DOI：10.13890/j.issn.1000-128X.2023.02.104　　文章编号：1000-128X(2023)02-0043-07

功率模块铜线键合工艺参数优化设计

胡　彪[1]，成兰仙[1]，李振铃[1]，戴小平[2,3]
（1.华南农业大学 电子工程学院（人工智能学院），广东 广州　510642；
2.湖南国芯半导体科技有限公司，湖南 株洲　412001；
3.湖南省功率半导体创新中心，湖南 株洲　412001）

摘　要：为了提高功率模块铜线键合性能，采用6因素5水平的正交试验方法，结合BP（Back Propagation）神经网络与遗传算法，提出了一种铜线键合工艺参数优化设计方案。首先，对选定样品进行正交试验并将结果进行极差分析，得到工艺参数对键合质量的影响权重排序。其次，运用BP神经网络构建了铜线键合性能预测模型，并通过遗传算法对BP神经网络适应度函数求解，得到了工艺参数的最优值。将BP-遗传算法与传统优化方法的优化结果进行对比，发现经BP-遗传算法优化后的铜线键合工艺稳定性提升更加明显。最后，对功率模块进行了功率循环试验，结果表明经BP-遗传算法优化后的模块功率循环能力得到显著提升。

关键词：铜线键合；BP神经网络；遗传算法；工艺参数优化
中图分类号：TG457.13；TN605　　**文献标识码：**A

Optimization design on process parameters of copper wire bonding for power modules

HU Biao[1], CHENG Lanxian[1], LI Zhenling[1], DAI Xiaoping[2,3]

(1. College of Electronic Engineering (College of Artificial Intelligence), South China Agricultural University, Guangzhou, Guangdong 510642, China; 2. Coresing Semiconductor Technology Co., Ltd., Zhuzhou, Hunan 412001, China; 3. Hunan Power Semiconductor Manufacturing Innovation Center, Zhuzhou, Hunan 412001, China)

Abstract: In order to improve the copper wire bonding performance of the power modules, an optimization design scheme of process parameters for copper wire bonding was proposed by using the six-factor five-level orthogonal test method, and combining the back propagation (BP) neural network and genetic algorithm (GA). Firstly, the selected samples were orthogonally tested and the results were analyzed by range analysis to generate the influence weight ranking of the process parameters on the bonding quality. Secondly, a prediction model of copper wire bonding performance was constructed using the BP neural network, and the optimal values of process parameters were generated by solving the BP neural network fitness function with GA. Comparing the optimization results from the BP genetic algorithm with those from the traditional methods, the former was found in the stability of the copper wire bonding process improved more significantly. Finally, the power cycle test was carried out on the power module, showing that the power cycle capability of the module optimized by the BP genetic algorithm was significantly improved.

Keywords: copper wire bonding; BP neural network; genetic algorithm; optimization of process parameters

0　引言

功率模块引线键合技术是指模块内部硅基芯片或SiC芯片与陶瓷衬板间，以及陶瓷衬板与功率端子间的电气互连技术[1]。随着功率模块的电流密度不断提高，传统粗铝线在通流能力与耐温能力等方面都难以满足

基金项目：国家自然科学基金项目（61804057）
通信作者：成兰仙（1981—），女，博士，副教授，硕士生导师，主要从事先进微电子封装材料及其工艺、电力传动及其控制系统方面的研究；E-mail: chenglx@scau.edu.cn
引用格式：胡彪, 成兰仙, 李振铃, 等. 功率模块铜线键合工艺参数优化设计[J]. 机车电传动, 2023(2): 43-49.
Citation: HU Biao, CHENG Lanxian, LI Zhenling, et al. Optimization design on process parameters of copper wire bonding for power modules[J]. Electric Drive for Locomotives, 2023(2): 43-49.

