# 人工神经网络技术在成形模具表面激光强化中的应用

王秀凤[1]，吕晓东[1]，陈光南[2]，胡世光[1]，
(1. 北京航空航天大学 机械工程及自动化学院，北京 100083；2. 中国科学院力学所材料工艺研究中心，北京 100080)

**摘 要**：基于人工神经网络基本理论，建立在成形模具表面激光强化中预测材料表面最高温度、强化效果的BP网络模型。借助于MATLAB仿真软件中的神经网络工具箱作为开发平台，将试验样本数据和经过试验验证的数值计算结果作为补充的样本数据用于BP网络的训练，利用训练好的BP网络对非线性的样本数据规律进行拟合，实现激光加工工艺参数的优化，为实际生产和加工提供有效的依据。

**关键词**：人工神经网络；成形模具表面激光强化；数值模拟
**中图分类号**：TG156.99 **文献标识码**：A **文章编号**：1001-3814(2003)06-0041-03

## Application of Artificial Neural Network in Laser Die-surface Hardening

WANG Xiu-feng[1], LU Xiao-dong[1], CHEN Guang-nan[2], HU Shi-guang[1]
(1. *School of Mechanical Engineering and Automation, BUAA, Beijing* 100083, *China*;
2. *Institute of Mechanics, Chinese Academy of Science, Beijing* 100080, *China*)

**Abstract**: Based on the basic theory of artificial neural network, BP network model is founded to predict the highest surface temperature and hardening effect in the process of laser die-surface hardening. Experimental result and numerical simulation result verified by experiment are used to train BP network by means of MATLAB software. Sample data regularity of nonlinear is curve fitting through BP network so as to optimize technological parameters and provide for effective foundation in actual production.

**Key words**: artificial neural network; laser die-surface hardening; numerical simulation

成形模具表面激光强化(即激光淬火)是通过具有一定功率密度的激光束快速扫描模具表面，使其表层达到相变温度以上(但低于熔化温度)，当激光束离开后，利用金属本身热传导使加热区快速冷却而发生自淬火，形成硬度高、抗磨损的表层，从而使模具表面得到强化，而热处理变形甚微。它可以通过调节激光功率、扫描速度和光斑直径来控制模具表面的温度及淬硬层深度，在改善模具表面硬度、耐磨性、韧性等综合力学性能的同时又能保证模具的精度要求。在应用成形模具表面激光强化工艺时，直接面临的困难是如何面对加工过程中影响因素多、耦合作用非常复杂的非线性热物理过程选取优化的激光加工工艺参数，以便在表面不熔化的条件下，得到最佳的强化效果。

运用人工神经网络对加工过程进行工艺参数的优化设计，可避免繁重的试制工作，降低试制成本和缩短试制周期。但是，训练人工神经网络需要足够的样本数据，考虑到强化效果指标主要是表面硬度、硬化层深度和宽度，单从试验中获取，费时、费力、成本高。本文通过试验与数值模拟的相互印证，数值计算强化效果，作为训练网络的补充样本数据。将试验结果、数值模拟和人工神经网络技术有机地结合在一起，开展成形模具表面激光强化工艺参数的优化研究，既大大节省了人力、物力和时间，又符合目前学术发展的新趋势。研究目标的实现必将推动成形模具表面激光强化应用领域的实用进程。

## 1 人工神经网络模型的建立

本文建模采用3层BP网络。根据所建模型的问题本身定义输入层节点数为3，即输出功率、扫描速度、光斑直径；输出层节点数为3，即材料表面的最高温度、硬化层深度、硬化层宽度。隐层节点承接着输入与输出之间的衔接任务，节点数的多少对预测精度有很大的影响。因为用人工神经网络预测材料表面的最高温度、硬化层深度和宽度，其实质是从一个子空间到另一个子空间逼近的映射问题，必定存在一个最优的隐层节点数预测的精度最高，而在这一节点两侧则预测的精度较低。通过选取不同的节点数进行训练比较，确定隐层节点数为5，BP网络的结构如图1所示。

