

文章编号: 0258-7025(2010)05-1203-06

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

肖光宗 龙兴武 张斌 吴素勇 赵洪常 陈文学

(国防科技大学光电科学与工程学院, 湖南长沙 410073)

摘要 提出了一种新颖的基于人工神经网络(ANN)和遗传算法(GA)的激光器参数全局优化方法,建立激光器输出功率的人工神经网络模型,来模拟激光器参数对输出功率的综合影响机理,进而以该模型作为目标函数,采用遗传算法对激光器参数进行全局优化。以平凹腔单横模氦氖激光器为例验证了该方法的可行性和有效性。对相同参数的激光器,人工神经网络模型的仿真数据与实验数据的均方根误差为 0.0127 mW。应用该方法对其他参数全局优化后激光器预期输出功率比实验室已有的同等尺寸的激光器大,说明了该方法的有效性。

关键词 激光技术;参数优化;神经网络;遗传算法;输出功率

中图分类号 TN24 文献标识码 A doi: 10.3788/CJL20103705.1203

A Novel Global Optimization Method to Design Laser Parameters with Artificial Neural Network and Genetic Algorithm

Xiao Guangzong Long Xingwu Zhang Bin Wu Suyong Zhao Hongchang Chen Wenxue

(College of Optoelectronic Science and Engineering, National University of Defense Technology, Changsha, Hunan 410073, China)

Abstract A novel global optimization method based on artificial neural network and genetic algorithm is proposed for laser parameters design. An artificial neural network (ANN) is built to simulate the mechanism of the effects of laser parameters on its output power. And then the laser parameters are further optimized with genetic algorithm (GA) with the above obtained network as objective function. As an example, parameters of a typical plano-concave cavity He-Ne laser are globally optimized to testify the feasibility and effectiveness of the method. As concluded from the optimization experiment, the mean square error between the experimental data and simulation data from laser output power network is only 0.0127 mW. The output power of laser with parameters optimized by genetic algorithm is larger than the other laser with the same cavity length, which proves the effectiveness of the method.

Key words laser technique; parameter optimization; artificial neural networks; genetic algorithms; output power

1 引言

输出功率是衡量氦氖激光器性能的一个重要参数。影响输出功率的参数较多,影响机理交错复杂。几十年来,单个参数对输出功率的影响在理论和实验上均已有了较多研究。设计和加工激光器时,通常从每个参数影响输出功率的经验公式出发分别寻找其局域最优值,但这样无法保证这些最优值的组合方案是全局最优的^[1]。此外,对于已经加工完成的激光谐振腔,通常采用实验的方法来确定最佳放电

条件以获得最大输出功率,效率较低。

激光器的输出功率实际上是关于其参数的多元非线性函数,因此其参数的优化设计是一个多参量非线性规划问题^[2,3]。传统的多元优化方法要么容易陷入局部最优,要么计算量浩大,都很难解决这类问题。因此,研究一种气体激光器参数全局优化设计方法尤为重要^[1~3]。

近年来,人工智能(AI)信息处理技术蓬勃发展,其中一个研究热点是人工神经网络(ANN)和遗

收稿日期: 2009-06-26; 收到修改稿日期: 2009-08-24

基金项目: 国防科技大学优秀研究生创新资助项目(B090703)资助课题。

作者简介: 肖光宗(1983—),男,博士研究生,主要从事新型激光器方面的研究。E-mail: xiaoguangzong@163.com

导师简介: 龙兴武(1958—),男,博士,教授,主要从事激光与光电子技术等方面的研究。E-mail: xwlong110@sina.com

传算法(GA)的结合,可用于模糊系统的多参量非线性优化问题^[4~6]。已有文献将遗传算法应用于激光器的研究和设计中^[2,3,7~9]。文献[2]以激光器输出功率的近似公式作为目标函数,较好地实现了全局优化,但由于该公式做了较多简化和近似,反映的激光器参数不够全面,因此优化结果与激光器的实际工作状态可能存在一定偏差。而激光器输出功率函数的精确数学解析式确是很难得到,这就制约了激光器参数全局优化效果的进一步提高。因此,亟待建立激光器输出功率的精确模型。

