

基于神经网络的喷丸 25CrMo 合金疲劳寿命及残余应力松弛行为预测研究

苏凯新, 张继旺, 李 行, 张金鑫, 朱守东, 易科尖

(西南交通大学 牵引动力国家重点实验室, 四川 成都 610031)

摘 要: 首先采用 BP 神经网络建立了喷丸 25CrMo 车轴钢疲劳寿命预测模型。然后, 在此基础上采用遗传算法 (GA) 对 BP 神经网络的预测精度进行了优化。此外, 还采用了径向基神经网络 (RBF) 进行建模分析, 并与以上 2 种模型的预测结果进行对比。结果表明: 遗传算法优化的 BP 神经网络 (GA-BP) 相比于 BP 和 RBF 神经网络具有更高的预测精度, 其中训练集和测试集的平均预测精度分别为 91.5% 和 85.4%。然后, 基于 GA-BP 神经网络模型的连接权值矩阵和 Garson 方程进行了灵敏度分析, 从而进一步量化了输入影响因素对喷丸 25CrMo 车轴钢疲劳寿命的相对影响比重; 最后, 还采用 GA-BP 神经网络预测了喷丸 25CrMo 车轴钢表面残余压应力的松弛行为。结果表明, 测试集的平均预测误差仅为 3.4%, 表明了该神经网络预测性能良好。综上所述, 采用神经网络建模分析了喷丸 25CrMo 车轴钢的疲劳性能和残余压应力松弛行为, 显著降低了传统疲劳试验所需的成本, 并且还保证了较高的准确性。

关键词: 喷丸; 神经网络; 遗传算法; 疲劳寿命预测; 残余应力松弛

中图分类号: TG174.442

文献标识码: A

文章编号: 1002-185X(2020)08-2697-09

车轴作为列车运行的关键部件之一, 其服役性能和使用寿命与列车的安全运行密切相关。近年来, 随着高速列车运行速度的不断提高, 对车轴材料的服役性能尤其是疲劳性能提出了越来越严苛的要求。25CrMo 合金钢具有优异的力学性能, 而且能够满足车轴服役所需强度、韧性等性能的要求, 因此被广泛应用于高速列车车轴上 (EN13261-2011)。为了进一步提高 25CrMo 车轴钢的疲劳性能, 常常采用表面强化处理^[1-3]。Chen 等^[1]研究了激光熔覆再制造处理对抑制 25CrMo 车轴钢疲劳裂纹萌生作用的影响。Regazzi 等^[2]研究了滚压表面处理对 25CrMo 车轴钢疲劳强度和裂纹扩展行为的影响。Fajkoš 等^[3]研究了表面感应淬火技术对提高 25CrMo 车轴钢疲劳强度的有效性。

其中, 喷丸处理是目前应用最广泛的机械表面强化处理方法之一, 它利用经过加速的丸粒反复撞击材料或零件表面, 使表层产生剧烈的塑性变形, 在基体表层产生加工硬化的同时又引入了残余压应力, 同时显著细化了基体表面材料的晶粒, 从而有效地提高了基体的疲劳性能。喷丸对材料疲劳强度的影响通常由喷丸后材料的表层完整性、残余压应力、加工硬化三者综合作用^[4]。一方面喷丸引起的表面完整性恶化会

加速裂纹形核; 另一方面硬化层延缓了裂纹扩展, 同时残余压应力层又促进了裂纹闭合, 从而降低了裂纹扩展的驱动力。在前期研究中^[5,6], 我们已经开展了部分关于喷丸处理在提高 25CrMo 车轴钢疲劳性能方面的研究。Li 等^[5]研究了传统喷丸 (CSP)、钢微粒子喷丸 (SMSP1) 和复合喷丸 (DSP) 处理 25CrMo 车轴钢的高周疲劳性能和残余应力松弛行为。此外, Zhang 等^[6]还研究了钢微粒子喷丸 (SMSP1) 和陶瓷微粒子喷丸 (CMSP) 处理 25CrMo 车轴钢的超高周疲劳性能和残余应力松弛行为。然而, 以上研究中^[5,6]疲劳性能和残余应力松弛行为的数据是通过传统的疲劳试验获得, 这需要花费大量时间和费用。因此, 需要建立一种节约成本、使用方便的模型来预测喷丸处理 25CrMo 车轴钢的疲劳性能和残余应力松弛行为。

神经网络兴起于 20 世纪 80 年代, 其具有对复杂问题的强大非线性分析功能。众多文献^[7-11]研究表明了神经网络相比于传统高成本的试验, 在复杂和定义不明确过程的建模方面表现出了明显的优势。因此, 在不同的科学和工程领域如制造工艺^[7]、材料科学^[8,9]、生物工程^[10]和能源系统^[11]等中得到了广泛的应用。近年来, 国内外学者采用神经网络对材料疲劳寿命的预

收稿日期: 2020-03-25

基金项目: 国家自然科学基金 (51675445, U1534209); 牵引动力国家重点实验室自主研究课题 (2019TPL-T06)