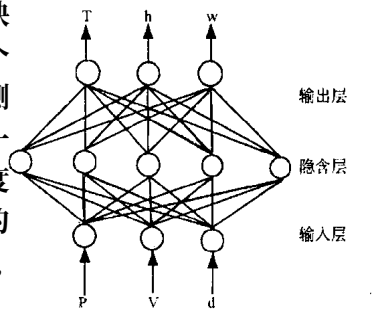


图1 预测成形模具表面激光硬化效果的BP结构网络

* 收稿日期：2003-04-30
基金项目：国家自然科学基金资助项目(59836220)；航空基础科学基金资助项目(98H51110)
作者简介：王秀凤(1963-)，女，浙江鄞县人，副教授，博士。

© 1994-2009 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

借助于美国MathWorks公司推出的MATLAB仿真软件中的神经网络工具箱作为开发平台，将试验样本数据和经过试验验证的数值计算结果作为补充的样本数据用于BP网络的训练，利用训练好的BP网络对非线性的样本数据规律进行拟合，实现激光加工工艺参数的优化，为实际生产和加工提供有效的依据。

BP网络学习程序框图如图2所示。表明，BP网络学习过程由正向和反向传播组成，在正向传播过程中，输入信息从输入层逐层处理，并传向输出层，每一层神经元的状态只影响下一层神经元的状态。如果输出层不能得到期望的输出，则转入反向传播，将误差信号沿原来的连接通路返回，通过修改各层神经元的权值，使得误差信号最小。

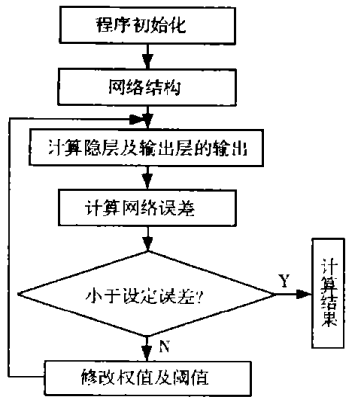

图2 BP网络学习程序框图

学习过程中对隐层、输出层的输出计算及误差的判断都是通过调用神经网络工具箱中的函数来实现。其中隐层节点数的确定比较复杂，如果隐层节点数过少就不足以描述输入与输出之间的关系，而过多则会导致网络训练速度慢，所建模型泛化能力下降，一般按下式选取：

$$h = \sqrt{n \cdot m} + a$$

式中：$h$ 为隐层节点数；$n$ 为输入层节点数；$m$ 为输出层节点数；$a$ 为0～10之间的常数。

具体计算过程如下：

(1) 程序初始化。利用试验样本数据和经过试验验证的数值计算结果作为补充的样本数据作为网络的输入和输出数据，并将输入数据归一化处理，使之取值在[0.1, 0.9]之间，以建立它们与[0, 1]间分布的网络实际输出的对应关系。为了加快收敛，采用变步长的方法。初始步长 $\eta = 0.6$，当网络训练过程出现动荡时，逐渐减小步长为 $0.9\eta$，最终步长取为0.09。

(2) 创建前馈BP网络。隐层节点和输出层节点的传递函数分别为“tansig(反正切函数)”型和“purelin(线性函数)”型；采用Levenberg-Marquardt算法进行训练，与“trainbp”算法相比，训练速度快，但是占用内存多。

(3) 预定训练次数为5000次，希望的误差平方和指标为0.0001，当训练步数达到预定值或误差达到期望值时都将停止训练。

(4) 对网络进行训练，绘制网络训练误差图、网络输出值与样本数据的比较图。

(5) 对网络进行检验，利用已训练好的网络得到网络输出值，绘制网络的预测值与检测样本数据值的比较图。

(6) 利用已训练好并检验后的网络，对新的工艺参数下的结果进行预测，得到优化的工艺参数。

## 2 训练网络的样本数据的获取

样本数据来自于试验结果和经过试验验证的数值计算结果。

### 2.1 试验

试验设备为2 kW连续输出式$CO_2$激光器。选用廉价的45钢制作试块，尺寸为40×20×20 (mm)。将试块放在工作台上，激光束沿试块中心线连续照射。试块被照射表面涂氧化锆以提高材料对激光的吸收率。将镍铬-镍硅热电偶一端焊接在如图3所示的位置上，另一端与放大调理板连接，柔性检测系统将采集到的电压放大信号转化为数字信号，用计算机显示温度随时间的变化曲线。

