

基于激光散斑成像的零件表面粗糙度建模

陈苏婷 胡海锋 张闯

Surface roughness modeling based on laser speckle imaging

Chen Su-Ting Hu Hai-Feng Zhang Chuang

引用信息 Citation: *Acta Physica Sinica*, 64, 234203 (2015) DOI: 10.7498/aps.64.234203

在线阅读 View online: <http://dx.doi.org/10.7498/aps.64.234203>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn/CN/Y2015/V64/I23>

---

您可能感兴趣的其他文章

Articles you may be interested in

基于指导滤波的图像盲复原算法

Guided filter-based blind image restoration method

物理学报.2015, 64(13): 134202 <http://dx.doi.org/10.7498/aps.64.134202>

基于尺度不变特征变换和区域互信息优化的多源遥感图像配准

Multi-source remote sensing image registration based on scale-invariant feature transform and optimization of regional mutual information

物理学报.2015, 64(12): 124204 <http://dx.doi.org/10.7498/aps.64.124204>

基于多相组重建的航空图像超分辨率算法

Super resolution of aerial image by means of polyphase components reconstruction

物理学报.2015, 64(11): 114208 <http://dx.doi.org/10.7498/aps.64.114208>

编码孔径光谱成像仪光学简化彗差对图谱反演误差分析

Analysis on the simplified optic coma effect on spectral image inversion of coded aperture spectral imager

物理学报.2015, 64(5): 054205 <http://dx.doi.org/10.7498/aps.64.054205>

目标跟踪中目标模型更新问题的半监督学习算法研究

Research on semi-supervising learning algorithm for target model updating in target tracking

物理学报.2015, 64(1): 014205 <http://dx.doi.org/10.7498/aps.64.014205>

# 基于激光散斑成像的零件表面粗糙度建模\*

陈苏婷<sup>1)†</sup> 胡海锋<sup>1)2)</sup> 张闯<sup>1)</sup>

1)(南京信息工程大学, 江苏省气象探测与信息处理重点实验室, 南京 210044)

2)(中国人民解放军 94654 部队, 南京 210046)

(2015年6月5日收到; 2015年7月16日收到修改稿)

表面粗糙度是衡量机械表面加工水平的重要参数. 通过构建一套激光散斑成像采集系统, 获取了不同表面加工类型和不同粗糙度值的零件表面激光散斑图像. 应用 Tamura 纹理特征理论提取图像的纹理粗糙度、对比度、方向度特征, 并分析了这三个特征与表面粗糙度的关系. 发现了纹理粗糙度特征与表面粗糙度的单调关系, 推导出平磨、外磨、研磨三种表面加工工艺的粗糙度值与图像纹理粗糙度特征的数学函数关系, 实现了表面粗糙度的测量. 同时, 利用 Tamura 纹理特征与加工工艺的依赖关系, 建立了基于贝叶斯网络的工艺识别推理模型, 推理出了零件表面加工工艺. 通过为多种加工类型表面建立粗糙度测量模型, 为粗糙度测量提供了新思路. 实验证明所提的粗糙度测量模型能以较高的准确率识别出零件表面加工类型并测量出其表面粗糙度值.

**关键词:** 激光散斑, 表面粗糙度, 纹理, 贝叶斯网络

**PACS:** 42.30.Va, 42.62.-b, 42.62.Cf

**DOI:** 10.7498/aps.64.234203

## 1 引言

金属零件表面的粗糙度值是衡量金属表面加工工艺的重要参数, 对零件运行时的稳定性、耐磨度以及使用寿命都有至关重要的影响<sup>[1]</sup>. 在生产中常用的粗糙度检测方法主要有针描法, 基于可见光的计算机视觉方法以及基于激光散斑的测量方法. 其中针描法原理简单, 但耗费时间长, 且容易造成金属表面划伤<sup>[2]</sup>. 另外受探针的直径大小影响, 对粗糙度值较小的表面其检测精度较低. 计算机视觉方法是基于零件表面图像的纹理特征对粗糙度进行区分, 对于微米级别的粗糙度检测, 受相机分辨率的限制, 其分辨率也有待提高<sup>[3]</sup>.

