

激光冲击区表面质量的人工神经网络研究*

於自岚 高传玉 曾丹勇 杨继昌 张永康

(江苏理工大学机械工程学院, 镇江, 212013)

摘要: 大量的实验表明, 经激光冲击处理后, 材料受冲击区的表面质量与材料的疲劳寿命有着明显的关系。因此, 表面质量是判断激光冲击强化效果的重要手段。将人工神经网络技术用于激光冲击处理后试件的表面质量分析, 建立了激光参数与激光冲击处理后试件的表面质量之间的联系, 并用其实现了对冲击处理后的试件表面质量的预测。研究及实验表明, 该方法不仅具有准确及稳定性好等特点, 而且这种预测能力在实际应用中还具有不断提高的智能特性。

关键词: 激光冲击处理 表面质量 神经网络

Study of the surface qualities of laser shock-processing zones using an artificial neural network

Yu Zilan, Gao Chuanyu, Zeng Danyong, Yang Jichang, Zhang Yongkang

(College of Mechanical Engineering, Jiangsu University of Science and Technology, Zhenjiang, 212013)

Abstract A lot of experiments have shown that there is an obvious relation between surface qualities of specimen after laser shock-processing(LSP) and its fatigue life. Consequently, the LSP effects can be evaluated by surface qualities in LSP areas. In this paper, an artificial neural network(ANN) is utilized to study the surface qualities of specimen after LSP. Based on the data obtained in the experiment, an ANN is established. The trained ANN could acquire the relations between surface qualities and laser parameters. From the verification of aluminium alloy 2024-T62, it is proved that the neural network can successfully predict the surface quality grades of specimen after LSP, and easily determine the laser parameters under different production conditions. The research and experimental results show that the ANN has not only the accuracy and good stability, but also the intelligent improving control ability during process.

Key words: laser shock-processing(LSP) surface qualities neural network

引 言

当短脉冲(ns) 强激光(10^9 W/cm^2) 照射到固体金属材料靶面时, 高温、高压的等离子体在材料表面被点燃。急速膨胀的等离子体由于受到约束层的约束作用, 从而产生了由激光支持的、瞬时的、向金属内部传递的压力冲击波, 其最高压力大大超过材料的动态屈服强度, 使金属材料表层发生塑性变形, 形成密集的位错及表面残余压应力, 从而提高了金属材料的疲劳寿命^[1,2]。可是, 由于脉冲强激光作用所造成的瞬时高温汽化、熔化、再结晶以及爆轰微粒对试件表面的冲击, 也会使材料的表面质量下降, 粗糙度增加, 形成微观不平、点状汽化斑、凹坑及射线状沟槽等。这些表面缺陷会损害材料的疲劳性能, 使其疲劳寿命大大缩短^[3]。激光冲击的上述特性, 决定了激光冲击处理工艺的复杂性。另外, 在实际工程应用中, 由于激光冲击处

* 江苏省应用基金和国家教委博士点基金资助。

理后的构件不允许再进行破坏性疲劳试验来检验强化效果,因而建立合理的激光冲击强化效果的检验与控制方法,是激光冲击处理技术工程应用的关键。事实上,文献[4]和[5]的作者在此方面已做了大量的研究工作。文献[4]的研究表明,经激光冲击处理后,材料受冲击区的表面质量与材料的疲劳寿命有着明显的关系:具有较高表面质量等级的试件对应着较高的疲劳寿命;具有较低表面质量等级的试件对应着较低的疲劳寿命。因此,可以通过对冲击后试件表面质量等级的判定,确保在激光冲击处理后,材料的疲劳寿命是显著增加的。

然而,在激光冲击处理过程中,有许多因素影响冲击后试件的表面质量,这些因素之间的关系十分复杂,存在着许多不确定性。其中,激光参数与表面涂层起着极其重要的作用,它们将直接影响到金属材料受激光冲击处理区的表面质量,因而在具体实施激光冲击处理时,对它们的选择有相当严格的要求,这样,就不利于激光冲击处理技术的工程应用与推广。

由于人工神经网络具有自组织、自学习和对输入数据或规则的鲁棒容错能力,我们尝试从其从所积累的实例中学习知识,总结规律,建立激光参数与材料冲击处理后的表面质量的非线性关系,实现对激光冲击处理后试件的表面质量的预测,从而使激光参数的选择更加合理,保证材料在经冲击处理后能够获得满意的性能。