作者简介: 苏凯新, 男, 1996 年生, 硕士生, 西南交通大学牵引动力国家重点实验室, 四川 成都 610031, E-mail: skx_swjtu@163.com

测模型开展了相关研究, 针对复合材料^[12]、钢^[13,14]、铝^[15]等不同材料提出了不同的神经网络预测方法。此外, 神经网络在喷丸处理方面的研究也有报道^[16,17]。Maleki 等^[16]采用了考虑喷丸强度和覆盖率以及碳含量等输入因素的 BP 神经网络模型, 预测了常规喷丸和重喷丸 AISI1045 和 1050 合金钢的疲劳寿命。Karataş 等^[17]人利用 BP 神经网络预测了喷丸处理 C-1020 材料的残余应力。然而, 基于神经网络对喷丸处理后的表层完整性、残余压应力和加工硬化三者综合作用的研究需进一步开展。Zhang 等^[18]认为残余压应力是喷丸处理中提高疲劳强度的主要因素之一, 因为它能有效抑制疲劳裂纹的扩展。但研究表明喷丸引入的残余压应力会在循环加载的机械载荷下发生松弛, 导致其有益的效果减小甚至消失^[19]。先前研究中^[5,6], 已经进行了多种喷丸 25CrMo 车轴钢表面残余压应力松弛行为的研究。然而, 喷丸残余压应力松弛过程的试验数据是基于疲劳试验所获得的, 通常也要花费较长时间。因此, 与喷丸 25CrMo 车轴钢疲劳寿命类似, 需要建立一种节约成本、预测准确和使用方便的喷丸残余应力松弛行为的预测模型。虽然, 神经网络在不同的科学和工程领域得到了十分广泛的应用^[7-17], 但至今为止, 采用神经网络分析喷丸处理 25CrMo 车轴钢残余压应力松弛行为的研究仍然鲜见报道。因此, 本研究基于神经网络对不同喷丸处理 25CrMo 车轴钢的疲劳性能和残余压应力松弛行为进行建模分析。

首先采用 BP 神经网络建立了以加载应力、粗糙度、残余压应力及其影响层深度、硬度及硬化层深度和尺寸效应为输入的喷丸 25CrMo 车轴钢疲劳寿命预测模型。在此基础上, 采用遗传算法对 BP 神经网络进行优化以提高模型的预测精度。此外, 还采用了径向基神经网络 (RBF) 进行建模, 并与以上 2 种模型的预测结果进行对比。然后, 基于遗传算法 (GA) 优化后 BP 神经网络模型的连接权值矩阵和 Garson 方程的灵敏度分析进一步量化了输入的 7 种影响因素对喷丸 25CrMo 车轴钢疲劳寿命的相对影响比重。最后, 还采用遗传算法优化后的 BP 神经网络预测了喷丸 25CrMo 车轴钢的残余压应力松弛行为。

1 材料、方法和样本数据

1.1 试验材料

试验采用的材料是 25CrMo 车轴钢 (EN13261-2011), 化学成分如表 1 所示。车轴热处理工艺为: 正火+淬火+回火。由于车轴的疲劳裂纹多从车轴表面萌生, 所以本研究中所采用的试样均取自实体车轴外表层。

表 1 25CrMo 车轴钢的化学成分

Table 1 Chemical composition of 25CrMo axle steel ($\omega/\%$)									
C	Si	Mn	P	S	Cr	Cu	Ni	Mo	Fe
0.27	0.39	0.72	0.0075	0.0013	1.11	0.01	0.25	0.25	Balance

1.2 试验方法

首先将试样加工成 2 种不同形状及尺寸的圆棒状试样, 如图 1 和图 2 所示。一种用于高周疲劳试验, 另一种用于超高周疲劳试验, 未喷丸的高周和超高周疲劳试样分别为 UP1 和 UP2。然后, 分别对 2 种不同的试样进行了不同类型的喷丸处理, 高周疲劳试样采用了传统喷丸 (CSP)、钢微粒子喷丸 (SMSP1) 和将二者结合的复合喷丸 (DSP) 处理, 超高周疲劳试样采用了钢微粒子喷丸 (SMSP2) 和陶瓷微粒子喷丸 (CMSP) 处理。采用 Olympus OLS4100 激光共聚焦显微镜、HVS-1000Z 显微硬度测试计和 Pulstec μ -X360n 残余应力测试仪分别获得了不同喷丸处理试样表面的粗糙度 (轮廓算术平均偏差 R_a)、显微硬度和残余应力等表面性能参数。然后, 分别采用筒支式 (高周疲劳试验) 和悬臂式 (超高周疲劳试验) 加载的旋转弯曲疲劳试验机 ($R=-1$) 获得了试样的疲劳 $S-N$ 数据。此外, 在疲劳试验加载到一定的预设周次时暂停试验并测量其表面残余压应力, 获得了循环加载应力作用下试样表面的残余压应力松弛过程。关于本研究中试样的形状及尺寸、疲劳试验条件、喷丸处理条件和表面性能的测量方法在先前研究的文献中已经有了详细的说明^[5,6]。同样本研究中所采用的疲劳 $S-N$ 数据以及残余压应力松弛行为数据也均来自于文献^[5,6], 所有数据的统计描述如表 2 所示。需要注意的是所有样本均不含疲劳极限 (高周疲劳试验对应循环