散斑是由相干光波经随机粗糙表面散射而形成的随机光场<sup>[4]</sup>, 它在许多领域都有着重要的应用<sup>[5-7]</sup>. 基于激光散斑原理进行的粗糙度检测是

利用激光照射在粗糙表面, 由于光的散射和干涉叠加, 在空间形成了随机的散斑场<sup>[8]</sup>, 俘获该散斑图像并结合图像处理算法进行粗糙度的测量. 文献<sup>[9]</sup>基于激光共聚焦扫描显微镜, 提出快速傅里叶变换(FFT)方法分析表面粗糙度; 文献<sup>[10]</sup>基于纹理分析方法, 研究了激光散斑纹理特征与表面粗糙度的关系; 文献<sup>[11]</sup>提出了动态散斑法, 分析了粗糙表面产生的动态散斑强度的统计特性. 目前相关研究主要是针对某一种加工工艺的金属表面, 提取其散斑图像的纹理特征, 并建立与粗糙度之间的关系, 没有建立确切的数学模型<sup>[12]</sup>.

本文提出了一种同时适用于平磨、外磨和研磨三种工艺加工而成的金属零件表面粗糙度检测方法. 分别找出以上三种金属表面的 Tamura 纹理特征与粗糙度之间的联系, 并建立准确的数学模型; 应用贝叶斯网络寻找加工工艺与 Tamura 纹理特征之间的联系, 识别出零件表面加工类型.

\* 国家自然科学基金(批准号: 61302188)、中国博士后特别资助基金(批准号: 2012 T50510)、中国博士后科学基金(批准号: 2011 M500940)、江苏省高校重大自然科学基金(批准号: 12KJA510001)和江苏高校优势学科建设工程项目资助的课题.

† 通信作者. E-mail: sutingchen@muist.edu.cn

## 2 激光散斑形成原理及粗糙度测量方案

激光照射在粗糙物体表面被散射, 在空间相互叠加形成的明暗相间的亮斑和暗斑. 这些光斑呈现无规则的排列, 被称为激光散斑 [13,14]. 由于散斑是激光照射在粗糙表面上经粗糙表面调制而成, 故激光散斑携带着粗糙表面的某些信息.

### 2.1 激光散斑的统计学描述

由于散斑场是一个随机场, 常用统计学的方法来对散斑进行描述 [15]. 令  $I(r)$  和  $\theta(r)$  分别表示散斑场在点  $r$  处的光强和相位, 将复振幅的实部和虚部分别表示为  $A^{(R)}(r)$  和  $A^{(I)}(r)$ , 则实部和虚部分别可以表示如下:

$$A^{(R)}(r) = \sqrt{I(r)} \cos \theta(r), \quad (1)$$


$$A^{(I)}(r) = \sqrt{I(r)} \sin \theta(r). \quad (2)$$

于是  $A^{(R)}(r)$  和  $A^{(I)}(r)$  的联合概率密度函数可以表示为下式:

$$P_{R,I}(A^{(R)}(r), A^{(I)}(r)) = \frac{1}{2\pi\sigma^2(r)} \times \exp \left\{ -\frac{[A^{(R)}(r)]^2 + [A^{(I)}(r)]^2}{2\sigma^2(r)} \right\}, \quad (3)$$

其中  $\sigma^2(r) = \frac{1}{2} \int_{-\infty}^{\infty} |h(r, r_0)|^2 dr_0$ . 将 (3) 式中复振幅的实部、虚部分别用光强和相位的方式, 表达式如下式所示:

$$P_{I,\theta}(I(r), \theta(r)) = \frac{1}{4\pi\sigma^2(r)} \times \exp \left\{ -\frac{I(r)}{2\sigma^2(r)} \right\}. \quad (4)$$



由联合概率密度与边缘概率密度的关系, 可以求出光强的概率密度分布, 如下式所示:

$$P_I(I(r)) = \int_{-\pi}^{\pi} P_{I,\theta}(I(r), \theta(r)) d\theta(r) = \frac{1}{2\sigma^2(r)} \times \exp \left[ -\frac{I(r)}{2\sigma^2(r)} \right], \quad I(r) \geq 0. \quad (5)$$

由 (5) 式可以看出, 散斑场的光强分布为负指数函数, 这也解释了散斑图像中暗斑多于亮斑的原因 [16].

上述基于统计学的散斑场概率密度函数较为准确地描述了激光散斑. 然而该密度函数含有待定的参数, 这些待定参数的确定与激光照射的物体表面粗糙度以及散斑观测点与光源距离都有密切关系. 因此通过上述概率密度函数结合激光散斑图像对零件表面粗糙度进行建模具有较大难度. 另外, 通过以上光强的概率密度函数也无法区分零件表面的不同加工工艺.

