

基于 MATLAB 图像处理的铸造表面粗糙度测量方法

邵长利

(哈尔滨理工大学 材料科学与工程学院, 黑龙江哈尔滨 150040)

摘要: 采用直接测量法测量铸造表面粗糙度时, 不仅操作繁琐, 而且仪器探头容易损坏。本文提出了一种基于BP神经网络模型为核心的模拟训练辨识方法, 建立了图像特征值与粗糙度的训练辨识关系。以铸铁试件为实验样本, 利用MATLAB对图像进行算法分析, 得出占空比和亮度比两个特征值, 推出特征值规律; 利用MATLAB中的BP神经网络模拟系统与粗糙度参数 R_a 进行对比。结果表明, 本方法试验结果较理想, 211次测试的粗糙度参数训练精度高达99.98%。

关键词: 表面粗糙度; 特征值; MATLAB

铸造表面粗糙度严重影响铸件的外观质量和使用性能, 表面粗糙度还影响机械设备配合性质的稳定性和动力的消耗, 而且表面越粗糙, 越容易产生噪声、振动等^[1-2]。所以, 控制和提高铸件表面粗糙度, 不仅能够有效提高铸件的外观质量、使用性能及其使用寿命^[3], 而且还可以降低生产成本, 从而提高铸造产品的经济效益。

表面粗糙度作为应用较为广泛的零件表面特性参数^[4], 其测量方法目前主要分为两类: 第一类包括触针法, 光切法、样块对比法等需要对试件表面进行实际测量; 第二类是建立理想的理论模型, 比如计算机视觉法。近几年利用神经网络作为辨识模型的方法层出不穷, 着重研究提取图像特征值, 利用特征参数与粗糙度系数之间建立辨识模型^[5-6], 有效避免了像直接测量法的触针法触针易磨损, 操作繁琐, 还有可能损伤铸件表面等缺点。

本研究采用了计算机视觉分析方法, 提出了基于MATLAB辨识神经网络的模拟训练方法。

1 图像识别表面粗糙辨识方法建立

1.1 试样样本测量

利用XD30M高级倒置金相显微镜对图1所示的铸铁样块表面进行显微拍摄, 获取的图像如图2所示。采用TR200型粗糙度测量仪, 分别对9件铸铁样块表面进行粗糙度测量。测量时, 随机选取表面三个位置进行 R_a 测量, 测量数据如表1所示。

1.2 表面粗糙度图像预处理

对于图像的预处理采用的最常用的方式是Gauss-Laplace 变换^[7]。图像在产生和传输过程, 不可避免地会产生噪声, 所以要对图像进行滤波处理。本文采用的滤波方式是高斯滤波, 因为在计算机视觉分析中, 高斯滤波较为常用^[8-9]。高斯滤波是一种平滑滤波, 用于得到信噪比SNR较高的图像(反应真实信号), 适用于消除图像信号在接收过程中产生的噪声, 其主要思想是对整幅图像进行加权平均, 对于图像上的每一点像素值都由周围的像素值加权平均得到。运用的高斯公式是采用公式(1):

作者简介:

邵长利(1993-), 男, 硕士研究生, 主要从事铸造表面粗糙度研究。E-mail: 18845153150@163.com

中图分类号: TG247

文献标识码: A

文章编号: 1001-4977(2019)04-0372-06

收稿日期:

2018-11-30。

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (1)$$

Gauss滤波后,接下来进行的就Laplace变换。由于图像在边缘部位不清晰,为后续的特征采集带来不便,所以需要进行Laplace锐化处理。拉普拉斯锐化主要思想是求二阶导矢,用二阶导的过零点确定边缘^[10]。如果在图像中一个比较暗的区域中出现了一个亮点,那么用拉普拉斯锐化就会使这个亮点变得更亮。对于数字图像,采用的拉普拉斯算子可以简化为:

$$g(i, j) = 4f(i, j) - f(i+1, j) - f(i-1, j) - f(i, j+1) - f(i, j-1) \quad (2)$$

卷积的形式为:

$$g(i, j) = \sum_{k=1}^k \sum_{l=1}^l f(i-r, j-s) H(r, s) \quad (3)$$

经过Gauss-Laplace变换的图像如图3所示。

1.3 特征参数提取

1.3.1 占空比特征提取

为了获得图像的特征参数,需要对锐化后图像进行二值化处理^[11]。二值化的原理是将图像上的点的灰度值置为0和255,使图像呈现明显的黑白效果。二值化处理需要设置一个阈值,阈值的选取采用Otsu算法(大律法)^[12-13],基本思想是用某一假想T将图像的灰度分为两组,当两组的类间方差最大时,灰度T为图像的最佳阈值。经过锐化的图像的像素值在阈值以上的越多,表明图像越粗糙,也就是白点数量越多。如图4所示,9组二值化图像较锐化后图像的细节更加清楚,黑白更加明显。为了后期训练模型输入参数更简单,设置占空比特征值为自定义函数: $x=b/a$, 式中 x 为占空比, b 为二值化处理后白像素点数, a 为总像素点数。