图 1 高周疲劳试样形状及尺寸

Fig.1 Shape and size of high-cycle specimen




图 2 超高周疲劳试样形状及尺寸

Fig.2 Shape and size of very high-cycle specimen

表 2 疲劳试验样本统计
Table 2 Statistics of fatigue test samples

Sample type	UP1	CSP	SMSP1	DSP	UP2	SMSP2	CMSP	Total
Number	8	7	7	7	5	4	4	42

周次 10^7 次、超高周疲劳试验对应循环周次 10^9 次) 时的样本数据。

1.3 疲劳性能影响因素

喷丸对材料疲劳强度的影响通常由喷丸后的材料表面完整性、残余压应力、加工硬化三者综合作用^[4]。所以为了建立一种预测喷丸 25CrMo 车轴钢疲劳性能的神经网络模型, 则需考虑喷丸处理后试样表层的性能参数(残余应力、粗糙度和硬度)对疲劳性能的影响。对于喷丸材料, Kim 等^[20]认为影响层的深度会影响喷丸的效果, 因为正如 Bagherifard 等^[21]所述, 大多数疲劳裂纹是从表面萌生, 然后逐渐向内部扩展。因此, 为了能够尽可能全面地考虑到与喷丸 25CrMo 车轴钢疲劳性能有关的因素, 又引入了残余压应力层深度和表面硬化层深度 2 种因素以表征影响层深度对喷丸 25CrMo 车轴钢疲劳性能的影响。此外, 由于高周和超高周疲劳试样形状和加载方式不同, 所以引入了尺寸效应影响因素。同时, 为了考虑疲劳试验的加载条件, 又引入了加载应力幅值影响因素。综上所述, 建立以加载应力幅值、残余压应力及其影响层深度、粗糙度、硬度及硬化层深度和尺寸效应共 7 种影响因素作为输入变量, 疲劳寿命作为输出变量的神经网络模型。未喷丸 UP (UP1 和 UP2) 试样在疲劳试验前经过了电解抛光以去除机加工表面残余应力层和硬化层的处理, 所以本研究中所有未喷丸 (UP1 和 UP2) 试样的表面残余压应力、及其影响层深度和硬化层深度均可视为 0。另外, 输入变量中的尺寸效应因素是一种定性的数据, 所以采用二进制记数法 (0 和 1) 对 2 种不同形状和尺寸的试样进行赋值^[14]。7 种影响因素如表 3 所示。

1.4 残余压应力松弛影响因素

喷丸处理后试样表面的残余压应力可以促进裂纹闭合, 并抑制裂纹扩展, 从而有效地提高材料的疲劳强度。然而, 喷丸引入的残余压应力会在循环加载的机械载荷下发生松弛, 导致其有益的效果减小甚至消

失^[19]。前期的研究^[5,6]表明喷丸残余压应力松弛过程的快慢在一定程度上取决于加载应力幅值的大小, 高加载应力的松弛过程较低加载应力迅速。Li 等^[5]还发现了在同一加载应力下, CSP 和 DSP 试样较 SMSP1 试样的残余压应力松弛过程更快。Zhang 等^[6]同样发现了 SMSP2 试样的残余压应力松弛过程较 CMSP 试样更快。这是由于试样表面大的粗糙度会使裂纹的萌生和扩展加速, 从而使喷丸试样表面残余压应力的松弛过程变快。所以, 喷丸表面残余压应力的松弛过程与加载应力和粗糙度的大小密切相关。此外, 为了准确地描述残余压应力随循环周次的松弛过程, 神经网络模型中还引入了循环周次参量。与 1.3 小节中的疲劳性能神经网络模型类似, 还考虑到了因高周与超高周疲劳试样形状和加载方式不同而带来的尺寸效应影响因素。同时, 还需引入疲劳试验前的初始残余压应力值的影响因素。综上所述, 建立以加载应力幅值、表面粗糙度、循环周次、尺寸效应和初始残余压应力值共 5 种影响因素作为输入变量, 松弛后的残余压应力值作为输出变量的神经网络模型, 以揭示喷丸试样的疲劳断裂机理。其中, 定性的尺寸效应影响因素采用二进制记数法 (0 和 1) 进行赋值^[14]。

2 神经网络模型

2.1 神经网络建模过程

在神经网络建模中, 网络训练和测试这 2 个步骤必不可少。这 2 个步骤中使用的数据是不同的, 用于测试的数据集在训练期间没有被使用过。训练过程是获得最优网络结构的关键, 而测试过程是评价训练后网络性能的必要手段^[16]。通常, 数据集中用于训练和测试的比例分别为 70% 和 30% 左右, 但它可以实际数据集和模型的性质而做相应的调整^[22]。为了避免不同数据之间范围相差过大而导致网络模型收敛速度慢和小数据被大数据湮没的问题, 采用 mapminmax 函数将输入变量和输出变量归一化到 [0,1] 之间, 训练完成后再进行数据的反归一化, 还原成实际值。此外, 为了保证训练集样本具有普适性, 采用 randperm 函数将所有样本顺序打乱, 然后随机选取预先设定数量的样本作为训练集样本, 其余的样本作为测试集样本以验证模型的泛化性。

