

文章编号: 0258-7025(2010)07-1856-05

基于径向基函数神经网络的激光焊接熔池光强分布预测

张 健 杨 锐

(天津工程师范学院电子工程学院, 天津 300222)

摘要 激光焊接过程复杂, 影响因素众多, 许多参数难以量化。基于归一化的径向基函数神经网络, 采用非参数统计方法, 建立了激光焊接熔池在时间和空间上的光强分布模型。该神经网络采用高斯函数作为径向基函数。提出了定量评价该模型预测光强分布质量的方法, 并根据该评价方法, 对影响光强分布模型的重要参数进行优化选择。根据优化选择结果, 对两幅光强分布图形进行预测。通过预测图像与实测图像的对比证明, 该神经网络可有效预测激光焊接熔池的光强分布。

关键词 激光技术; 光强分布预测; 径向基函数神经网络; 非参数统计模型

中图分类号 TG456.7 文献标识码 A doi: 10.3788/CJL20103707.1856

Prediction on Light Intensity Distribution of Laser Welding Melt Pool Based on Radial Basis Function Neural Network

Zhang Jian Yang Rui

(Institute of Electronic Engineering, Tianjin University of Technology and Education, Tianjin 300222, China)

Abstract Laser welding is a complicated process, and quantitative analysis of this process is quite difficult. A non parametric statistical method of light intensity distribution modeling, based on normalized radial basis function neural network, is proposed to predict the spatiotemporal dynamics of surface optical activity in the laser welding process. This neural network adopts Gaussian function as radial basis function. A quantitative evaluation method for light intensity distribution of modeling quality is proposed. Parameters are optimized according to this evaluation method. Comparison of predicted images and testing images exhibits a good resemblance.

Key words laser technique; light intensity distribution prediction; radial basis function neural network; non parametric statistical model

1 引 言

激光焊接已广泛应用于工业加工领域^[1]。激光焊接参数的自动优化和调整, 是保证焊接质量的重要手段^[2]。然而, 激光焊接过程复杂, 影响焊接质量的因素众多, 许多参数难以量化^[3]。激光焊接时, 入射光功率密度的不均匀以及焊接过程中产生的等离子体, 会造成熔池光强分布的不均匀^[4], 使材料微组织间形成非均匀的温度场和热应力, 这是造成裂晶、裂纹、孔洞等缺陷的重要因素^[5]。近年来, 利用机器视觉技术直接观测焊接熔池, 通过图像处理获取熔

池特征信息, 建立焊接过程的实时传感与控制系统, 已成为重要的研究方向^[6~12]。本文基于归一化的径向基函数神经网络, 建立了激光焊接熔池在时间和空间上的光强分布模型。通过实时分析熔池表面的光强分布, 可以对各种焊接参数进行调整, 进而提高焊接质量^[13]。

2 神经网络的建立

径向基函数神经网络是具有独特结构的三层前向网络。输入层不处理信息, 只为隐藏层分配输入

收稿日期: 2009-09-04; 收到修改稿日期: 2009-10-23

基金项目: 天津市高校科技发展基金(20070809)资助课题。

作者简介: 张 健(1976—), 男, 博士, 副教授, 主要从事固体激光器及其应用等方面的研究。

E-mail: tjuzzjj@sina.com.cn

信息。隐藏层上每一神经元都代表一组径向基函数。径向基函数神经网络具有以下特点：1)是一种静态网络；2)与函数逼近理论相吻合；3)具有唯一最佳逼近点；4)网络连接权值与输出呈线性关系。

由于具有上述特点，径向基函数神经网络特别适用于多变量非线性函数的逼近、模式识别、自适应滤波等领域^[14]。

2.1 非参数统计模型

为描述熔池的光强分布，设 $\varphi = \varphi(s)$ ， $\varphi(s)$ 为时空点 s 的光强分布，而 $s = s(r, t)$ 是关于时间和空间的变量。通常，为求得光强分布，需要求解偏微分方程或积分差分方程。然而，实践中很难通过实验数据得到方程的解析解。为此，可设方程^[15]

$$\varphi(s) = \Psi\{\varphi[s' \in S(s)], \sigma\}, \quad (1)$$

式中 $\varphi(s' \in S)$ 代表已知时刻的光强分布； $\varphi(s)$ 代表未知时刻的光强分布； σ 是与实验条件相关的参数； S 代表变量 s 的采样域，变量 s 及其采样域 S 的时空关系如图 1 所示。所以，可根据(1)式由已知时刻的光强分布得出未知时刻的光强分布。