散斑是激光由物体表面的粗糙度信息调制产生的, 故采集的激光散斑图像中含有表面粗糙度的信息. 通过分析图像的纹理信息, 能建立表面粗糙度与激光散斑图像纹理信息的函数模型, 用于表面粗糙度的测量. 同时, 将不同加工工艺零件的散斑图像纹理特征输入贝叶斯网络, 通过机器学习的方法, 找出散斑图像纹理特征与加工工艺的潜在联系, 实现零件表面加工工艺识别.

### 2.2 基于激光散斑图像的表面粗糙度测量方案

基于激光散斑图像的表面粗糙度测量方案如图 1 所示, 主要包括散斑图像采集和图像处理两部分.

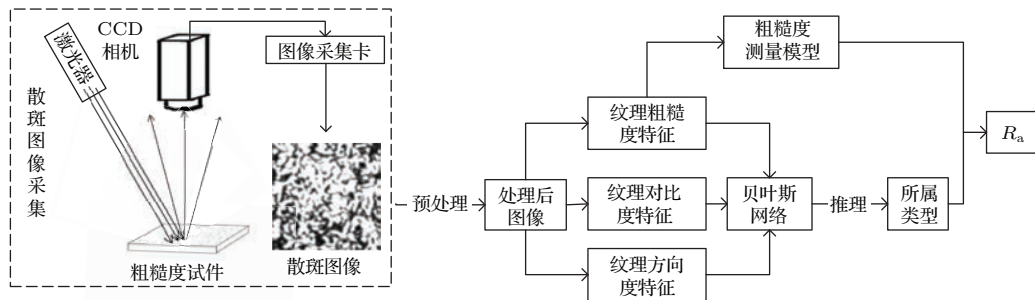


图 1 粗糙度测量方案

Fig. 1. Surface roughness measurement solution.

散斑图像采集部分由氦氖激光器发出的相干光照射在粗糙度试件的粗糙表面, 光会被粗糙表面所调制, 形成干涉和散射效应. CCD 相机接收到的是干涉光和散射光所形成的随机场, 生成亮度和散斑大小都受表面粗糙度影响的激光散斑图像. 采集到的散斑图像通过图像采集卡传输到计算机终端, 完成散斑图像的获取. 图 1 中激光入射角度为  $45^\circ$ , CCD 相机与粗糙度试件的距离为 20 cm.

采集到的试件激光散斑图像, 通过预处理, 统一截取  $128 \times 128$  像素大小的区域作为实验图像. 图像中含有较多的噪点, 通过中值滤波的方法去除噪点. 预处理完的激光散斑图像如图 2 所示. 从左到右, 粗糙度值依次为  $1.6 \mu\text{m}$ ,  $0.8 \mu\text{m}$ ,  $0.4 \mu\text{m}$ ,  $0.2 \mu\text{m}$ ,  $0.1 \mu\text{m}$ ,  $0.05 \mu\text{m}$ . 从图 2 可以看出, 随着粗糙度值的增大, 散斑图像的纹理呈现一定的变化规律, 说明散斑图像的纹理特征与粗糙度之间存在着特定的联系. 将图中粗糙度试件换为外磨和研磨工艺的试件即可获得这两种试件的散斑图像, 这里不再赘述.




图 2 不同粗糙度平磨试件的激光散斑图像

Fig. 2. Laser speckle images of work piece with different roughness.

预处理后的图像即可提取出其纹理特征, 利用这些特征建立粗糙度测量模型. 并将这些数据作为训练数据训练贝叶斯网络, 用于推导零件表面加工类型. 结合以上两个步骤就能根据零件表面的激光散斑图像得出其表面加工类型和表面粗糙度值  $R_a$ .

### 3 激光散斑图的 Tamura 纹理特征提取

对图像纹理的描述主要有基于区域和基于信号处理的纹理描述. 基于区域的纹理描述中, 灰

度共生矩阵、自相关函数、Markov 随机场等都被广泛运用于纹理特征提取<sup>[17]</sup>. 基于信号的纹理描述中的 Gabor 滤波器, 小波分析等在纹理特征提取方面也有较好的效果. 本文所用的 Tamura 纹理特征是 Tamura 等结合人类对纹理图像的视觉感受与心理学所提出的一种纹理特征的数字化表达<sup>[18]</sup>. Tamura 纹理特征能很好地吻合人类的视觉效应, 主要包括粗糙度、对比度、方向度、线性度、规整度和粗略度 6 种属性. 其中线性度、规整度、粗略度这三种属性是对前三种属性的进一步提取和概括, 故本文只研究粗糙度、对比度和方向度这三种属性与零件表面粗糙度的关系.