1 激光冲击处理及表面质量分类

1.1 激光冲击处理实验

试样的材料为 2024 T 62 航空铝合金,采用双联无传递载荷的“狗骨型”典型紧固件。涂层采用黑色涂料,约束层为 f 20mm × 4.5mm 的 K9 光学玻璃。实验设备为波长 1.06μm 的调 Q 钕玻璃激光器,该设备由一级调 Q 激光振荡器、一级前置放大器以及一级双程激光主放大器组成,多模输出。所选择的激光参数为:脉宽 13ns~ 50ns,光斑直径 f 5mm~ f 10mm,能量 5.29J~ 37.9J,功率密度 10⁸W/ cm²~ 10⁹W/ cm²。

采用双面依次激光冲击方式,即先对一面进行冲击处理,然后试样翻转 180°,再对其另一面进行冲击处理。试件经激光冲击后,以冲击区的 f 1mm 中心孔为基准在 Hauser OP2 精密坐标镗床上精镗出 f 2mm 的孔,孔内壁表面粗糙度小于 0.1μm。然后在 INSTRON 1341 疲劳试验机上进行低频常幅拉-拉疲劳试验,最大载荷 4.2kN,应力比 R= 0.1,精度 ±0.5%,试验频率 13Hz。

试验共激光冲击处理 50 根试件,激光冲击后随即进行疲劳寿命试验,结果如表 1 所示。

Table 1 Laser shocking parameters, increase of fatigue life and surface quality grade

| specimen No. | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
|-----------------------------|-------|------|-------|-----|------|--------|-------|-------|-------|-------|
| energy(J) | 7.6 | 7 | 10.8 | 8.1 | 12.3 | 11.3 | 8 | 8.8 | 13.7 | 11.3 |
| | 7 | 14.3 | 8.8 | 8 | 7.3 | 10.8 | 8 | 18.9 | 10.4 | 9.2 |
| pulse duration(ns) | 13 | 13 | 13 | 13 | 13 | 13 | 18 | 30 | 30 | 30 |
| diameter(mm) | 10 | 10 | 10 | 10 | 10 | 10 | 6 | 7 | 7 | 7 |
| increase of fatigue life(%) | 126.4 | 59.8 | 131.1 | 115 | 88.3 | - 19.5 | 272.6 | 583.1 | 331.5 | 467.6 |
| surface quality grade | A | A | C | B | C | D | A | A | A | A |
| | A | D | B | A | A | C | A | A | A | A |

| | | | | | | | | | | |
|------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| specimen No. | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 |
| energy(J) | 23. 3 | 14. 1 | 18. 07 | 18. 75 | 16. 44 | 16. 85 | 16. 31 | 16. 44 | 17. 4 | 18. 35 |
| | 15. 65 | 15. 1 | 16. 72 | 18. 07 | 19. 03 | 16. 04 | 15. 63 | 16. 44 | 16. 99 | 19. 16 |
| pulse duration(ns) | 30 | 30 | 30 | 30 | 30 | 30 | 30 | 30 | 30 | 30 |
| diameter(mm) | 7 | 7 | 7 | 7 | 7 | 7 | 7 | 7 | 7 | 7 |
| increase of fatigue life(%) | 367. 9 | 269. 6 | 872. 7 | 808. 3 | 303. 2 | 711. 9 | 459 | 670. 2 | 322. 7 | 237. 1 |
| surface quality grade | A | A | A | A | A | A | A | A | A | A |
| | A | A | A | A | A | A | A | A | A | A |

| | | | | | | | | | | |
|-------------------------------|--------|--------|--------|--------|--------|--------|-------|-------|--------|--------|
| specimen No. | 21 | 22 | 23 | 24 | 25 | 26 | 27 | 28 | 29 | 30 |
| energy(J) | 20. 2 | 14 | 19. 71 | 17. 5 | 16. 8 | 9. 1 | 11. 3 | 15. 4 | 18. 34 | 25. 4 |
| | 8. 1 | 18. 1 | 19. 30 | 16. 7 | 16 | 5. 29 | 13. 1 | 10 | 17 | 17 |
| pulse duration(ns) | 30 | 30 | 30 | 30 | 30 | 50 | 50 | 50 | 50 | 50 |
| diameter(mm) | 7 | 7 | 7 | 7 | 7 | 5 | 5 | 5 | 6 | 6 |
| increase of fatigue life (%) | 218. 3 | 645. 3 | 754. 6 | 871. 5 | 739. 4 | 11. 73 | 37. 7 | 42 | 11. 28 | 63. 95 |
| surface quality grade | B | A | A | A | A | B | B | B | B | B |
| | A | A | A | A | A | B | B | B | B | B |