表 3 输入变量
Table 3 Input variables

Applied stress	Surface compressive residual stress	Depth of p_2	Roughness	Surface hardness	Depth of hardened layer	Scale effect
p_1	p_2	p_3	p_4	p_5	p_6	p_7

2.2 神经网络模型

2.2.1 BP 神经网络

BP 神经网络由输入层、隐含层和输出层组成，是一种按误差逆向传播算法训练的多层前馈网络。在常用的 3 层 BP 神经网络中，如果输入层的输入变量为 p ，输出层的输出变量为 o ，则根据神经网络的映射关系，隐含层和输出层的输入输出参数可以用数学公式 (1) ~ (4) 来描述^[12]。

$$in_1 = w_1 p + b_1 \tag{1}$$

$$out_1 = f_1(in_1) \tag{2}$$

$$in_2 = w_2 out_1 + b_2 \tag{3}$$

$$out_2 = f_2(in_2) \tag{4}$$

其中：其中 in_1 和 in_2 分别为隐含层和输出层的输入参数； w_1 为连接输入层与隐含层的权重， w_2 为连接隐含层与输出层的权值； b_1 为输入层与隐含层连接的阈值， b_2 为隐含层与输出层连接的阈值； out_1 和 out_2 分别为隐含层和输出层的输出参数； f_1 和 f_2 分别为隐含层和输出层的传递函数。 out_2 可以看作是神经网络的整体输出。

对于本研究中的喷丸 25CrMo 车轴钢疲劳性能和残余压应力松弛过程的 BP 神经网络模型，前者输入变量为加载应力幅值、残余压应力及其影响层深度、粗糙度、硬度及硬化层深度和尺寸效应共 7 种影响因素，输出变量为疲劳寿命；而后者输入变量为加载应力幅值、表面粗糙度、循环周次、尺寸效应和初始残余压应力值共 5 种影响因素，输出变量为松弛后的残余压应力值。经过反复训练可知，当疲劳性能和残余压应力松弛过程 BP 神经网络模型的隐含层结点个数分别为 15 和 13 时，测试效果最佳；所以，本研究中疲劳性能和残余应力松弛过程 BP 神经网络模型的结构分别为 $7 \times 15 \times 1$ 和 $5 \times 13 \times 1$ ，结构形式如图 3 和图 4 所示。

2.2.2 遗传算法优化的 BP 神经网络

虽然 BP 神经网络具有强大的非线性分析功能，

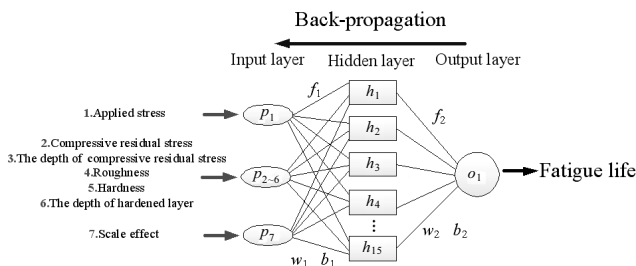


图 3 疲劳性能 BP 神经网络模型的结构

Fig.3 Structure of BP neural network of the fatigue property

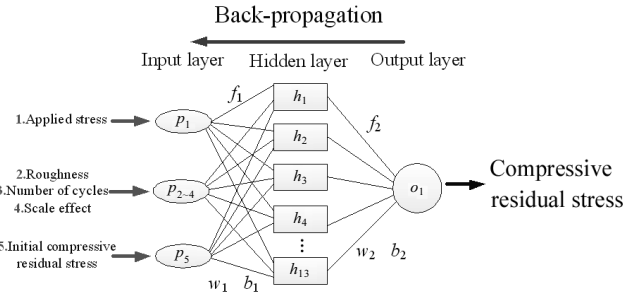


图 4 残余压应力松弛过程 BP 神经网络模型的结构

Fig.4 Structure of BP neural network of the compressive residual stress relaxation process

但容易出现局部误差极小化和收敛速度慢的问题，导致模型预测精度不高。因此，采用遗传算法 (GA) 对已经建立好的 BP 神经网络进行优化。遗传算法 (GA) 是模拟自然界遗传机制和生物进化论而成的一种并行随机搜索最优化的方法，其目的是优化 BP 神经网络的初始权值和阈值，以提高预测精度。遗传算法是以预测输出值和真实值之间的误差平方和作为个体适应度，将输入参数的个体转化为一个个独立的染色体，对这些独立的染色体进行编码，然后进行染色体之间的选择、遗传和变异。以适应度作为评价标准，根据优胜劣汰的法则，不断得到更加优化的群体，在最优群体的范围内搜索最优个体，实现遗传算法的寻优功能^[23]。