1.3.2 亮度比特征值提取

对于一张 $m \times n$ 图像的像素点, x 为 $0, 1, 2, \dots, m-1$; y 为 $0, 1, 2, \dots, n-1$ 。从空域转换到频域更有利于提取图像的纹理特征,还受噪声的影响,本文采用的傅里叶变换是属于谐波分析^[14],从而利用(4)式和(5)、(6)式对预处理图像进行傅里叶频率变换。

$$f(u, v) = \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x, y) \exp[-j2\pi(ux+vy)] \quad (4)$$

$$F(u, v) = R(u, v) + jI(u, v) \quad (5)$$

频谱公式为

$$|F(u, v)| = [R^2(u, v) + I^2(u, v)]^{\frac{1}{2}} \quad (6)$$

$F(u, v)$ 中的 $R(u, v)$ 为实部, $I(u, v)$ 为虚部频率谱图就是图像梯度的分布图,但是频率谱图中的各点与原图像的各点并不存在一一对应关系。如图5所示,频率谱图分为高频区和低频区。低频区是指图像中变化较缓慢的像素区,如变化不明显的背景区

域;高频区指灰度变化较剧烈的像素区,如边缘和噪声等。中心灰度变化更加剧烈,相应的频谱中高频分量较强,但整体还是低频区域更多,毕竟背景无变化的黑色区都属于低频。

从频率谱图中可以看出,白点从中心向四周扩散,因为图像粗糙度变化越快,灰度变化越剧烈,高频部分占的比重越大,那么频率谱中白点的像素值就越大。因为整张图亮度值过于庞大,不利于计算,设置亮度比公式 $y=c/z$, 式中 y 为亮度比, c 为频率谱中白点亮度的总数, z 为整张频率谱的亮度总数。

1.4 BP神经网络训练

BP神经网络是通过大量的神经元或节点互连组




图1 铸铁样块

Fig. 1 Cast iron testing piece




图2 原始铸件表面图像

Fig. 2 Original surface image of the testing piece

表1 铸件粗糙度测试数据
Table 1 Surface roughness of nine testing pieces

试验编号	粗糙度 $R_a/\mu\text{m}$			均值/ μm
1	0.323	0.529	0.252	0.368
2	4.198	3.852	4.590	4.21
3	6.219	5.331	3.326	4.95
4	5.412	3.793	5.985	5.06
5	4.675	5.657	5.208	5.18
6	5.287	5.428	5.392	5.36
7	6.640	4.937	6.199	5.62
8	5.835	6.034	6.196	6.02
9	6.590	6.119	5.671	6.12

成,能并行处理信息的非线性系统,具有良好的学习能力^[15]。BP神经网络具有逼近任意有界连续非线性函数的能力,而且网络的中间层数、各层的处理单元数及网络的学习系数等参数可根据具体情况设定,灵活性很大,是一种按误差逆传播算法训练的多层前馈网络,是目前应用最广泛的神经网络模型之一。BP神经网络整体结构如图6所示,包括一个输入层,一个或多个隐含层和一个输出层。算法包括正向传播过程和误差反向传播过程,其中正向传播过程是向输入层输入样本,经过隐含层处理,根据权值和阈值计算每个单元的实际输出值,若实际输出值和期望值在误差范围内,则学习过程结束,如果在误差范围以外,则继续进行学习。反向传播法是反向通过网络误差调节权重,根据实际输出值和期望值修改权值权重,以减小神经网络的误差。

对于本文的输入层和输出层神经元的数目很容易确定,输入层神经元由占空比和亮度比两个特征值个数决定,输出神经元对应粗糙度参数 Ra 。

采用的神经网络训练函数newff如下所示:

```
net=newff([1 9],[2 1],{'tansig','tansig'},
'trainlm');
```

```
net.trainParam.epochs = 1000; %训练的最大次数;
```

```
net.trainParam.goal = 0.05; %全局最小误差。
```

其中隐含层和输出层采用tansig函数,输入层采用trainlm函数得到的效果图逼近效果最好。

2 试验结果分析

将9个试验样块的原始表面图像进行特征值提取得到占空比曲线图7和亮度比曲线图8,由两图中可以看出,占空比随着粗糙度 Ra 值的升高而下降,而亮度比则呈上升趋势。将图中占空比和亮度比数值作为输入参数进行BP神经网络训练,训练结果见图9和图10。

由图9和图10训练结果可知,训练次数为211次,模拟结果 Ra 与原 Ra 重合度较高。

$$\text{训练精度} = 1 - \frac{1}{9} \sum_{i=1}^9 \frac{|\text{模拟}R_{ai} - R_{ai}|}{\text{模拟}R_{ai}} = 99.98\%$$




图3 不同粗糙度表面经Gauss-Laplace变换后图像

Fig. 3 Gauss-Laplace transformation images of the surfaces with different roughnesses