| | | | | | | | | | | |
|------------------------------|--------|-------|--------|---------|-------|-------|-------|--------|--------|-------|
| specimen No. | 31 | 32 | 33 | 34 | 35 | 36 | 37 | 38 | 39 | 40 |
| energy(J) | 18. 2 | 26 | 22. 5 | 16. 7 | 16. 1 | 28. 3 | 28. 8 | 34. 5 | 37. 9 | 36. 4 |
| | 13. 2 | 27. 2 | 15. 07 | 18. 2 | 24. 6 | 26. 3 | 19. 1 | 32. 4 | 34. 4 | 34. 1 |
| pulse duration(ns) | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 50 |
| diameter(mm) | 6 | 6 | 6 | 6 | 9 | 10 | 10 | 10 | 9 | 9 |
| increase of fatigue life(%) | 48. 63 | 60. 2 | 50. 36 | 247. 28 | 88. 7 | 70. 7 | 58. 7 | - 4. 2 | - 7. 3 | 5. 1 |
| surface quality grade | B | B | B | A | B | B | B | C | C | C |
| | B | B | B | A | B | B | B | C | C | C |

| | | | | | | | | | | |
|------------------------------|-------|-------|-------|--------|---------|---------|---------|---------|-------|---------|
| specimen No. | 41 | 42 | 43 | 44 | 45 | 46 | 47 | 48 | 49 | 50 |
| energy(J) | 32. 9 | 32. 8 | 32. 6 | 30. 5 | 25. 4 | 26 | 28 | 25. 8 | 31. 2 | 23. 3 |
| | 20 | 27. 9 | 29. 8 | 6. 1 | 29. 4 | 28. 6 | 28 | 27. 3 | 20. 1 | 26. 5 |
| pulse duration(ns) | 50 | 50 | 50 | 50 | 40 | 40 | 40 | 40 | 40 | 40 |
| diameter(mm) | 9 | 9 | 9 | 9 | 7 | 7 | 7 | 7 | 7 | 7 |
| increase of fatigue life(%) | 7. 0 | 10 | 30. 9 | - 6. 9 | - 17. 3 | - 30. 2 | - 16. 7 | - 26. 5 | - 40 | - 52. 3 |
| surface quality grade | C | C | C | C | D | D | D | D | D | D |
| | B | B | B | B | D | D | D | D | D | D |

1. 2 表面质量分类

金属材料表面在冲击波的作用下发生塑性变形从而形成了冲击强化区。激光冲击区表面宏观特征为表面产生较大的残余压应力和较高的表面硬度, 其内层显微特征是密集的位错和细化的晶粒^[3, 6]。激光冲击区的表面质量是这几个因素的综合反映, 在此可用表面粗糙度与

微凹坑这两个指标来表示。若冲击区的表面粗糙度越低,则冲击强化效果越好。应力波在冲击区所形成的微凹坑的大小、深浅及形状,可通过对光线在材料表面的反射进行观察与分析。一般情况下,微凹坑仅有几个微米至二十几个微米数值的深度。微凹坑的深度是塑性变形的结果,反映了残余压应力的大小及表面硬度的高低。微凹坑的形貌反映了残余压应力与硬度的分布情况。通过对冲击后工件的表面粗糙度与微凹坑进行直观地观察与分析,就可以判别激光冲击强化效果的好坏,从而达到无损检验的目的^[7]。

根据对大量的激光冲击试件进行分析的结果,可将激光冲击区的表面质量分成 A, B, C, D 4 个等级^[4]:

A 级:冲击区表面粗糙度小于或等于未冲击区表面粗糙度,光斑均匀,形成一层十分致密的光亮圈,微凹。A 级真实地反映了激光冲击强化对疲劳寿命的贡献。

B 级:表面粗糙度稍增大,汽化层厚度均匀,有极少量汽化斑点,光斑较均匀。B 级较大程度上反映了激光冲击强化对疲劳寿命的贡献,因为有一小部分疲劳寿命增益用于补偿表面质量下降所造成的疲劳寿命损失。