图 1 变量 s 与其采样域 S 的关系

Fig. 1 Relation between variate s and sampling domain S

$\varphi(s)$ 和 $\varphi(s' \in S)$ 可构成样本向量 $\mathbf{V}_i(s) = [\varphi_i(s), \varphi_i(s' \in S)]$ 。为分析方便，令： $x_i = \varphi_i(s')$ ， $y_i = \varphi_i(s)$ ，则 $\mathbf{V}_i(s) = (y_i, x_i)$ 。 \mathbf{V}_i 为随机变量，可得联合概率分布函数^[16]

$$f_N(\mathbf{V}) = \frac{1}{N} \sum_{i=1}^N \phi(\mathbf{V} - \mathbf{V}_i, \sigma), \quad (2)$$

式中 N 为样本向量个数， ϕ 为所有可接受的基函数，这里取高斯函数：

$\phi(x - x_i, \sigma) = \exp[-(x - x_i)^2 / (2\sigma)] / (\sqrt{2\pi}\sigma)$ ， σ 为函数的宽度参数，控制了函数的径向作用范围。为得到最佳的预测结果，均方预测误差应为最小

$$E[(y - \hat{y})^2 | x] = \min(\hat{y}). \quad (3)$$

由(2)，(3)式可得条件平均估计^[16]

$$\hat{y}(x) = \frac{\sum_{i=1}^N y_i \phi(x - x_i, \sigma)}{\sum_{j=1}^N \phi(x - x_j, \sigma)} = \sum_{i=1}^N y_i C_i(x). \quad (4)$$

由(4)式描述的条件平均估计，构造径向基函数神经网络， x 和 $\hat{y}(x)$ 分别是网络的输入和输出。因为 $\sum_{i=1}^N C_i(x) = 1$ ，所以该网络是归一化的径向基函数神经网络。

2.2 预测结果的质量

为定量评价该网络对光强分布的预测质量，引入参数 Q

$$Q = 1 - \frac{E[(\hat{y} - y)^2]}{E[(\hat{y} - \bar{y})^2] + E[(y - \bar{y})^2]}, \quad (5)$$

式中 \hat{y} 和 \bar{y} 分别代表预测和实测的光强分布平均值，即 $E[\hat{y}] = \bar{y}$ ， $E[y] = \bar{y}$ 。预测结果最佳时 $\hat{y} = y$ ，即 $Q = 1$ ；反之，若 \bar{y} 与 y 不相关，则 $Q = 0$ 。

2.3 训练及评价过程

训练及评价过程包括以下三步：

- 1) 学习，即构造样本向量： $[\varphi_i(s), \varphi_i(s' \in S)] = (y_i, x_i)$ ；
- 2) 根据(4)式预测 \hat{y} ；
- 3) 如果存在实测结果，根据(5)式评价上一步预测结果的质量。

3 熔池光强分布预测

3.1 试验设计

试验采用平均功率 2000 W 的 Nd:YAG 激光器；试件材料为不锈钢 1Cr18Ni9Ti；试件尺寸为 100 mm × 100 mm × 10 mm；保护气体为氩气 (Ar)。利用与光路同轴的监控系统获得熔池光强分布图像，如图 2 所示。采用 AOS Technologies 公司生产的 S-PRI F1 高速图像采集系统，图像分辨率为 32 pixel × 32 pixel，采样间隔 1 ms，共获取 1000 个图像。