#### 3.1 散斑图像的纹理粗糙度特征

粗糙度是纹理特征的本质特征, 也即图像纹理基元的大小. 对于同样大小的图像, 纹理基元重复的次数越少, 人类视觉感受上就认为纹理越粗糙. 从图 2 可看出随着表面粗糙度的增大, 其粗糙度值逐渐减小, 即亮斑越小. Tamura 纹理特征的粗糙度值计算如下:

1) 对图像中每个像素计算窗口大小为  $2^k \times 2^k$  区域的平均灰度值  $A_k$ . 其中  $k$  为计算窗口的大小 (一般  $1 \leq k \leq 5$ ),  $g(i, j)$  表示图像位于坐标  $(i, j)$  处的灰度值, 其表达式为

$$A_k(x, y) = \frac{1}{2^{2k}} \sum_{i=x-2^{k-1}}^{x+2^{k-1}-1} \sum_{j=y-2^{k-1}}^{y+2^{k-1}-1} g(i, j) \quad (6)$$

2) 对于每个像素点, 计算其水平和垂直方向互不重叠的活动窗口的平均灰度差如 (7) 式, (8) 式所示.

$$E_{k,h}(x, y) = |A_k(x + 2^{k-1}, y) - A_k(x - 2^{k-1}, y)|, \quad (7)$$

$$E_{k,v}(x, y) = |A_k(x, y + 2^{k-1}) - A_k(x, y - 2^{k-1})|. \quad (8)$$

对于图像中每个像素, 取使得  $E$  取最大值的  $k$  设置最佳尺寸  $S_{\text{best}} = 2^k$ .

3) 计算整幅图像的最佳尺寸, 即该图像各像素最佳尺寸  $S_{\text{best}}$  的平均值. 该平均值即为该图像的粗糙度值为

$$F_{\text{crs}} = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n S_{\text{best}}(i, j). \quad (9)$$



按照上述流程即可提取出一幅图像的粗糙度值. 通过上述算法流程的描述可以看出, 粗糙度值的计算过程中涉及到窗口大小, 即参数  $k$  的取值问题. 将  $k$  值分别取 2, 3, 4, 5, 并计算各平磨试件的粗糙度值, 得到 Tamura 纹理粗糙度  $F_{crs}$  与  $R_a$  的对应关系如图 3 所示.




图3 平磨试件不同窗口大小  $R_a$  与  $F_{crs}$  关系图  
Fig. 3. Relationship between  $R_a$  and  $F_{crs}$  with different size of window.




图4 外磨试件  $R_a$  与  $F_{crs}$  关系图  
Fig. 4.  $R_a$  and  $F_{crs}$  relationship of external grinding.




图5 研磨试件  $R_a$  与  $F_{crs}$  关系图  
Fig. 5.  $R_a$  and  $F_{crs}$  relationship of grinding.

从图 3 可以看出: 当  $k$  取 4 时, 相对其他取值,  $F_{crs}$  值增大较为明显, 具有较好的单调性, 对粗糙度值不同的试件具有较好的区分度, 故将  $k$  值取为 4. 分别将该取值应用于另外两种外磨和研磨试件得到 Tamura 特征的  $F_{crs}$  值与表面粗糙度  $R_a$  之间的关系如图 4、图 5 所示.

### 3.2 散斑图像的纹理对比度特征

对比度指的是一幅图像中黑与白的比值, 也就是从黑到白的渐变层次, 反应了图像灰度分化的程度. Tamura 特征对对比度的定义为

$$F_{con} = \frac{\sigma}{\alpha_4^{1/4}}, \quad (10)$$

其中  $\sigma$  为图像的标准差,  $\alpha_4 = \mu_4/\sigma^4$ ,  $\alpha_4$  为图像的四阶矩. 按照上述定义分别计算平磨、外磨、研磨三种不同工艺粗糙表面的对比度特征, 结果如表 1 表 2 所示.

表 1 平磨外磨零件对比度  
Table 1. Contrast of Flat and external grinding.

粗糙度 $R_a/\mu m$	平磨零件对比度	外磨零件对比度
0.05	890.36	865.54
0.1	876.76	814.95
0.2	966.09	877.63
0.4	797.28	1000.49
0.8	595.47	975.79
1.6	684.53	825.35

表 2 研磨零件对比度  
Table 2. Contrast of grinding.

粗糙度 $R_a/\mu m$	研磨零件对比度
0.012	925.27
0.025	1104.05
0.05	860.01
0.075	842.36
0.1	474.30
0.125	854.21

从表 1、表 2 数据可以看出, 对比度  $F_{con}$  这一特征与零件粗糙度值  $R_a$  之间并不存在着简单的单调递增或递减的关系.