图4 不同粗糙度表面的二值化图像

Fig. 4 Binarized images of the surfaces with different roughnesses




图5 不同粗糙度表面的频率谱图

Fig. 5 Frequency spectrums of the surfaces with different roughnesses

式中：模拟 R_{ai} 为试验数据中第*i*个模拟训练值， R_{ai} 为试验数据中第*i*个实测数据。

表2给出了模拟 Ra 值与实测 Ra 值的对比情况。由表2可知，误差百分比都低于0.05%，训练精度高达99.98%。所以本文粗糙度三维测量方法可行。在实际应用中，模拟 Ra 与实际 Ra 或多或少会有一些偏差，对于铸件表面的特征值提取计算也会更加复杂，MATLAB神经网络训练难度也会增大，训练次数也会有所增加。显然，其特征值差别越大，训练效果越好。




图7 占空比曲线
Fig. 7 Duty cycle curve




图6 BP神经网络模型
Fig. 6 BP neural network model




图8 亮度比曲线
Fig. 8 Brightness ratio curve




图9 Ra 训练模拟预测结果
Fig. 9 Ra training simulation prediction results




图10 模拟训练次数
Fig. 10 Number of simulated training

表2 模拟 Ra 对比表
Table 2 Simulated Ra contrast table

试验编号 <i>i</i>	模拟 R_{ai}	R_{ai}	误差值	误差百分比/%
1	0.37	0.368	0.002	0.05
2	4.22	4.21	0.01	0.023
3	4.94	4.95	0.01	0.02
4	5.05	5.06	0.01	0.01
5	5.18	5.18	0	0
6	5.30	5.36	0.06	0.01
7	5.95	5.62	0.33	0.05
8	6.00	6.02	0.02	0.03
9	6.12	6.12	0	0

3 结论

通过对样块图像进行两种特征值提取,一方面通过高斯滤波,拉普拉斯锐化等一系列处理获得特征值占空比 x ,另一方面通过频率谱变换获得亮度比 y ,得出

的数值与粗糙度值进行比较,得出普遍规律,再通过BP神经网络训练,推导出的误差值低于0.05%,训练精度高达99.98%,表明此MATLAB图像处理方法可行。

参考文献:

- [1] 马先,刘建睿,李勉,等.耐火骨料粒度与粒形对铸件表面粗糙度的影响[J].特种铸造及有色合金,2013,33(4):312-315.
- [2] 王新节,王维.消失模铸件表面粗糙度的测量与分析[J].特种铸造及有色合金,2014,34(8):839-843.
- [3] 徐丹,项楠,魏斌.金属修复体表面粗糙度对其磨损性能的影响[J].上海口腔医学,2013,22(3):270-273.
- [4] 李伯奎.触针式三维粗糙度测量仪的开发及应用[J].润滑与密封,2006(4):140-142.
- [5] 杨春兰,浦昭邦,叶会英.新型光触针式表面粗糙度测量系统[J].宇航计测技术,1999,19(5):55-59.
- [6] 李晓梅.表面粗糙度模糊神经网络在线辨识模型[J].机械工程学报,2007,43(3):212-217.
- [7] 李振宗.铸造表面粗糙度及其测量方法的研讨[J].上海计量测试,1987,14(2):164-165.
- [8] 谭丞.基于联合概率密度判别器和神经网络技术的煤种辨识方

- 法[J].机械工程学报,2010,46(18):18-23.
- [9] 徐德衍,林尊琪.光学表面粗糙度研究的进展和方向[J].光学仪器,1996,18(1):32-37.
- [10] 田继成,丁志华,尹锦.测量表面粗糙度的新型光纤传感器[J].计量学报,1993,14(3):183-186.
- [11] 项阳,郭玉彬.一种检测超光滑表面粗糙度方法的初步研究[J].光散射学报,1996,8(3):168-173.
- [12] LEE B Y, JUAN H, YU S F. A study of computer vision for measuring surface roughness in the turning process[J]. International Journal of Advance Manufacturing Technology, 2002, 19: 295-301.
- [13] 尤政,田芋,章恩耀.光外差干涉全光纤表面粗糙度传感器的研究[J].光学技术,1994(6):45-47.
- [14] CHUNG L L, REINHORN A M, SOONG T T. Experiments on active control of seismic structures[J]. Journal of Engineering Mechanics, 1988, 114: 241-256.
- [15] 吴春亚,刘献礼,王玉景.机械加工表面粗糙度的图像检测方法[J].哈尔滨理工大学学报,2007,12(3):148-151.

Measuring Method of Surface Roughness of Casting Based on MATLAB Image Processing

SHAO Chang-li

(School of Materials Science and Engineering, Harbin University of Technology, Harbin 150040, Heilongjiang, China)

Abstract:

Aiming at the problems of cumbersome operation and easy damage of instrument probe when measuring the surface roughness of castings using direct measurement method, a simulation training identification method based on BP neural network model was proposed, and the training identification relationship between image eigenvalue and roughness was established. Taking nine cast iron test pieces as the experimental samples in this work, their surface images were analyzed by MATLAB so that two eigenvalues (duty cycle and brightness ratio) were obtained and then the rule of eigenvalue was deduced. The comparison between the simulation system of BP neural network in MATLAB and the roughness parameter R_a was made. The results showed that the training accuracy of the proposed method was as high as 99.98% via 211 times of testing training, with effective and satisfactory results.

Key words:

surface roughness; eigenvalue; MATLAB