2.2.3 径向基神经网络

径向基函数 (RBF) 神经网络是具有唯一最佳逼近 (克服局部极小值问题)、训练简洁、学习收敛速度快等良好性能的前馈型神经网络。其基本思想是将低维线性不可分的数据映射到高维空间，使其在高维空间线性可分。因此本研究还采用了 RBF 神经网络分析喷丸 25CrMo 车轴钢的疲劳性能。RBF 神经网络与 2.2.1 小节中的 3 层 BP 神经网络相同，但不同的是 RBF 神经网络隐含层的激活函数为高斯型函数。

2.3 灵敏度分析

神经网络是一种由大量节点相互连接而成的计算模型，各网络层中每个连接的节点都有一个权值。权值的大小代表了输入变量对输出变量的相对影响比重^[24]，灵敏度分析就是用来量化该影响比重的一种方法，所获得的灵敏度系数即代表了影响比重。采用基于神经网络权值矩阵和 Garson 方程^[16,25]的灵敏度分析评估输入变量对输出变量的影响比重。计算方程如公式 (5) 所示^[16,25]。

$$I_j = \frac{\sum_{m=1}^{N_h} \left(\frac{|w_{jm}^{ih}|}{\sum_{k=1}^{N_i} |w_{km}^{ih}|} \right) \times |w_{mn}^{ho}|}{\sum_{k=1}^{N_i} \left\{ \sum_{m=1}^{N_h} \left(\frac{|w_{km}^{ih}|}{\sum_{k=1}^{N_i} |w_{km}^{ih}|} \right) \times |w_{mn}^{ho}| \right\}} \quad (5)$$

其中： I_j 表示第 j 个输入变量对输出变量的重要程度； N_i 和 N_h 分别为输入变量和隐含层节点个数； w 为连接权值； i 、 h 和 o 分别表示输入变量对应节点、隐含层节点和输出变量对应节点。从公式中可以看出， I_j 值越大，其对应的输入变量占全部输入变量的重要程度比例也越高。

3 结果和讨论

3.1 疲劳性能

3.1.1 疲劳寿命预测模型

采用 MATLAB 软件建立 BP 神经网络模型，训练集样本数量为 35，测试集样本数量为 7。采用基于 Levenberg-Marquardt 算法的训练函数 `trainlm`，输入层和隐含层之间的传递函数为 `logsig`，隐含层和输出层之间的传递函数为 `tansig`。性能评价函数为均方根误差 `mse`，目标误差为 0.0001，最大训练次数为 10 000，学习速率为 0.01。经过 23 次迭代之后，性能评价函数 `mse` 的值达到了 0.000 039 3，小于目标误差。训练集 35 个样本的预测值与试验值的对比如图 5 所示。从图中可以明显看出，网络训练集的预测值和试验值之间相差较小，平均预测准确率 85.7%，表明所建模型可用于喷丸 25CrMo 车轴钢疲劳寿命的预测。测试集 7 个样本预测值和试验值的对比如图 6 所示。从图中可以看出，测试集样本的预测值和试验值相差较小，平均预测精度为 80.1%，表明所建模型可以有效地实现各输入变量到疲劳寿命的映射。

采用遗传算法对建立的 BP 神经网络进行优化以提高预测准确度。遗传算法的最大进化代数为 100，种群规模 10，交叉概率为 0.3，变异概率为 0.1。经过 197 次迭代之后，性能评价函数 `mse` 达到了 0.000 012 6，小于目标误差 0.0001。经过遗传算法优化后 BP 神经网络的训练集预测值与试验值的对比如图 7 所示，平均预测准确度 91.5%。测试集 7 个样本预测值和试验值的对比如图 8 所示，平均预测准确度 85.4%。RBF 神经网络训练集和测试集样本预测值和试验值的对比如图 9 和 10 所示，平均预测准确度分别为 99.3%和 80.4%。3 种不同神经网络测试集 7 个样本的预测值和试验值的对比如图 11 所示。从图 11 中可以看出，遗传算法优化后的神经网络 (GA-BP) 和 RBF 神经网络模型的预测精度均优于 BP 神经网络，其中遗传算法