### 3.3 散斑图像的纹理方向度特征

方向度特征描述的是纹理基元如何按照一定的方向进行分布和重复, 它反应了图像纹理基元的

形状和排列规则. 方向度的计算如下:

1) 计算各像素点的梯度向量, 包括该向量的模值  $|\Delta G|$  和角度  $\theta$ , 计算方法分别为

$$|\Delta G| = \frac{|\Delta_H| + |\Delta_V|}{2}, \quad (11)$$

$$\theta = \arctan\left(\frac{\Delta_V}{\Delta_H}\right) + \frac{\pi}{2}, \quad (12)$$

(11) 式, (12) 式中的  $\Delta_H$  和  $\Delta_V$  分别表示图像在该点水平和垂直方向上的灰度变化量, 可以通过图像与图 6 所示的两个掩膜做卷积运算得到.

-1	0	1	1	1	1
-1	0	1	0	0	0
-1	0	1	-1	-1	-1

图 6 图像掩膜

Fig. 6. Image mask.

表 3 平磨外磨零件方向度

Table 3. Direction of flat and external grinding.

粗糙度 $R_a/\mu\text{m}$	平磨零件方向度	外磨零件方向度
0.05	30.21	28.74
0.1	33.24	33.85
0.2	32.78	29.47
0.4	28.74	33.11
0.8	29.88	33.35
1.6	28.31	25.47

2) 将  $\theta$  值划分为  $k$  个区间, 统计各区间中  $|\Delta G|$  大于设定阈值  $t$  的像素数量  $N_\theta(k)$ , 得到  $\theta$  的直方图, 如 (13) 式所示. 若是图像纹理有明显的方向性, 则该直方图会在对应的区间表现出峰值.

$$H_D(k) = \frac{N_\theta(k)}{\sum_{i=0}^{k-1} N_\theta(i)}. \quad (13)$$

3) 计算步骤 2 中直方图的峰值尖锐程度, 也即图像的方向度特征, 如 (14) 式所示. 其中  $p$  表示直方图中的峰值,  $n_p$  表示直方图中峰值总数.  $\omega_p$  表

示某一峰值所对应的  $\theta$  区间,  $\varphi_p$  表示峰值所在的位置.

$$F_{\text{dir}} = \sum_p^{n_p} \sum_{\varphi \in \omega_p} (\varphi - \varphi_p)^2 H_D(\varphi). \quad (14)$$

按照上述步骤分别计算平磨、外磨、研磨工艺粗糙度样块的方向度特征, 得到结果如表 3、表 4 所示. 从表中可以看出, 与对比度一样, 方向度  $F_{\text{dir}}$  与粗糙度  $R_a$  之间也不存在着简单的单调关系.

表 4 研磨零件方向度

Table 4. Direction of grinding.

粗糙度 $R_a/\mu\text{m}$	研磨零件方向度
0.012	36.10
0.025	38.68
0.05	29.43
0.075	34.65
0.1	31.08
0.125	34.58

### 3.4 粗糙度值测量模型建立

为建立能实现任意粗糙度值测量的数学模型, 需要上文所获取的 Tamura 纹理特征与粗糙度值  $R_a$  进行多项式拟合. 从而实现通过获取零件表面散斑图像, 计算图像纹理特征参数, 代入粗糙度计算模型, 进而实现粗糙度值  $R_a$  的测量. 通过上文分析可知, 零件表面粗糙度值  $R_a$  与 Tamura 纹理特征之间, 只与纹理粗糙度特征  $F_{\text{crs}}$  存在较为明显的函数关系, 而与对比度  $F_{\text{con}}$ 、方向度  $F_{\text{dir}}$  之间函数关系不明确. 故选用具有明显函数关系的  $F_{\text{crs}}$  与表面粗糙度值  $R_a$  进行曲线拟合. 为便于区分, 分别用  $R_{\text{ap}}$ ,  $R_{\text{aw}}$ ,  $R_{\text{ay}}$  表示平磨、外磨和研磨工艺的零件表面粗糙度. 拟合结果如图 7 及 (15) 式—(17) 式所示.

$$R_{\text{ap}} = 0.021F_{\text{crs}}^3 - 0.502F_{\text{crs}}^2 + 4.301F_{\text{crs}} - 12.283, \quad (15)$$

$$R_{\text{aw}} = 0.061F_{\text{crs}}^3 - 1.364F_{\text{crs}}^2 + 10.518F_{\text{crs}} - 27.323, \quad (16)$$

$$R_{\text{ay}} = 0.054F_{\text{crs}}^3 - 1.329F_{\text{crs}}^2 + 10.927F_{\text{crs}} - 29.985. \quad (17)$$




图7  $R_a$  与  $F_{crs}$  函数关系图 (a) 平磨试件; (b) 外磨试件; (c) 研磨试件

Fig. 7. Function diagram of  $R_a$  and  $F_{crs}$ : (a) Flat grinding; (b) External grinding; (c) Mill grinding.