本文提出了一种新颖的基于人工神经网络和遗传算法相结合的激光器参数全局优化方法。以平凹腔单横模氦氖激光器为例,采用人工神经网络建立输出功率模型,逼近激光器参数对输出功率的综合影响机理,进而以该网络的输出结果作为目标函数,采用遗传算法实现了气体激光器参数的全局优化设计。

2 激光器参数全局优化方法

人工神经网络由大量的人工神经元通过适当的方式互连构成,是一个大规模的非线性自适应系统。反向传播(BP)网络是人工神经网络中应用最为广泛的一种^[4,10]。本文选用BP网络建立激光器输出功率的人工神经网络模型。

BP网络一般由输入层、输出层和隐含层(可以为一层或多层)组成。只具有一个隐含层的简单BP网络结构示意图如图1所示。图中*i,j,k*层分别为输入层、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, P_m 为输入矢量, T_n 为输出矢量, w_{ij} 和 w_{jk} 为权值,虚线表示

误差传播途径。




图1 具有一个隐含层的BP网络结构示意图

Fig.1 Schematic diagram of a simple BP network

函数逼近是神经网络的典型应用,理论上可以通过训练和学习建立任意函数的神经网络模型。因此,建立激光器输出功率的神经网络模型不啻是精确逼近输出功率函数的一条新颖而有效的途径。

遗传算法是 John H. Holland 根据生物进化的模型提出的一种有别于传统方法的优化算法,它能够在复杂空间进行全局优化搜索,具有较强的稳健性^[4~6]。遗传算法的一个重要特点是它只需知道目标函数,而不需了解问题本身的内部机理,对于待寻优目标函数的形式基本无限制。因此,以神经网络模型作为目标函数,就可以采用遗传算法实现激光器参数的全局优化设计了。

总结起来,基于人工神经网络和遗传算法的激光器参数的全局优化方法的主要步骤如图2所示。图中,虚线左边的部分为建立激光器输出功率的人工神经网络模型;虚线右边的部分则利用该神经网络

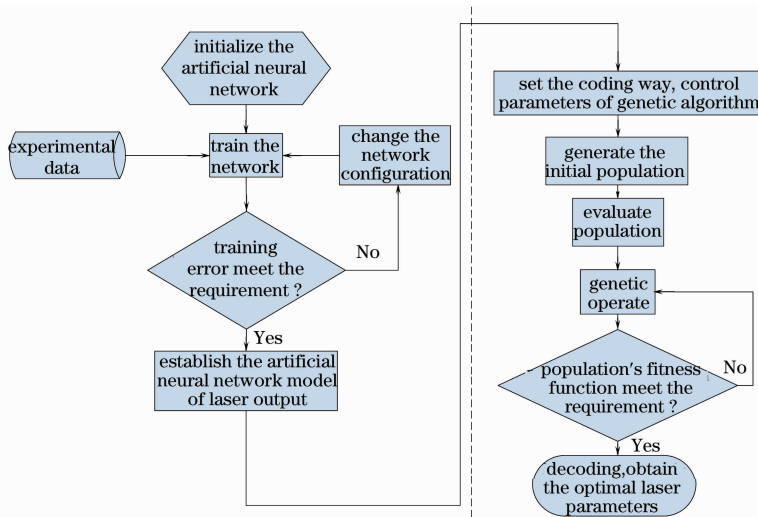


图2 激光器参数全局优化流程图

Fig.2 Flow chart of laser parameter global optimization method

络模型作为遗传算法的目标函数对激光器参数进行全局寻优。

3 激光器输出功率的人工神经网络模型

虽然人们已经对 BP 网络做了大量的研究工作,但至今没有一套通用的理论和公式来指导 BP 网络结构参数的选择。一般先根据实际问题的具体情况创建初步的 BP 网络模型,然后根据训练误差不断地调整网络结构参数,最终确定网络模型。这种确定神经网络的方法也称为“实验试凑法”。

