 BP 网络结构图

Fig. 3 Illustration of structure of BP network

3.2.3 网络收敛性

双层非线性网络的 BP 算法有个缺点,就是它的均方误差的性能曲面可能有多个局部极小点,而且在参数空间的不同区域曲率也是变化的。这使得难以以为最速下降法选择一个合适的学习速度,在较为平坦的区域平面需要一个较大的学习速度,以增加收敛速度;而在其他区域曲率很高的曲面则需要较小的学习速度,否则会导致网络的不稳定^[6]。

因此采用改进的 BP 算法:动量方法(MOBP)。MOBP 是将动量项加入到最速下降法,现已证明总是由动量系数 γ 决定算法的稳定性而非学习速度,其中 γ 在 0 和 1 之间时满足稳定条件,而算法对它的选择并不敏感^[6]。文中 γ 的默认值为 0.9。为了保证得到全局极小点,进行了多次训练,选择多个初始点,从

中选择出收敛最快、性能表现最好的训练网络。

3.2.4 网络训练

使用大量学习样本训练网络,开始随机给定较小的权值和阈值,通过反复的训练,在规定的代数内达到衡量目标时便停止训练。衡量目标一般是最小均方误差^[6](目标值与实际输出值的差值的平方和),如果该值小于期望的误差就是理想的结果。

通过对激光器的正向计算,获得表 2 所示的训练样本。样本中,峰值功率在 10~120 kW 之间,光束质量在 1.1~2 之间,脉冲宽度在 4.5~9 ns 之间。将其应用在设计的神经网络中进行训练。

训练过程中,网络的目标参数如表 3 所示, Training epochs 为训练代数, Training goal 为训练目标, Learning rate 为学习速度。图 4 为相应的训练曲线。从图 4 可知,均方误差可达 9.74×10^{-5} 。

表 3 网络设置参数

Table 3 Parameters of the neural network

Training epochs	Training goal	Learning rate
300	10^{-4}	0.1

该训练利用 Matlab 神经网络工具箱在配置为 Pentium 42.4 GHz, 512 M 内存的计算机下,耗时 2.96 s。共训练了 22 组网络,平均用时为 3 s。因为该神经网络的结构非常简单,所以在有限的 30 个数据

表 4 测试结果

Table 4 Training results

Input and target parameters							Forecasting laser parameters		
Peak output power /kW		Beam quality		Laser pulse width /ns		Pumping	Cavity	Pumping	
Test value	Target value	Test value	Target value	Test value	Target value	power / W	length / mm	beam radius / mm	
1	100	100.5	2.0	2.07	8.0	7.85	42.2	81.8	0.61
2	95	91.9	2.1	2.04	5.2	5.59	29.3	66.5	0.49
3	85	84.3	2.0	1.99	9.0	8.81	44.3	91.8	0.66
4	85	84.4	2.1	2.02	6.0	6.09	30.8	72.5	0.52
5	55	56.5	2.1	2.17	6.0	5.72	18.9	62.3	0.42
6	35	36.7	2.0	1.96	6.0	6.51	14.6	58.9	0.40
7	100	100.1	1.7	1.68	5.5	5.60	23.3	58.3	0.40
8	115	107.6	1.3	1.27	5.5	5.66	18.8	52.4	0.34
9	90	90.6	2.0	1.90	6.5	6.93	31.2	72.2	0.51
10	100	98.0	1.9	1.99	6	5.40	28.0	64.3	0.46

表 5 预测结果与实验数据的对比

Table 5 Contrast between the forecasting results and the experimental data

Network inputs			Experimental outputs of laser			Network forecasting results (as experimental inputs)			
Peak output power /kW	Beam quality	Laser pulse width /ns	Peak output power /kW	Beam quality	Laser pulse width /ns	Pumping power /W	Cavity length /mm	Pumping beam radius /mm	
1	120	1.8	6.0	115	2	5.5	30	62	0.5
2	35	2.2	6.5	34	2	6.5	16	65	0.4




图 4 网络训练曲线

Fig. 4 Training curve

的训练下就能很快收敛^[9],且精度较高。而训练好的网络对输入数据进行预测输出的时间为 0.48 s。

3.3 网络测试

在训练参数的取值区域,将 10 组与训练样本不同的激光器输出设计要求(即峰值功率、脉冲宽度、光束质量,称为测试值)输入到训练好的网络的输入端,由网络的输出端即可以得到网络所预测的谐振腔参数与抽运参数。

将此参数代入速率方程中进行正向计算,获得的激光器仿真输出参数如表 4 所示(称为目标值)。

从图 5 可看出设计要求和激光器仿真输出存在




图 5 误差百分比

Fig. 5 Percentage of errors

最大不超过 10% 的误差,且表 4 中峰值功率、光束质量、脉宽的标准差分别为 3.1%, 3.4% 和 5.8%, 基本符合实验要求。这说明用激光器的输入输出数据样本来训练神经网络,并用于反向设计的设想是可行的。