#### 4 基于贝叶斯网络的零件加工类型识别

前述已建立了零件表面粗糙度值  $R_a$  与 Tamura 纹理粗糙度特征  $F_{crs}$  之间的函数关系, 但针对平磨、外磨、研磨三种不同加工工艺, 其函数关系都不一致. 在获得散斑图像的  $F_{crs}$  值后需确定加工工艺才可代入相应公式计算其粗糙度值  $R_a$ .

从上文分析可以看出, Tamura 纹理的粗糙度、对比度、方向度和零件加工工艺之间存在着某种因果关系, 但不是简单的单调关系. 为了描述这种不确定性关系, 采用贝叶斯网络来进行推理 [19].

表5 网络训练数据

Table 5. Data for Bias network training.

种类	$F_{crs}$	$F_{con}$	$F_{dir}$	种类	$F_{crs}$	$F_{con}$	$F_{dir}$
平磨	12.85	975	28.74	1	L	L	M
外磨	10.25	1000.52	33.35	2	M	L	L
研磨	8.37	474	29.34	3	S	S	L
...	...	...	...	...	...	...	...

为构建贝叶斯网络推理模型, 首先构造用于学习的数据  $D$  如下: 3种加工工艺的试件各有6种粗糙度, 共有18个粗糙度标准试件; 每个试件取10幅不同部位的表面散斑图像, 共有180幅散斑图像; 分别计算其Tamura特征的  $F_{crs}$ ,  $F_{con}$ ,  $F_{dir}$ ; 对三个特征值分别进行量化, 得到学习数据如表5所示. 对特征值的量化根据值的大小分为三档, 为大、中、小, 分别用L, M, S表示. 用1, 2, 3表示平磨、外磨、

研磨三种类型. 获得网络训练数据后, 需分别进行结构和参数学习, 详细设计如下.

##### 4.1 网络结构学习

贝叶斯网络结构学习的目的是通过对数据集的分析, 发现各因素之间存在的依赖关系, 找出与数据集最为吻合的网络结构 [20]. 关于网络结构学习有很多经典的算法, 本文选用Cooper和Herskovits提出的K2算法. K2算法是基于评分搜索的学习算法, 其目的是使得学习到网络结构  $B_S$  对于学习数据  $D$  具有最大后验概率  $P(B_S|D)$ . K2算法将整个网络结构分解为各节点  $X_i$  与其父节点  $\pi_i$  构成的局部结构, 局部结构的评分达到最大也就使整个网络的评分最大, 即该结构与数据集  $D$  最吻合. 各局部结构的评分函数如(18)式所示. 其中  $r_i$  为节点  $X_i$  的取值个数,  $q_i$  为父节点  $\pi_i$  的配置数,  $N_{ijk}$  为数据集  $D$  中当  $X_i$  取值为  $k$  时, 其父节点为第  $i$  个配置的数目,  $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$ .

$$g(X_i, \pi_i) = \prod_{i=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}!. \quad (18)$$

具体网络构建过程如下: 给出节点序  $\rho$ (工艺类型 Class,  $F_{crs}$ ,  $F_{con}$ ,  $F_{dir}$ ), 确定每个节点父节点个数上限  $u$  不大于2. 对每一个节点  $X_i$ , 从节点序中排在它之前的节点集中不断地找出节点加入  $X_i$  的父节点集  $\pi_i$ , 使得  $X_i$  与  $\pi_i$  构成的局部结构的评分  $g(X_i, \pi_i)$  不断增加, 直到  $\pi_i$  加入节点不再增加局部结构的评分为止, 在此过程中, 限制每个节点的父节点的数量不超过2. 这样就完成了贝叶斯网络的构建.

### 4.2 网络参数学习

参数学习是从数据集中学习已知网络结构中各节点的条件概率分布, 本文选用最大似然估计法, 其基本思想是根据数据样本与模型参数 $\theta$ 的似然程度来估计网络的拟合程度, 似然程度越大, 拟合度越好.