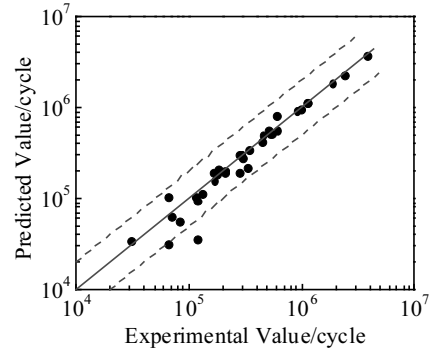


图 5 BP 神经网络训练集结果

Fig.5 Training set results of BP neural network




图 6 BP 神经网络测试集结果

Fig.6 Testing set results of BP neural network

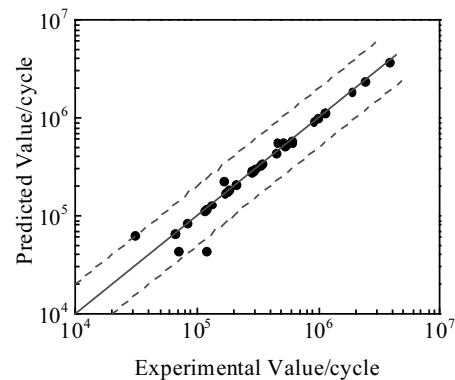


图 7 遗传算法 BP 神经网络训练集结果

Fig.7 Training set results of GA-BP neural network

优化后的神经网络 (GA-BP) 预测精度最高。

3.1.2 疲劳寿命预测模型灵敏度分析

根据 3.1 小节中 3 种神经网络模型的预测结果可知，经过遗传算法优化的 BP 神经网络的预测精度明显高于其它 2 种。所以灵敏度分析采用了基于遗传算法优化的 BP 神经网络的连接权值矩阵。提取网络权




图 8 遗传算法 BP 神经网络测试集结果
Fig.8 Testing set results of GA-BP neural network




图 11 3 种神经网络测试集结果
Fig.11 Testing results of three kinds of neural networks

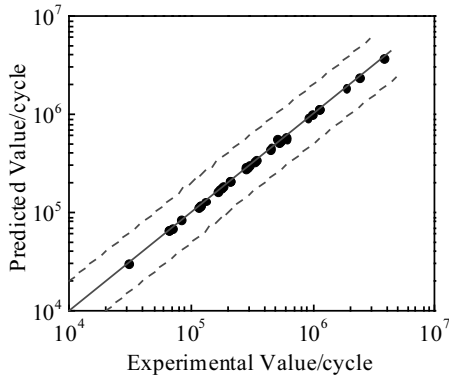


图 9 RBF 神经网络训练集结果
Fig.9 Training set results of RBF neural network

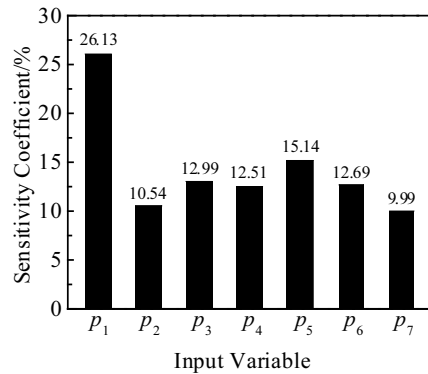


图 12 疲劳寿命预测模型的输入变量影响比重
Fig.12 Influence proportion of the input variables of fatigue life prediction model

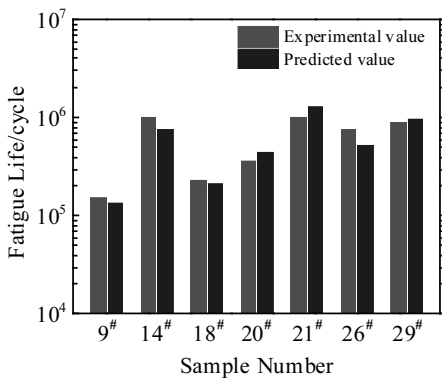


图 10 RBF 神经网络测试集结果
Fig.10 Testing set results of RBF neural network

值后代入公式 (5) 可得所有输入变量对输出变量即喷丸 25CrMo 车轴钢疲劳寿命的相对影响比重, 如图 12 所示。可以看出, 加载应力幅值 p_1 和表面硬度 p_5 对喷丸 25CrMo 车轴钢疲劳性能的相对影响比重最大, 分别为 26.13% 和 15.14%; 残余压应力影响层深度 p_3 、

硬化层深度 p_6 和表面粗糙度 p_4 三者相差较小, 均为 12% 到 13% 之间; 表面残余压应力 p_2 和尺寸效应 p_7 相对影响比重最小, 但这并不代表表面残余压应力和尺寸效应因素不重要或不考虑^[14]。

综上所述, 遗传算法优化的 BP 神经网络模型 (GA-BP) 相比于 BP 和 RBF 神经网络模型, 可以更为准确地分析喷丸 25CrMo 车轴钢的疲劳性能。此外, 灵敏度分析还明确了加载应力、喷丸表面性能参数和尺寸效应与喷丸 25CrMo 车轴钢疲劳性能之间的具体联系, 从而为优化 25CrMo 车轴钢的喷丸表面强化工艺参数提供理论参考依据。

3.2 残余压应力松弛行为

3.1 小节中证实了遗传算法优化后的 BP 神经网络比 BP 和 RBF 神经网络预测精度更高。所以本小节采用 MATLAB 软件建立基于遗传算法优化后的 BP 神经网络的残余压应力松弛行为预测模型。训练集样本数量为 143, 测试集样本数量为 30。所建模型除了输入

和隐含层节点个数与 3.1 小节中遗传算法优化的 BP 神经网络不同外，其它参数设置均相同。测试集 30 个样本的预测值与试验值的对比情况如图 13 所示，相对误差如图 14 所示，平均相对误差仅为 3.4%。所有样本的预测值与试验值的对比情况如图 15~19 所示，平均预测误差仅为 2.5%。从图 15~17 中可以看出，高周疲