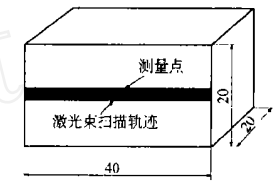

图3 试块尺寸及热偶焊位

激光连续照射后，将试件在任一光斑作用中心处切取横截面制作金相试样，试样经过打磨、抛光后，用3%的硝酸酒精腐蚀，在NEOPHOT21金相显微镜下观察其金相组织。测量结果为模具表面激光强化过程的数值模拟提供验证依据。

### 2.2 数值模拟

借助大型非线性有限元软件MSC.Marc，对上述试验过程进行数值模拟。计算时所用的参数取自试验中所用的相关参数，具体过程可参见文献[1]，这里不多阐述。

### 2.3 对比结果

试块测量点温度随时间变化曲线的计算结果与实测结果如图4所示，可见两者曲线的变化趋势相同，最高点温度值接近；硬化层深度和宽度的计算结果与实测结果如图5所示，可见硬化层形貌尺寸的计算结果与实测结果基本符合。以上结果表明，有限元分析模型正确，计算结果可作为训练人工神经网络补充样本数据。

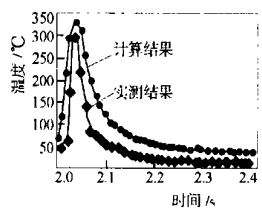

图4 测量点温度随时间的变化

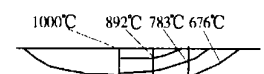


| 硬化层尺寸 | 计算值 | 实测值 |
|---|---|---|
| 深度/mm | 0.2 | 0.2 |
| 宽度/mm | 1.8 | 1.7 |

图5 硬化层的深度和宽度

© 1994-2009 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

## 3　人工神经网络的训练与检验

网络在运行中, 系统首先对试验数据和数值模拟的数据进行学习, 训练样本数为 28, 在经过 5000 次学习循环后, 网络误差达到了规定的误差 0. 000 1。样本数据与网络输出的比较如图 6 所示。表明网络经学习后, 网络输出的值与样本数据的值几乎一致, 可以认为网络对每个样本数据有了基本的掌握, 说明正确建立了网络的输入与输出关系。由此可见, 该系统具有较好的稳定性。

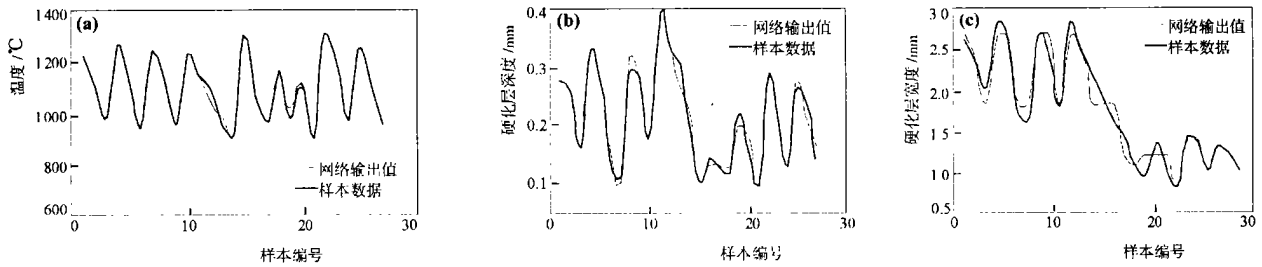


图 6　材料表面最高温度(a)、硬化层深度(b)、硬化层宽度(c)的样本数据与网络输出值的比较

网络的校验是很重要的, 只有经过用检测数据对网络的性能进行检验后, 若结果满足要求, 网络才能投入使用。网络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学习的数据, 这样, 才能全面检验网络的性能。选取 2 组检测样本数据, 用学习后的网络对其进行推断, 网络预测值与检测样本数据值如表1所示。可