3.1 人工神经网络的初步创建

人工神经网络的初步创建包括确定输入矢量、输出矢量、隐含层数、各层神经元数、激活函数和权值初始化等。

影响激光器输出功率的参数主要有放电毛细管内径 d 和长度 l , 输出腔镜的反射率 r 和曲率半径 ρ , 增益气体的充气总压强(以下简称“气压”) p , 充气配比(以下简称“气比”) η 和放电电流 i 等, 以上 7 个参数作为输入矢量 $\mathbf{P} = [d, l, r, \rho, p, \eta, i]$, 输出功率 W 作为输出矢量 $\mathbf{T} = [W]$, 因此输入层设置为 7 个神经元, 输出层设置为 1 个神经元。

BP 网络隐含层的层数及其神经元数的设计是建立神经网络的关键。理论已经证明, 任意一个连续函数都可以只有一个隐含层的网络以任意精度进行逼近; 具有两个隐含层的网络可以输出任意的连续函数^[10]。经过大量实践, 人们归纳了如下经验: 对任何实际问题首先只用一个隐含层; 隐含层使用尽量少的神经元数; 不断增加隐含层的神经元, 直到获得满意性能为止, 否则再考虑用两个隐含层。因此, 初步创建网络时首先考虑只选一个隐含层。

隐含层神经元数的初始值可以使用金字塔规则来确定^[4]。在该规则中, 当只有一个隐含层时, 若输入层、输出层神经元数分别为 M 和 N , 则隐含层神经元数为

$$L = \sqrt{MN}, \quad (1)$$

式中输入层神经元 $M = 7$, 输出层神经元数 $N = 1$, 根据(1)式可将隐含层神经元数初始值设为 $L = 3$ 。这样就初步创建了 $7 \times 3 \times 1$ 型 BP 网络。

BP 网络的隐含层的激活函数一般选择 S 型激活函数 tansig , 输出层一般选择线性激活函数 purelin 。由于系统是非线性的, 初始权值 w 和偏差 b 对于学习是否能达到局部最小, 是否能够收敛以

及训练时间的长短的关系很大。一般总是希望经过初始加权后的每个神经元的输入值都接近于 0, 这样可以保证每个神经元的权值都能够在它们的 S 型激活函数变化最大之处进行调节, 所以初始权值和偏差一般均取为 $(-1, 1)$ 之间的随机数^[11]。

3.2 人工神经网络的训练与建立

3.2.1 训练样本数据的预处理

训练样本数据的预处理包括实验数据的选取和标准化^[12]。实验数据的选取主要考虑两个方面。一方面, 训练样本要能涵盖不同参数情况的激光器, 另一方面要剔除无效实验数据。

实验数据的标准化是指网络的输入、输出数值变量都要限制在 $0 \sim 1$ 或 $-1 \sim 1$ 。对 BP 网络的激活函数 tansig , 标准化后可防止因输入量过大而使神经元输出饱和, 继而使权值调整进入误差曲面的平坦区。另一方面, 标准化也会使数据与计量单位无关^[4]。

实验数据的标准化方法为: 当输入和输出矢量的各分量量纲不同时, 应对不同分量在取值范围内分别进行标准化; 当各分量物理意义相同, 且为同一个量纲时, 应在整个数据范围内确定最大值 x_{\max} 和最小值 x_{\min} , 并进行统一的变化处理。将输入输出数据变换为 $[0, 1]$ 区间的值, 常用的变换公式为