通过以上步骤即可完成贝叶斯网络的结构及参数学习. 得到的贝叶斯网络结构如图8所示, 从图8可看出工艺类型Class,  $F_{crs}$ ,  $F_{con}$ ,  $F_{dir}$ 4个节点的相互依赖关系. 对任意给定激光散斑图像, 求出其 $F_{crs}$ ,  $F_{con}$ ,  $F_{dir}$ 参数, 代入学习好的贝叶斯网络, 即可推理出该表面的加工类型.




图8 贝叶斯网络训练结果

Fig. 8. The training results of Bias network.

### 5 实验及讨论

为验证本文所提测量方案的有效性, 按照文章2.2节图1所提的测量方案进行验证: 对待检测零件, 获取其表面激光散斑图像, 预处理为标准大小, 按照前文所述方法求出其 $F_{crs}$ ,  $F_{con}$ ,  $F_{dir}$ 三个参数; 输入贝叶斯网络, 推理出所属加工类型; 按照推理出的加工类型将 $F_{crs}$ 值代入(15)—(17)式中相应的公式, 即可求出该零件的表面粗糙度值 $R_a$ .

表6 平磨试件实验结果

Table 6. Experimental result of Flat grinding work piece.

标准值/ $\mu\text{m}$	0.05	0.1	0.2	0.4	0.8	1.6
	0.051	0.095	0.243	0.385	0.785	1.621
测量值/ $\mu\text{m}$	0.053	0.142	0.192	0.392	0.792	1.632
	0.049	0.117	0.235	0.422	0.814	1.621
平均误差/ $\mu\text{m}$	0.001	0.021	0.028	0.015	0.012	0.024

按照上述方案对每种加工工艺的6种粗糙度试件各取3幅测量其表面粗糙度值, 以检验所述方

案的可行性, 结果如表6—表8所示. 实验结果表明该方案能较准确地测量零件表面的粗糙度值 $R_a$ .

表7 外磨试件实验结果

Table 7. experiment result of external grinding work piece.

标准值/ $\mu\text{m}$	0.05	0.1	0.2	0.4	0.8	1.6
	0.054	0.122	0.213	0.387	0.816	1.632
测量值/ $\mu\text{m}$	0.048	0.114	0.205	0.396	0.842	1.621
	0.049	0.089	0.198	0.389	0.814	1.596
平均误差/ $\mu\text{m}$	0.002	0.015	0.006	0.009	0.024	0.023

表8 研磨试件实验结果

Table 8. Experimental result of grinding work piece.

标准值/ $\mu\text{m}$	0.012	0.025	0.05	0.075	0.1	0.125
	0.011	0.022	0.048	0.074	0.098	0.119
测量值/ $\mu\text{m}$	0.011	0.024	0.052	0.074	0.086	0.116
	0.014	0.022	0.051	0.075	0.134	0.126
平均误差/ $\mu\text{m}$	0.001	0.002	0.002	0.001	0.017	0.005

### 6 结论

通过对零件表面激光散斑图像的Tamura纹理特征研究, 发现了粗糙度特征 $F_{crs}$ 与表面粗糙度值 $R_a$ 之间存在简单的单调关系, 拟合了粗糙度特征 $F_{crs}$ 与粗糙度值 $R_a$ 之间的函数关系式. 另外用贝叶斯网络建立了粗糙度特征 $F_{crs}$ 、对比度特征 $F_{con}$ 、方向度特征 $F_{dir}$ 与零件加工工艺之间的依赖关系, 能通过散斑图像的这三个纹理特征推理出所属的加工类型.

实验结果说明了该方案能有效地实现多工艺的零件粗糙度测量, 为表面粗糙度测量提供了一种快速、方便的解决方案. 下一步的研究将采用更多粗糙度值的试件, 丰富实验数据, 提高模型的准确性.

### 参考文献

- [1] Wang C X 2010 *IIE Trans.* **35** 11
- [2] Fuh YK, Hsu KC, Fan JR 2012 *Opt. Lett.* **37** 848
- [3] Shahabi H H, Ratnam M M 2010 *Int. J. Adv. Manuf. Technol.* **46** 275
- [4] Dainty J C 1984 *Laser Speckle and Related Phenomena* (Berlin: Springer-Verlag) p18, p29
- [5] Williams G, Pfeifer M, Vartanyants I, Robinson I 2003 *Phys. Rev. Lett.* **90** 175501