表 1　检测样本数据值与网络预测值的比较

| | 输出功率/W | 扫描速度/mm·s⁻¹ | 光斑直径/mm | 表面最高温度/℃ | 硬化层深度/mm | 硬化层宽度/mm |
|---|---|---|---|---|---|---|
| 检测样本数据 1 | 350 | 20 | 4 | 997 | 0. 2 | 1. 8 |
| 网络的预测值 1 | 350 | 20 | 4 | 1 024 | 0. 224 1 | 2. 001 |
| 检测样本数据 2 | 140 | 25 | 2 | 1 114 | 0. 2 | 1. 2 |
| 网络的预测值 2 | 140 | 25 | 2 | 1 146 | 0. 254 7 | 1. 181 9 |

见, 两者比较接近, 可以认为预测值基本能够反映实际值的变化。表明用自学习学得的材料表面最高温度、硬化层深度和宽度与各个输入参量之间的关系可以作为预测新的样本上述指标的知识。网络利用这个知识进行推理, 进而可以预测出该工艺条件下未经网络学习过的样本的上述指标, 具有一定的实用价值。

## 4　模型的应用

训练好的网络就可以投入实际应用, 用来预测成形模具表面激光强化后材料表面最高温度、硬化层深度和宽度, 为实际生产和加工提供优化的激光工艺参数; 同时, 可以通过网络预测方便地分析主要工艺参数对强化效果的影响, 如图 7 所示。表明, 当输出功率增加时, 由于材料表面吸收的能量增多, 使得材料表面达到的最高温度升高, 同时参与材料相变的区域增大, 冷却时导致硬化层深度和宽度相应增加; 当扫描速度增加时, 由于材料表面吸收的能量减少, 使得材料表面达到的最高温度降低, 同时参与材料相变的区域减小, 冷却时导致硬化层深度和宽度相应减少。

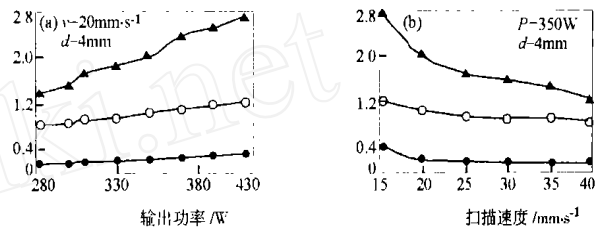


图 7　输出功率(a)、扫描速度(b)对硬化效果的影响

▲-温度(×1000℃); ○-硬化层深度(mm); ●-硬化层宽度(mm)

## 5　结论

人工神经网络模型具有良好的记忆和预测能力, 对于复杂的非线性数据处理能力强。可以在较少的样本数据基础上建立成形模具表面激光强化中预测材料表面最高温度、强化效果的BP 网络模型。计算结果表明, 所建立的BP 网络模型, 不仅能自动获取学习样本中输入与输出的映射关系知识, 较准确地反映成形模具表面激光强化工艺参数与强化效果的非线性关系, 而且对不完整信息能通过网络联想计算出合理的结果, 当添加或更新数据后, 还可以在原有的基础上继续学习, 这对于数据的继承和规律的完善具有深远意义。利用这一模型, 还可以通过网络预测方便地分析主要工艺参数对强化效果的影响, 以便于在加工时根据要求, 选取适当的工艺参数。

需要说明的是, 在程序运行过程中, 对于样本数据, 尽管由于通过随机函数赋初值而得到不同的连接权值, 但这不妨碍最后的交互运行结果, 说明人工神经网络具有较强的容错性。

**参考文献:**

[1]　王秀凤. 激光非熔凝加工技术在板料成形中的应用[D]. 北京: 北京航空航天大学机械工程及自动化学院博士论文, 2003.

© 1994-2009 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net