劳试样的模型预测效果非常理想；而对于超高周疲劳试样，由于样本数据本身分散性较大，模型预测结果误差明显大于高周喷丸疲劳试样，但仍然可以接受，如图 18, 19 所示。综上所述，所建模型能够较为准确地预测不同喷丸处理 25CrMo 车轴钢表面残余压应力的松弛行为。

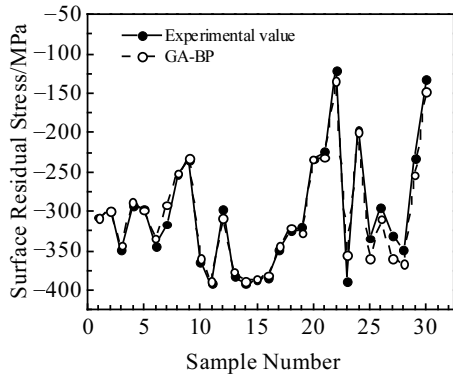


图 13 残余应力松弛的测试集结果

Fig.13 Test set predicted results of residual stress relaxation




图 14 相对误差

Fig.14 Relative error




图 15 CSP 预测结果

Fig.15 Results of CSP




图 16 SMSPI 预测结果

Fig.16 Results of SMSPI

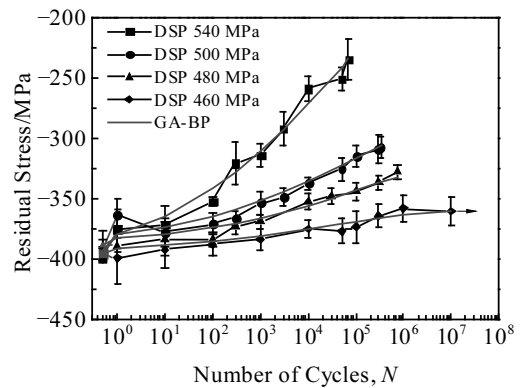


图 17 DSP 预测结果

Fig.17 Results of DSP

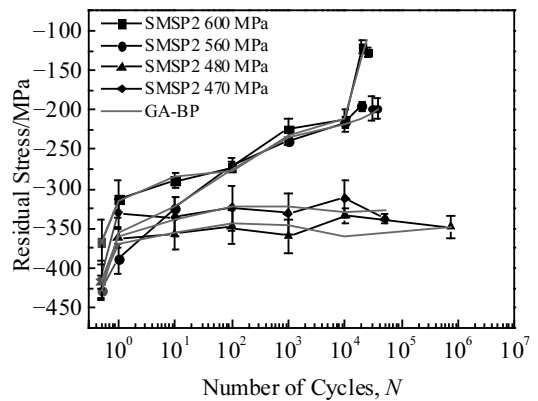


图 18 SMSPI2 预测结果

Fig.18 Results of SMSPI2

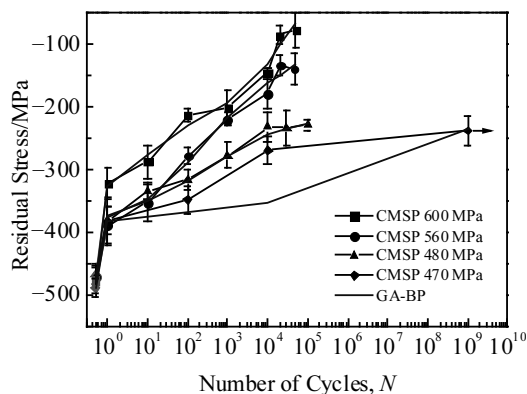


图 19 CMSP 预测结果
Fig.19 Result of CMSP

4 结 论

1) 采用 3 种不同的神经网络 (BP 神经网络、遗传算法优化后的 BP 神经网络和 RBF 神经网络) 建立了以加载应力、粗糙度、残余压应力及其影响层深度、硬度及硬化层深度和尺寸效应共 7 种影响因素为输入的喷丸 25CrMo 车轴钢疲劳寿命预测模型。经过遗传算法优化后 BP 神经网络的训练集和测试集的平均预测精度分别为 91.5%和 85.4%，相比于另外 2 种网络具有更高的预测精度。

2) 基于遗传算法优化 BP 神经网络模型的连接权值矩阵和 Garson 方程的灵敏度分析进一步量化了所有输入影响因素对喷丸 25CrMo 车轴钢疲劳寿命的影响比重。加载应力幅值是最影响喷丸 25CrMo 车轴钢疲劳寿命的输入因素，然后是表面硬度和残余压应力影响层深度。

3) 采用遗传算法优化后的 BP 神经网络预测了喷丸 25CrMo 车轴钢的残余压应力松弛行为。网络测试集的平均预测误差仅为 3.4%。

4) 采用神经网络建模预测不同喷丸处理 25CrMo 车轴钢疲劳性能和残余压应力松弛行为的方法显著降低了传统疲劳试验所需的成本，并且保证了一定的建模准确性。因此，可作为高速列车用 25CrMo 车轴钢的喷丸表面强化工艺参数优化的理论依据。