C 级:冲击区表面呈现离散点状、蜂窝状、大斑块状,汽化区不均匀。C 级已不能反映出激光冲击对材料疲劳寿命的贡献。

D 级:汽化强烈,冲击区表面发生熔化,晶粒粗大,形成汽化凹坑,表面粗糙,有射线状沟槽。D 级疲劳寿命的增益已不足以补偿表面质量下降所造成的损失,材料的疲劳寿命增益降为负。

本次冲击试验后试件的表面质量等级见表 1。

2 激光参数与表面质量非线性关系的人工神经网络模型

2.1 神经网络模型的建立

神经网络是在研究生物神经系统的启示下发展起来的一种信息处理方法,它不需要设计任何数学模型,只靠过去的经验来学习,学习好的网络可以处理模糊的、非线性的、含有噪声的数据,可用于预测、分类、模式识别、非线性回归、过程控制等各种数据处理场合,而且在大多数情况下,应用效果优于传统统计分析方法^[8]。

大量的实验表明,在约束层、表面涂层等其它工艺条件一定的前提下,激光冲击区表面质量与所选择的激光的能量、脉宽、光斑直径参数有关。因此,我们在此选用一个 3 层后传播网络,如图 1 所示。由于不同材料本身的特性参数互不相同,这里仅以 2024 T 62 铝合金为例。网络的输入节点有 3 个,即能量、脉宽和光斑直径。以冲击区表面质量等级作为输出节点,单元输出 4 表示表面质量等级为 A 级,输出 3 表示质量等级为 B 级,输出 2 表示质量等级为 C 级,输出 1 表示质量等级为 D 级。

隐含层选择是关键,可以首先选取 15 个隐含层单元进行试验,在训练好的网络对预测的精度相同的情况下,逐渐减少隐含层单元数,这样,可以减少网络规模,缩短网络训练和运算时间。同时,由于减少了单元间的连接数,网络更容易学习到训练数据的一般规律。




Fig. 1 Model of the neural network architecture

2.2 神经网络的训练与检验

网络的训练是以后传播方式进行的。先从输入层开始正向计算各层神经元(节点)的输入和输出。当输出层节点的实际输出与事先给定的信号不一致或误差不满足时,则执行误差反向传播,逐层修改网络的连接权值,直至误差信号满足要求为止。网络的训练数据必须包括表面质量的各个等级。由于激光冲击试验采取了双面依次冲击方式,在此,我们选用了 36 根试件的激光参数和表面质量等级,这相当于用 72 组实例样本数据训练上述网络。在经过 108, 335, 050 次学习循环后,网络误差达到了规定的误差 $4.6635E-05$ 。由图 2,同样也可以看出,网络经学习后,输出的表面质量等级与实际状况几乎一致。此时,可以认为网络对每个实例样本有了基本的掌握。




Fig. 2 Training scheme of the neural network
——actual resulttraining output




Fig. 3 Classifying scheme of the neural network
——actual resultclassifying result

网络的检验是很重要的,只有经过检验数据对网络的性能进行检查后,若结果满足要求,网络才能投入使用。网络的检验数据的选择方式与训练数据的选择相同,包含了网络设计要求的全部模式,并且应不曾被作为网络训练学习的数据,这样,才能保证全面检查网络性能。这里选择了 14 组样本数据,这相当于 7 根试件的激光参数和表面质量等级作为检验数据。图 3 为这 14 组样本数据的网络预测值与实际值的比较,从中可以看出预测值基本能够反映出实际值的变化。这说明网络用自学习方法学得的表面质量与其各个输入参量之间的关系可以作为预测新的样本表面质量的知识。网络利用这个知识进行推理,进而预测出了未经网络学习过的样本的表面质量。

3 实验验证及结果

训练好的网络就可以投入实际应用,用来预测经激光冲击处理后材料的表面质量等级。本次试验共冲击处理了 5 根试件,试样的材料、试验设备及试验方法与前相同。按工艺要求选择了 10 组激光参数。经网络预测后的结果如表 2 所示。由于在实际工程应用中所希望获得的表面质量等级为 A 级,因而需要对预测试件获得表面质量等级为 B 级、C 级、D 级的激光参数重新进行调整,输入网络进行预测,直至得到 A 级输出,再按此激光参数重新对试件进行冲击处理。表 2 中 1#, 2#, 3# 所示的激光参数为试件 1, 2, 3 经调整后的激光参数。按此参数,经激光冲击处理后获得了令人满意的结果。此时,还可将试件 1 经调整后的激光参数输入网络,让其重新进行学习。由于神经网络本身所具有的自学习、自适应的特点,重新学习后的网络的预测精度将会得到进一步的提高,表 2 中* 1 列出了网络重新学习后预测的结果。