根据试验条件， $\varphi[s(r, t)]$ 由二维空间变量 $\{(r_{x,i}, r_{y,j}) ; i = 1, \dots, 32, j = 1, \dots, 32\}$ 和一维时间变量 $\{t_k ; k = 1, \dots, 1000\}$ 确定。其中时间变量坐标为图片序号，实测与预测光强分布图像的空间坐标变量均为像素。为避免焊接过程产生的等离子体影响成像质量，采用对等离子体有较强透射能力的波长 830 nm 的半导体激光器作为辅助光源，对焊接熔池进行照射，并在光路中加入了波长 850 nm 的反射镜。由图 3 对比可见，这一措施可显著提高熔池成像质量，从图 3(b)中明显可见熔池光强分布的不均匀。




图 2 熔池光强采样系统

Fig. 2 Sampling system for melt pool light intensity




图 3 熔池成像效果对比。(a)不采用辅助光源;(b)采用辅助光源

Fig. 3 Contrast of melt pool images. (a) without auxiliary illuminant; (b) with auxiliary illuminant

试验采用前 800 张光强分布图像作为神经网络的输入,进行光强分布预测;采用后 200 张图像作为实测结果,并利用参数 Q 评价预测结果。

3.2 参数 σ 的优化选择

函数宽度参数 σ ,控制函数的径向作用范围,对 Q 值有重要影响,通过大量试验得出图 4 所示曲线。




图 4 σ 与预测质量的关系

Fig. 4 Dependence of prediction quality on the value of parameter σ

图 4 中学习样本数 $N = 800$,采样域 S 取相同的空间坐标,时间坐标仅取 t_{-1} (参见图 1)。 Q 值为相同条件下 10 次结果的平均值。从图 4 中可以看出 $\sigma \approx 4$ 时 Q 值最大, σ 进一步增大 Q 值反而略有降低。

这是由于:当 σ 较小时,与实测结果差别很小的那些输入对预测结果影响最大;而当 σ 较大时,差别较大的那些输入的累积影响使预测质量反而有所降低。

3.3 学习样本个数 N 的优化选择

对(4)式来说,神经网络预测过程的计算量随学习样本数 N 线性增长。为提高预测速度,应在不影响预测质量的前提下寻求 N 的最小值。通过大量试验得出图 5 所示曲线。




图 5 N 与预测质量的关系

Fig. 5 Dependence of prediction quality on the value of parameter N

图 5 中 S 的选取与图 4 相同, $\sigma = 4$, Q 值仍为 10 次结果的平均值。从图 5 可以看出:当 $N < 400$ 时, Q 随 N 的增大显著提高;当 $N > 600$ 时, Q 值的提高十分有限。

3.4 采样域 S 的优化选择

采样域 S 是由二维空间坐标和一维时间坐标决定的。 S 直接决定着预测过程的复杂程度和计算量,应在不影响预测质量的前提下寻求最简单的采样域。图 6 显示了在 15 种典型采样域下, Q 值的分布情况。

在各种情况下,均取 $\sigma = 4$, $N = 600$, Q 值仍为相同条件下 10 次结果的平均值。其中 1~6 采样域下仅选取一个时间点 t_{-1} ; 7~15 采样域下选取多个时间点。