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (2)$$

式中 x_i 为输入或输出数据。

3.2.2 网络的训练与建立

对于激光器输出功率这样并不算复杂的问题来说, 其 BP 神经网络模型一般是收敛的。但网络的训练中可能存在收敛速度慢的问题, 这时就必须增加网络的复杂性, 或增加训练时间^[4, 12]。激光器输出功率的人工神经网络模型没有实时性要求, 但对精度有较高要求, 因此在采用“实验试凑法”确定网络结构时, 可适当增加隐含层个数和神经元数, 牺牲训练时间, 追求高的仿真精度。

对实验室现有的 5 支不同参数的平凹腔基横模氦氖激光器, 改变放电条件, 放电电流分别设置为 2.5, 3.0, 3.5, 4.0, 4.5, 5.0, 6.0 和 7.0 mA, 气压分别设置为 266.6, 333.25, 399.9, 466.65, 533.2, 599.85, 666.5, 733.15 和 799.8 Pa, 气比分别设置为 3:1, 5:1, 7:1, 9:1, 10:1, 12:1, 15:1 和 16:1, 分别测量它们的输出功率, 按照 3.2.1 节中的方法对实验数据进行预处理, 然后将其作为训练样本, 采用带有附加动量法和自适应的梯度下降法, 对 3.1 节中初步创建的网络进行训练, 根据训练效果改变网络

层数和每层神经元数目训练网络。

实验中激光器输出功率的测量精度为 0.01 mW , 将训练样本输出值与网络输出值的均方根误差称为“训练误差”, 目标设置为 0.015 mW 。训练中发现当达到一定训练次数后训练误差变化非常缓慢, 趋于收敛。将一组没有参加网络训练的实验数据作为检验样本, 利用训练后的网络进行仿真, 计算出网络输出值与实验数据之间的均方根误差, 称为“检验误差”, 用以评价网络的逼近精度和泛化能力^[11]。不同结构的网络训练结果如表 1 所示。

表 1 网络训练结果

Table 1 Training results for different net configurations

L	Training error /mW	Testing error /mW
3	0.023	0.025
4	0.027	0.026
5	0.018	0.015
6	0.014	0.016
7	0.013	0.014
2,5	0.015	0.018
5,2	0.014	0.017
8	0.012	0.016
9	0.012	0.018

从表 1 可见, 初始创建的网络隐含层神经元数目为 3 时训练误差较大, 当神经元数目增加到 5 时网络

性能有明显改善, 神经元数目增加到 6 以后训练误差均小于 0.015 mW , 满足误差要求。若将 7 个神经元分为两个隐含层, 神经元数分别为 2 和 5, 训练误差变化不大, 但检验误差却比单个隐含层时大很多。此外, 与单个隐含层神经元数为 7 时比较, 当神经元数为 8 和 9 时, 训练误差较小, 但检验误差却较大。这说明增加神经元数或增加隐含层数都将增加网络的复杂程度, 过于复杂的网络将通过学习记住训练样本的特殊信息或噪声, 使得训练误差很小, 但网络的泛化能力大大降低, 检验误差就较大。因此, 综合考虑训练误差和检验误差, 选择 $7 \times 7 \times 1$ 型 BP 网络。

3.3 仿真与分析

利用训练后的神经网络, 对现有的一支激光器的输出功率进行仿真。激光器的结构参数为: 长度为 28 cm , 毛细管直径为 0.12 cm , 球面镜曲率半径为 1 m , 输出镜反射率为 98.8% 。气比设置为 $15:1$, 放电电流分别设置为 $3.0, 3.5, 4.0, 4.5$ 和 5.0 mA , 气压分别设置为 $266.6, 333.25, 399.9, 466.65, 533.2, 599.85, 666.5, 733.15$ 和 799.8 Pa 。仿真数据和实验数据如表 2 所示, 输出功率 W 分为实验数据 W_E 和仿真数据 W_S , 检验误差为 0.0127 mW , 仿真效果较好。