Table 2 Experimental result and ANN output of surface quality grade for different laser parameters

| specimen No. | laser shocking parameters | | | | | surface quality grade | | | |
|-----------------|---------------------------|-------|----------------|----|----------|-----------------------|--------------|---|---|
| | energy | | pulse duration | | diameter | ANN output | experimental | | |
| | (J) | | (ns) | | (mm) | | result | | |
| 1 | 9.73 | 18.4 | 30 | 40 | 7 7 | A(4) | D(1.17) | A | D |
| # 1 | 9.73 | 8.46 | 30 | 18 | 7 6 | A(4) | A(3.84) | A | A |
| * 1 | 9.73 | 9.05 | 30 | 18 | 7 6 | A(4) | A(3.92) | A | A |
| 2 | 25.6 | 12.15 | 30 | 30 | 7 7 | B(3.10) | A(4) | B | A |
| # 2 | 19 | 12.15 | 30 | 30 | 7 7 | A(4) | A(4) | A | A |
| 3 | 33.6 | 14.4 | 50 | 30 | 9 7 | C(1.92) | A(3.96) | C | A |
| # 3 | 16.7 | 14.4 | 30 | 30 | 7 7 | A(3.96) | A(3.96) | A | A |
| 4 | 23.1 | 17.35 | 50 | 50 | 9 9 | B(3.11) | B(3.15) | B | B |
| 5 | 7.1 | 16.32 | 13 | 30 | 10 7 | A(3.97) | A(3.95) | A | A |

4 结 论

研究结果显示,神经网络在学习训练过程中,能够将以往的经验有效地进行归纳,不仅迅速、准确地预测出激光冲击处理后试件的表面质量,具有自适应能力,而且其预测能力可以在实践中不断地积累,具有不断提高和完善的自学习特点,神经网络应用在实际工程中,将可以有效、合理地选择零件冲击处理的激光参数,确保产品最终能够获得满意的性能。

参 考 文 献

1 Fairand B P, Wilcox B A, Gallagher W J *et al.* J A P, 1972; 43(9)
2 张永康,张淑仪,吴鸿兴 *et al.* 中国科学(E 辑), 1997; 27(1): 28~ 34
3 张永康. 激光冲击强化提高航空材料疲劳寿命的研究. 南京航空航天大学博士学位论文, 1995
4 张永康. 中国激光, 1997; A24: 467~ 471
5 张 宏. 抗疲劳断裂激光冲击处理技术的研究. 南京航空航天大学博士学位论文, 1997
6 Fairand B P, Clauer A H. SPIE, 1976; 86
7 Zhang Y K, Zhang Sh Y, Yang J Ch *et al.* Surface and Coatings Technology, 1997; 92: 104~ 109
8 张际先, 宓 霞. 神经网络及其在工程中的应用. 北京: 机械工业出版社, 1996

* * *

作者简介: 於自岚, 男, 1968 年 9 月出生。硕士。主要从事金属材料激光冲击强化技术研究。

收稿日期: 1999-11-01 收到修改稿日期: 2000-05-06

• 简 讯 •

采用高功率 LD 泵浦的 Nd YAG 激光器输出倍频绿光达 40W

天津大学激光与光电子研究所采用美国激光二极管阵列(RE63-2C2-CA1-0021 型) 泵浦的 Nd: YAG 激光器, 工作物质尺寸为 f 6.35mm×146mm, 5 付列阵对 YAG 棒横向泵浦, 恒温控制系统可实现 0.2℃~ 0.5℃的监测及控制, 在 21A 泵浦电流时, YAG 连续输出(1064nm) 功率为 402W。采用声光 Q 开关(27MHz) KTP 晶体内腔倍频方案, 用两种腔型(直腔及 L 型腔), 在激励电流为 13.7A 时, 532nm 准连续输出为 41W(f = 5~ 40kHz, 脉宽为 70~ 250ns)。对于 KTP 在高功率时的热效应问题, 可采用调整相位匹配角等进行补偿。为进一步提高绿光输出功率, 正准备采用 Z 型腔, 可望在激励电流为 20~ 21A 时, 倍频绿光输出达 80~ 100W。

(王 鹏 供稿)