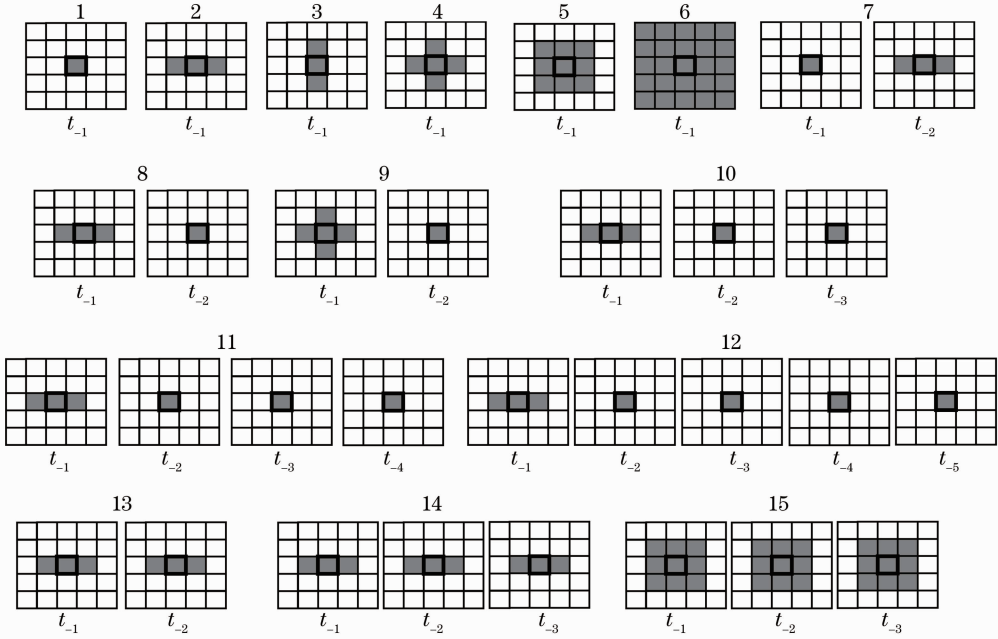



图 6 S 与预测质量的关系

Fig. 6 Dependence of prediction quality on the value of parameter S

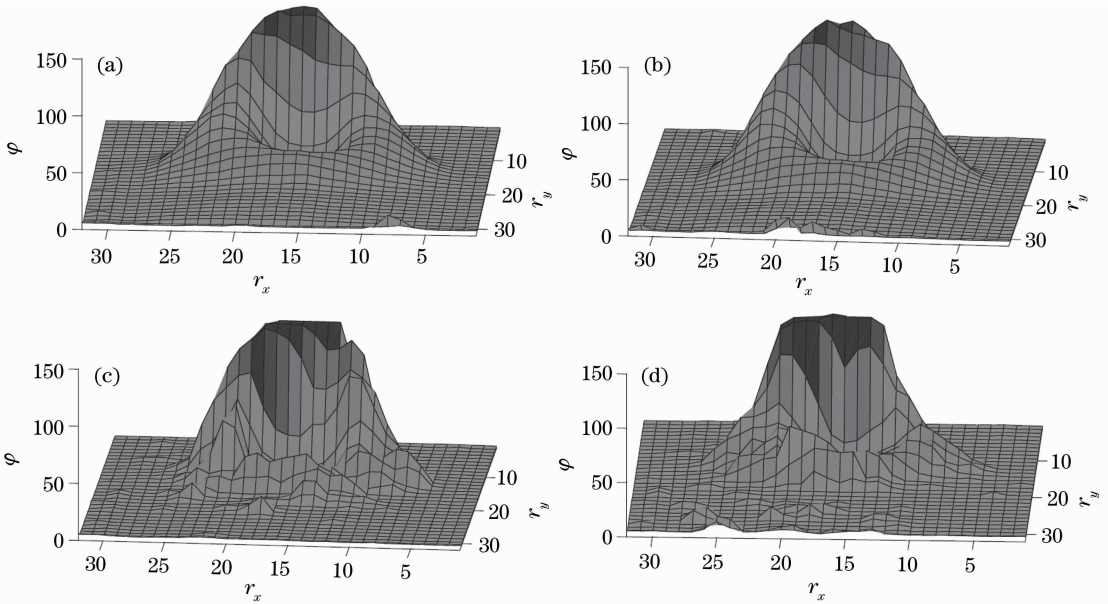


图 7 熔池光强分布预测

Fig. 7 Prediction of melt pool light intensity distribution

由图 6 可得出如下结论:

1) 时间采样点个数相同时, 空间采样点个数较少的 Q 值较高, 见图 6 中 1~6 和 7~9 的对比;

2) 对比图 6 中 1 和 7, 13 和 14 可知, 空间采样点相同时, 取两个时间点 t_{-1} 和 t_{-2} 的 Q 值较高。

3.5 熔池光强分布预测

为验证上述优化选择的有效性, 进行了光强分布图像的预测, 见图 7。其中(a), (c)为预测图像, (b), (d)为实测图像, r_x 和 r_y 为空间坐标变量, φ 为光强。