表 2 仿真数据与实验数据

Table 2 Comparison between simulation data and experimental data

p / Pa	$i=3.0 \text{ mA}$		$i=3.5 \text{ mA}$		$i=4.0 \text{ mA}$		$i=4.5 \text{ mA}$		$i=5.0 \text{ mA}$	
	W_E / mW	W_S / mW	W_E / mW	W_S / mW	W_E / mW	W_S / mW	W_E / mW	W_S / mW	W_E / mW	W_S / mW
799.80	3.36	3.49	3.36	3.41	3.34	3.31	3.16	3.16	2.84	2.95
733.15	3.62	3.69	3.72	3.67	3.72	3.62	3.68	3.53	3.48	3.40
666.50	3.86	3.86	3.98	3.89	4.02	3.90	4.04	3.87	3.96	3.81
599.85	4.04	3.99	4.20	4.08	4.26	4.13	4.28	4.16	4.20	4.16
533.20	4.08	4.11	4.32	4.25	4.42	4.35	4.48	4.42	4.40	4.45
466.65	4.26	4.18	4.46	4.40	4.62	4.55	4.76	4.65	4.80	4.72
399.90	4.16	4.13	4.46	4.43	4.66	4.65	4.82	4.81	4.94	4.92
333.25	3.92	3.78	4.32	4.17	4.60	4.49	4.78	4.74	4.90	4.91
266.60	3.14	3.11	3.54	3.51	3.90	3.90	4.16	4.23	4.40	4.49




图 3 输出功率随放电电流的变化曲线

Fig. 3 Relation between the output power and discharging current




图 4 输出功率随气压的变化曲线

Fig. 4 Relation between the output power and gas pressure


利用训练后的神经网络仿真输出功率随放电电流和气压的变化规律,激光器参数设置为: $l=28\text{ cm}$, $d=0.12\text{ cm}$, $\rho=1\text{ m}$, $r=98\%$, $\eta=12:1$ 。图 3 为输出功率随放电电流的变化曲线,气压为 466.55 Pa 。图 4 为输出功率随气压变化的曲线,放电电流为 4 mA 。两图中 * 点为实验数据点,实线为仿真曲线。从两图看,实验数据点均匀地分布在仿真曲线附近,与仿真曲线符合得较好。

4 遗传算法用于激光器参数全局优化

遗传算法用于激光器参数全局优化的基本步骤如图 2 中虚线右边部分所示。其中基因数目即为待求解问题的参数个数,基因编码长度取决于求解精度,主要的编码方式有二进制编码、格雷码编码、符号编码、浮点数编码和多参数级联编码等。遗传算法的控制参数包括群体规模、交叉概率、变异概率、循环代数 and 计算结束条件等。群体规模是种群中个体的数目,它的大小直接影响到遗传算法的收敛性和计算效率。交叉概率控制着交叉操作被使用的频度;变异概率控制着变异操作被使用的频度。计算每个个体的目标函数值时,首先将每个个体译码到问题空间,然后用第 3 节中已经训练好的神经网络模型来计算每个个体对应的激光器输出功率,即为目标函数值^[4,7~9]。

4.1 激光器待优化参数的选取及取值范围设置

建立的激光器输出功率的神经网络共有 7 个输入参数,其中定义 $\beta = \rho/l$ 为腔结构参数,它是一个非常重要的参量。对于确定长度的基横模激光器,腔结构参数决定了它的毛细管直径和凹面镜曲率半径。它与激光器的输出功率、光束发散角和调整精度等 3 个指标都有着密切的关系^[1]。根据对这 3 个指标的要求选定一个合适的 β 值范围,并由此确定凹面镜的曲率半径 ρ 的范围和毛细管直径 d 的范围。



激光器的平面镜一般作为全反镜,凹面镜一般作为输出镜,前者的反射率尽可能接近 100% ,现有的镀膜水平可以达到 99.9999% ,输出镜的反射率范围可设定为 $0\sim97\%$ 。放电条件可以设置较宽的范围,根据经验,气压范围设置为 $1\sim1333\text{ Pa}$,气比范围设置为 $3:1\sim15:1$,放电电流范围设置为 $2\sim10\text{ mA}$ 。