为进一步验证该网络的精度,用该网络设计两款激光器的参数。由表 5 可知,要求两款激光器输出的峰值功率分别为 120 和 35 kW;光束质量分别为 1.8 和 2.2;脉宽分别为 6 和 6.5 ns。将该要求参数作为神经网络(图 3 所示)的输入,得到网络的输出是:抽运功率分别为 30 和 16 W;腔长为 62 和 65 mm;抽运光半径为 0.5 和 0.4 mm。该输出参数即是网络预测的激光器抽运参数和谐振腔参数。按照该参数完成两款激光器的实验装置,结构如图 6 所示。图 6 中晶体抽运端面镀有 808 nm 的全透膜, 1064 nm 的全反膜,与输出镜一起形成激光谐振腔,输出镜透过率均为 15%。两款激光器输出情况的实测数据是:峰值功率分别为 115 和 34 kW;光束质量均为 2;脉宽分别为 5.5 和 6.5 ns。该数据和设计要求非常接近。




图 6 激光器实验结构

Fig. 6 Scheme of DPL experiment

设计要求和实验结果的峰值功率、光束质量和脉宽的平均误差分别为 3.5%, 10% 和 4%。误差的来源有神经网络本身预测误差以及实验中光束质量测量的不准确性。实验证明,采用神经网络的方法,可以根据激光器的输出要求对激光器的结构参数进行反向设计,设计效果符合实际应用的精度要求。

4 结 论

针对调 Q 固体激光器设计的要求,讨论了根据激光器输出参数预测激光器主要结构腔参数的问题,提出了非线性系统的神经网络解决方案。利用调 Q 固体激光器的速率方程数值求解得到神经网络的训练样本,即激光器结构参数和其输出性能参数。根据样本规模、问题复杂程度等对神经网络进行基本参数设置后,利用样本数据对神经网络进行训练,用时 2.96 s,获得了理想的结果。利用该网络设计激光器参数,激光器的输出参数如峰值功率、光束质量、脉宽等与要求值之间的标准差分别为 3.1%, 3.4% 和 5.8%。由于神经网络易于实现、处理速度快的特性,在有限的样本数据训练下即可达到要求精度。期待它在激光器设计方面有越来越多的应用。

参 考 文 献

- 1 T. Y. Fan, R. L. Byer. Diode laser-pumped solid-state lasers [J]. *IEEE J. Quantum Electron.*, 1988, **QE-24**(6):895~912
- 2 Wang Shiyu, Guo Zhen, Fu Junmei *et al.*. Effect of the pump light on the beam quality of the diode pumped laser [J]. *Acta Physica Sinica*, 2004, **53**(9):2995~3003
王石语, 过 振, 傅君眉 等. 抽运光分布对二极管抽运激光器振荡光束质量的影响[J]. *物理学报*, 2004, **53**(9):2995~3003
- 3 Tian Xinning, Yan Ping, Liu Qiang *et al.*. Optimization of passively Q-switched Nd: YAG/Cr: YAG microchip lasers and experiments [J]. *Optical Technique*, 2004, **30**(6):669~671
田信宁, 闫 平, 柳 强 等. 被动调 Q Nd: YAG/Cr: YAG 微晶片激光器的优化设计与实验[J]. *光学技术*, 2004, **30**(6):669~671
- 4 Yan Pingfan, Zhang Changshui. *Artificial Neural Networks and Evolutionary Computing* [M]. Beijing: Tsinghua University Press, 2005. 1
阎平凡, 张长水. *人工神经网络与模拟进化计算*[M]. 北京:清华大学出版社, 2005. 1
- 5 R. Hecht-Neilsen. Theory of the back propagation neural network [C]. *IJCNN*, 1989, **1**:593~605
- 6 Martin T. Hagan, Howard B. Demuth, Mark H. Beale. *Neural Network Design* [M]. Beijing: China Machine Press, 2002. 201~205, 210~211, 229~231, 248~250
- 7 Mat Buckland. *AI Techniques for Game Programming* [M]. Beijing: Tsinghua University Press, 2006. 221~223
M. 巴克兰德. *游戏中的人工智能*[M]. 北京:清华大学出版社, 2006. 221~223
- 8 Kaili Zhou, Yaohong Kang. *Neural Network Model and MATLAB Simulation Programming* [M]. Beijing: Tsinghua University Press, 2005. 90
周开利, 康耀红. *神经网络模型及其 MATLAB 仿真程序设计* [M]. 北京:清华大学出版社, 2005. 90
- 9 Rui Zhang, Alan Bivens. Comparing the use of bayesian networks and neural networks in response time modeling for service-oriented systems [C]. *Proceedings of the 2007 Workshop on Service-Oriented Computing Performance: Aspects, Issues, and Approaches*, 2007, **1**:67~74