其中 $\sigma = 4$, $N = 600$, S 取图 6 中采样域 7。从图 7 可以看出, 该神经网络对激光焊接熔池的光强分布具有较强的预测能力。

4 结 论

基于归一化的径向基函数神经网络, 利用非参数统计方法建立了预测激光焊接熔池光强时空分布的模型。提出了定量化评价光强分布预测质量的方法。通过预测图像与实测图像的对比证明, 该神经网络可有效预测激光焊接熔池的光强分布。

参 考 文 献

- 1 Fu Yunchang, B. Martin, A. Loredo *et al.*. Velocity distribution of the powder particles in laser cladding[J]. *Chinese J. Lasers*, 2002, **B11**(6): 470~474
- 2 Qing Li, Youqing Wang. Kinetic modeling of a high power fast-axial-flow CO₂ laser with computational fluid dynamics method [J]. *Chin. Opt. Lett.*, 2008, **6**(7): 513~516
- 3 A. Klimpel, A. Lisiecki. Laser welding of butt joints of austenitic stainless steel AISI 321 [J]. *J. Achievements in Materials and Manufacturing Engineering*, 2007, **25**(1): 63~66
- 4 B. J. Aalderink, R. G. K. M. Aarts, J. B. Jonker *et al.*. Weld

- plume emissions during Nd:YAG laser welding[C]. *Proceedings of the Third International WLT-Conference on Lasers in Manufacturing*, 2005, Munich
- 5 Li Junchang, Li Xingyi, Chen Jingbo *et al.*. Discussion for the semi-infinite medium approximation and the thermal diffusion velocity in laser heat treatment[J]. *Chinese J. Lasers*, 1999, **B8**(4): 377~383
- 6 Wang Baoguang, He Zhonghai, Liao Yibai *et al.*. Study on calibration methods of structured light sensor[J]. *Chinese J. Lasers*, 2002, **B11**(3): 198~204
- 7 Chaoyang Han, Jianxun Li, Xiao Chen *et al.*. Real-time restoration of rotational blurred image using gradient-loading[J]. *Chin. Opt. Lett.*, 2008, **6**(5): 334~337
- 8 Teresa Sibillano, Antonio Ancona, Vincenzo Berardi *et al.*. A real-time spectroscopic sensor for monitoring laser welding processes[J]. *Sensors*, 2009, (9): 3376~3385
- 9 Akihiko Matsushita, Masahiro Yamanaka, Shun'ichi Kaneko *et al.*. Basic image measurement for laser welding robot motion control[J]. *Int. J. of Automation Technology*, 2009, **3**(2): 136~137
- 10 Tatiana Bernardon Silva, Mauro Antonio De Arruda Nobilo, Guilherme Elias Pessanha Henriques *et al.*. Influence of laser-welding and electroerosion on passive fit of implant-supported prosthesis[J]. *Stomatologija, Baltic Dental and Maxillofacial Journal*, 2008, **10**(3): 96~100
- 11 J. Bruncko, F. Uherek, M. Michalka. Monitoring of laser welding by optical emission spectroscopy [J]. *Laser Physics*, 2003, **13**(4): 669~673
- 12 M. Hyrcza-Michalska, J. Lisok, Sz. Sikorski. The analysis of plastic flow of laser welded tubes in the process of hydromechanical forming[J]. *Acta Metallurgica Slovaca*, 2007, **13**(2): 214~220
- 13 A. Zajac, D. Podniesinski, D. Kecik *et al.*. Real-time control procedures for laser welding of biological tissues[J]. *Technical Sciences*, 2008, **56**(2): 139~146
- 14 Yuannan Xu, Liping Liu, Yuan Zhao *et al.*. Hopfield neural network-based image restoration with adaptive mixed-norm regularization[J]. *Chin. Opt. Lett.*, 2009, **7**(8): 686~689
- 15 Lara Abbaschian, Milton Sergio Fernandes de Lima. Cracking susceptibility of aluminum alloys during laser welding [J]. *Materials Research*, 2003, **6**(2): 273~278
- 16 Igor Grabec. Extraction of physical laws from joint experimental data[J]. *Eur. Phys. J. B*, 2005, **48**(2): 279~289