4.2 优化结果与分析

利用本方法对基横模激光器参数进行全局优化,以获得最大输出功率。激光器规格要求为:毛细管长度 42 cm ,腔结构参数为 $2.0\sim6.0$ 。为了使激光器可靠地工作在基横模上,且该横模的衍射损耗又能保持在较低值,根据腔结构参数定义和经验公式可得凹面镜的曲率半径 ρ 的范围为 $0.84\sim2.52\text{ m}$,毛细管直径 d 的范围为 $1.371\sim1.533\text{ mm}$,其他参数范围如 4.1 节所述,这些数值范围都将按照 3.2.1 节中所述的预处理方法进行标准化处理后作为遗传算法中的变量范围。

由于待优化参数有 6 个,遗传算法中的基因数目设置为 6,采用常用的格雷码编码方式,考虑到求解精度要求,基因编码长度设置为 20。由于遗传算法的控制参数关系到算法的优化效果和收敛速度,可先初始设置这些参数,然后再根据优化情况仔细调试,直至达到较好的效果。遗传算法的控制参数先初始设置为:种群规模为 50,选择概率采用轮盘赌方法,交叉概率为 0.9,变异概率为 0.015,迭代次数为 100。

实验室已有的两支毛细管长度为 42 cm 的激光器参数和它们的最大输出功率如表 3 所示,分别将它们的参数作为初始种群各参数的平均值,利用遗传算法进行全局优化时随着迭代次数的增加,各代群体的目标函数平均值的变化情况如图 5 所示,图 5(a)和(b)中的直线分别表示实验室激光器的输

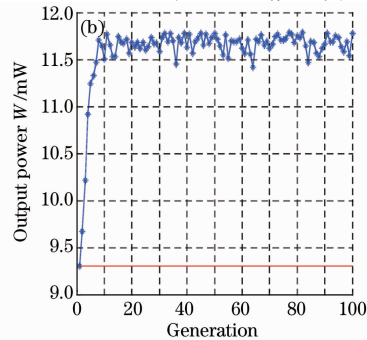


图 5 输出功率随遗传代数的变化

Fig. 5 Variation of output power with the generation

出功率。两次运行的全局优化结果如表 3 所示。

由图 5 可见,随着迭代次数的增加,各代个体相应参数的激光器输出功率快速收敛,最后逼近于一

最大功率。由表 3 可见虽然两次运行时初始种群不同,但优化结果(包括最优激光器参数和输出功率)比较接近,说明该优化方法的合理性和可重复性。

表 3 优化计算结果和实验数据对比

Table 3 Optimized results and experimental results

	d/mm	$r/\%$	ρ/m	p/pa	η	i/mA	W/mW
Experimental data	1.2	99.7	2	533.2	7:1	5	9.36
	1.2	98.5	2	666.5	7:1	6	8.75
Optimized data	1.47	98.93	2.12	479.50	11.82:1	5.44	11.79
	1.39	98.89	2.20	478.68	11.80:1	5.43	11.82

由图 5 和表 3 可见,经过参数全局优化后的激光器预期输出功率比实验室已有相同毛细管长度的激光器要大,这说明该方法可以提高激光器输出功率,其优化结果具有实际意义。

5 结 论

提出了一种新颖的激光器参数全局优化方法,将人工神经网络和遗传算法相结合应用于激光器参数的全局优化设计中,对激光器的设计和生产有一定的参考意义。

利用神经网络建立了激光器输出功率模型,该模型由于采用激光器的实验数据建模,与以往的半经验半理论公式相比,一方面它能更好地逼近激光器各参数对输出功率的影响机制,另一方面该模型也可反映激光器的加工工艺。计算结果表明,激光器输出功率的神经网络模型检验误差为 0.0127 mW,效果较好;采用本方法优化设计的激光器预期输出功率比类似参数的激光器高。