- [6] Pierce M S, Moore R G, Sorensen L B, Kevan S D, Hellwig O, Fullerton E E, Kortright J B 2003 *Phys. Rev. Lett.* **90** 175502
- [7] Zhang N Y, Teng S Y, Song H S, Liu G Y, Cheng C F 2009 *Chin. Phys. Lett.* **26** 034209
- [8] Briers D, Duncan D, Hirst E, Kirkpatrick S J, Larsson M, Steenbergen W, Thompson O B 2013 *J. Biomed. Opt.* **18** 066018
- [9] Samtas G 2014 *Int. J. Adv. Manuf. Technol.* **73** 353
- [10] Shimizu M, Sawano H, Yoshioka H 2014 *Precis. Eng* **38** 1
- [11] Gao Z, Zhao X Z 2011 *Opt. Laser Eng.* **50** 668
- [12] Kayahan E, Oktem H, Hacizade F 2010 *Tribol. Int.* **43** 307
- [13] Wu Y L, Wu Z S 2014 *Chin. Phys. B* **23** 37801
- [14] Regan C, Ramirez-San-Juan J C, Choi B 2014 *Opt. Lett.* **39** 5006
- [15] Zeng Y, Wang M, Feng G 2013 *Opt. Lett.* **38** 1313
- [16] Song H S, Zhuang Q, Liu G Y, Qin X F, Chen C F 2014 *Acta Phys. Sin.* **63** 094201 (in Chinese) [宋洪胜, 庄桥, 刘桂媛, 秦希峰, 程传福 2014 物理学报 **63** 094201]
- [17] Françon M 2012 *Laser speckle and applications in optics (Elsevier)* p56
- [18] Bunge, H J 2013 *Texture analysis in materials science: mathematical methods (Elsevier)* p23
- [19] Pernkopf F, Wohlmayr M 2013 *Pattern Recogn.* **46** 464
- [20] Florian C, Traverso P A, Santarelli A, Filicori F 2013 *IEEE Trans. Instrum. Meas.* **62** 2857

# Surface roughness modeling based on laser speckle imaging\*

Chen Su-Ting<sup>1)†</sup> Hu Hai-Feng<sup>1)2)</sup> Zhang Chuang<sup>1)</sup>

1) (*Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science & Technology, Nanjing 210044, China*)

2) (*Unit 94654, PLA, Nanjing 210046, China*)

( Received 5 June 2015; revised manuscript received 16 July 2015 )

## Abstract

Surface roughness is an important parameter in measuring the roughness of surface formed by laser irradiation on the workpiece. Speckle images of rough surfaces in different classes and different surface roughness values are obtained by constructing a set of laser speckle image acquisition systems. First, the texture features of speckle images including coarseness, contrast and direction are extracted using Tamura texture theory. Then, the interactions these three features with the surface roughness are analyzed. Based on the analyses of their monotonic relations, the surface roughness functions, including flat grinding, external grinding and mill grinding craftworks, are established respectively between the texture coarseness feature of the speckle image  $F_{\text{crs}}$  and surface roughness  $R_a$ . Through the establishment of surface roughness function for the above three classes of workpieces, the value of surface roughness can be computed directly. However, before obtaining the value of surface roughness, the classes of processing technic should be determined because of the inconsistency of function expressions for different classes. And based on the specific connection and related dependencies between Tamura texture features and workpiece class, Bayes network is proposed to describe this uncertainty relation among different classes. Through network structure learning and parameter learning, a model for reasoning is found which can be used to determine the class of workpiece after obtaining texture coarseness feature  $F_{\text{crs}}$ . Thus, not only can the value of surface roughness be measured, also the class of work-piece can be recognized. Experiments are conducted to confirm the feasibility of the proposed model for measurement. The detection results indicate that high precision and accuracy are achieved for both workpiece class recognition and roughness measurement.

**Keywords:** laser speckle, surface roughness, texture, Bayes network

**PACS:** 42.30.Va, 42.62.-b, 42.62.Cf

**DOI:** 10.7498/aps.64.234203

---

\* Project supported by the National Natural Science Foundation of China (Grant No. 61302188), the Special Science Foundation for Post Doctorate Research of the Ministry of Science and Technology of China (Grant No. 2012 T50510), the Science Foundation for Post Doctorate Research of the Ministry of Science and Technology of China (Grant No. 2011 M500940), the Key Natural Science Foundation of the Higher Education Institutions of Jiangsu Province, China (Grant No. 12KJA510001), and the Priority Academic Program Development of Jiangsu Higher Education Institutions.

† Corresponding author. E-mail: [sutingchen@nuist.edu.cn](mailto:sutingchen@nuist.edu.cn)