参考文献 References

[1] Chen W J, Chen H, Li C C *et al. Engineering Failure Analysis* [J], 2017, 79: 120
 [2] Regazzi D, Beretta S, Carboni M. *Engineering Fracture Mechanics*[J], 2014, 131: 587
 [3] Fajkoš R, Zima R, Strnadel B. *Fatigue & Fracture of Eng-*

ineering Materials & Structures[J], 2015, 38(10): 1255
 [4] Ramos R, Ferreira N, Ferreira J A M *et al. International Journal of Fatigue*[J], 2016, 92: 87
 [5] Li X, Zhang J W, Yang B *et al. Journal of Materials Processing Technology*[J], 2020, 275: 116 320
 [6] Zhang J X, Zhang J B, Yang B *et al. Journal of Materials Engineering and Performance*[J], 2019, 28(10): 6407
 [7] Maleki E. *IOP Conference Series: Materials Science and Engineering*[J], 2015, 103(1): 012 034
 [8] Powar A, Date P. *Materials Science and Engineering A*[J], 2015, 628: 89
 [9] Kondo R, Yamakawa S, Masuoka Y *et al. Acta Materialia*[J], 2017, 141: 29
 [10] Maleki N, Kashanian S, Maleki E *et al. Biochemical Engineering Journal*[J], 2017, 128: 1
 [11] Maleki E, Maleki N. *Journal of Electronic Materials*[J], 2016, 45(8): 3822
 [12] Xiang K L, Xiang P Y, Wu Y P. *Materials & Design*[J], 2014, 57: 180
 [13] Kang J Y, Choi B I, Lee H J *et al. International Journal of Fatigue*[J], 2006, 28(2): 132
 [14] Lotfi B, Beiss P. *Materials & Design*[J], 2013, 50: 440
 [15] Mishra S K, Brahma A, Dutta K. *Transactions of the Indian Institute of Metals*[J], 2016, 69(2): 597
 [16] Maleki E, Unal O, Kashyzadeh K R. *International Journal of Fatigue*[J], 2018, 116: 48
 [17] Karataş C, Sozen A, Dulek E. *Expert Systems with Applications*[J], 2009, 36(2): 3514
 [18] Zhang J W, Lu L T, Shiozawa K *et al. Materials Science and Engineering A*[J], 2011, 528(3): 1615
 [19] Kim J C, Cheong S K, Noguchi H. *International Journal of Fatigue*[J], 2013, 56: 114
 [20] Kim J C, Cheong S K, Noguchi H. *International Journal of Fatigue*[J], 2013, 55: 147
 [21] Bagherifard S, Fernandez-Pariente I, Ghelichi R *et al. Materials & Design*[J], 2013, 45: 497
 [22] Verpoort P C, MacDonald P, Conduit G J. *Computational Materials Science*[J], 2018, 147: 176
 [23] Zhao Chuanying(赵传营), Zhao Yugang(赵玉刚), Liu Ning (刘宁) *et al. Surface Technology*(表面技术)[J], 2020 , 49(2): 316
 [24] Shi Quan(施全), Liu Peihai(柳培海), Guo Dong(郭栋) *et al. Journal of Vibration and Shock*(振动与冲击)[J], 2017, 36(6): 175
 [25] Garson D G. *Artificial Intelligence Expert*[J], 1991, 6: 46

Prediction of Fatigue Life and Residual Stress Relaxation Behavior of Shot-Peened 25CrMo Axle Steel Based on Neural Network

Su Kaixin, Zhang Jiwang, Li Hang, Zhang Jinxin, Zhu Shoudong, Yi Kejian

(State Key Laboratory of Traction Power, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Firstly, a fatigue life prediction model of shot-peened 25CrMo axle steel was established using BP neural network. Then, the genetic algorithm (GA) was used to optimize the prediction accuracy of BP neural network. In addition, radial basis function neural network (RBF) was used for modeling and analysis, and it was compared with the prediction results of the above two models. The results show that GA-BP has higher prediction accuracy than BP and RBF neural network, and the average prediction accuracy of training set and test set are 91.5% and 85.4%, respectively. Then, the sensitivity analysis was carried out based on the connection weight matrix of GA-BP neural network model and Garson equation, so as to further quantify the relative influence proportion of the input influencing factors on the fatigue life of shot-peened 25CrMo axle steel. Finally, GA-BP neural network was used to predict the relaxation behavior of compressive residual stress on the surface of shot-peened 25CrMo axle steel. The results show that the average prediction error of the test set is only 3.4%, indicating that the network prediction performance is good. In conclusion, the neural network modeling used to analyze the fatigue performance and compressive residual stress relaxation behavior of shot-peened 25CrMo axle steel, significantly reduces the cost of traditional fatigue test and ensures the high accuracy.

Key words: shot peening; neural network; genetic algorithm; fatigue life prediction; residual stress relaxation

Corresponding author: Zhang Jiwang, Ph. D., Professor, State Key Laboratory of Traction Power, Southwest Jiaotong University, Chengdu 610031, P. R. China, Tel: 0086-28-87600843, E-mail: zhangjiwang@swjtu.cn