该方法尚存在一些需要改进的地方。神经网络输入矢量中放电条件(即放电电流、气压和气比等)的相关实验数据容易获取,数据量充足。但谐振腔参数的相关实验数据受激光器加工条件和激光器数量限制,较难获取,虽然搜集了实验室多年的相关数据记录,但仍然不够全面和充足,因此本模型对谐振腔参数的仿真效果可能略差。对于专业设计和生产激光器的厂家可以不断地丰富实验数据,训练神经网络,使之达到更好的仿真效果。另一方面,遗传算法的效率有赖于控制参数的设计,本文中只是应用了常用的参数设置,有待进一步研究和改善。表 3 中的优化结果,与现有的激光器比输出功率确实有较大改善,但限于实验条件没有按优化结果加工激光器以验证其实际优化效果。

参 考 文 献

- 1 Ma Yangwu, Chen Yuqing. The Laser Device[M]. Hangzhou: Zhejiang University Press, 1994. 9~39
马养武,陈钰清. 激光器件[M]. 杭州:浙江大学出版社, 1994. 9~39
- 2 Xu Zhijun, Cheng Cheng. Application of a genetic algorithm to a design of a laser resonator with single mode[J]. *Acta Photonica Sinica*, 2003, **32**(12): 1413~1417
徐志君,程 成. 遗传算法在激光器谐振腔优化设计中的应用[J]. *光子学报*, 2003, **32**(12): 1413~1417
- 3 Cheng Cheng, He Sailing. A global optimization and design of a copper vapor laser with 100 W order for obtaining maximum output[J]. *Acta Optica Sinica*, 2001, **21**(3): 278~282
程 成,何赛灵. 百瓦级铜蒸气激光器最大功率的全局优化设计[J]. *光学学报*, 2001, **21**(3): 278~282
- 4 Wang Xue. Measurement Intelligent Information Processing [M]. Beijing: Tsinghua University Press, 2008. 78~91
王 雪. 测试智能信息处理[M]. 北京:清华大学出版社, 2008. 78~91
- 5 D. E. Goldberg. Genetic Algorithms in Search, Optimization, and Machine Learning[M]. New York: Addison Wesley, 1989. 1~145
- 6 R. L. Haupt. An introduction to genetic algorithm for electromagnetic[J]. *IEEE Antenna and Propagation Magazine*, 1995, **37**(2): 7~15
- 7 C. Cheng, S. L. He. Optical design for a copper laser system with a maximum power by using a genetic algorithm[J]. *Optical and Quant. Electron.*, 2001, **33**(1): 83~85
- 8 C. Cheng, F. Zhuang. Plasma kinetics mechanisms of an optimized copper vapor laser[J]. *J. Phys. D: Appl. Phys.*, 2000, **33**(10): 339~341
- 9 M. J. Withford, D. J. Brown, J. A. Piper. Optimization of He-Ne buffer gas mixtures for copper vapor lasers[J]. *IEEE J. Quantum Electron.*, 1996, **32**(8): 1310~1315
- 10 Wang Yunsong, Xu Hongguo. Fast convergent algorithm BP for training neural network[J]. *J. Jilin University (Engineering and Technology Edition)*, 2003, **33**(4): 79~84
王贇松,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
- 11 Cong Shuang. The Theory and Application of Neural Network Based on Matlab Toolbox[M]. Hefei: University of Science and Technology of China Press, 2003. 55~87
丛 爽. 面向 MATLAB 工具箱的神经网络理论与应用[M]. 合肥:中国科学技术大学出版社, 2003. 55~87
- 12 Liu Jun, Guo Quidong, Wang Yinhu. Optimizing the laser-cutting parameters by using improved artificial neural network[J]. *Laser Journal*, 2007, **28**(6): 80~81
刘 君,郭秋东,王银辉. 利用改进的人工神经网络优选激光切割工艺参数[J]. *激光杂志*, 2007, **28**(6): 80~81