封装要求，具有更强通流能力的铜线凭借其自身优异的力学和热学性能，受到了业界的极大关注[2]。

对于功率模块引线键合质量与性能的相关研究，目前主要运用的是基于试验与仿真的方法。文献[3-5]通过对粗铝丝进行键合试验，得到了超声功率、键合压力、键合时间3个工艺参数，以及这3个参数与键、性能之间的影响权重关系；文献[6]采用极差分析法对功率模块芯片区域的第一键合点与第二键合点进行系统研究，确定了粗铝线键合的最优工艺参数；文献[7]运用响应面法（response surface methodology，RSM）进行数据建模，得到了优化后的超声楔形焊工艺参数。近年随着深度学习被广泛应用在各学科领域，基于数据的方法开始出现在功率模块引线键合研究中，这类方法目前主要应用于功率模块引线键合的失效分析与模块寿命预测中，在铜线键合性能研究中的应用仍不常见。文献[8]使用基于神经网络的键合线状态评估方法，对IGBT模块键合线故障进行在线监测，有效地提高了功率模块的可靠性；文献[9]基于改进后的小波神经网络建立了IGBT时间序列预测模型，对评估IGBT运行状态与预测剩余寿命提供了支持。分析国内外相关研究可以发现，针对引线键合的工艺研究一般基于极差分析或RSM等传统方法，然而随着试验水平数量与试验次数的增加，该类方法得到的优化工艺值准确度偏低，不利于实际生产。

为了更好地对键合工艺参数进行优化，提升功率模块铜线键合性能，本文以6因素5水平的正交试验为基础，采用BP（Back Propagation）神经网络预测和遗传算法反向求解铜线键合点最优键合工艺参数值，为功率模块铜线键合的工艺参数优化设计提供了一种新方法。将传统优化方法与“BP–遗传算法”进行优化结果对比，“BP–遗传算法”对键合工艺稳定性的提升明显；对功率模块进行功率循环试验，发现随着超声功率的不断优化，模块功率循环寿命也得到显著提高。

1 正交试验

1.1 试验材料及设备

在本次试验中，键合铜线分别采用A品牌与B品牌，技术规格如表1所示。衬板采用AMB（Active Metal Bonding）衬板，外形尺寸（长×宽×厚）为28 mm×26 mm×0.92 mm [0.3(Cu)/0.32(ceramic)/0.3(Cu)]；铜箔采用DTS（Die Top System）铜箔，尺寸为4.2 mm×2.8 mm×0.1 mm。试验选用全自动引线键合机进行铜线键合，搭配推拉力测试仪对铜线键合强度进行测试。

表1 A品牌与B品牌铜线技术规格

Table 1 Technical specifications of brand A and brand B copper wire

品牌	直径/mm(或mils)	伸长率/%	断裂载荷/cN	抗变形指数
A	0.304 8(12)	15	800~1 500	0.83
B	0.304 8(12)	15	800~1 500	0.81

1.2 试验及结果

相比于铝线键合，铜线键合的工艺参数设置整体偏大。因此，在进行键合工艺前，需要先在功率芯片表面烧结1层DTS铜箔，避免劈刀与芯片的直接接触。图1为使用DTS工艺的键合点示意图，由于键合位置的不同，分别标记为键合点1与键合点2。根据DTS工艺中铜线键合参数的经验值，分别列出键合点1与键合点2因素水平表，如表2所示。将本试验所确定的因素水平进行分析，设计6因素5水平共25组试验的正交试验方案，同时为了减小偶然因素与试验方法带来的误差影响，规定每组工艺参数组合进行10次重复试验[10]，共计得到250组试验结果，作为后续分析的样本数据。25组样品经过10次重复试验得到的键合点剪切力之和，作为功率模块铜线键合正交试验的结果，如表3所示。

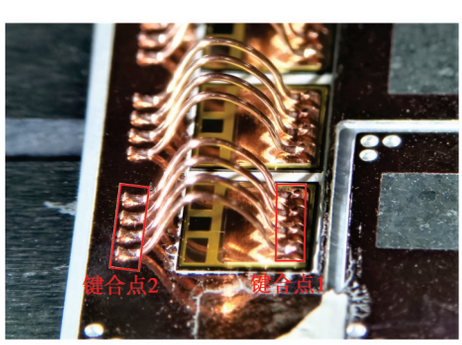


图1 铜线键合点示意图

Fig. 1 Schematic diagram of copper wire bonding point

表2 铜线键合因素水平表

Table 2 Bonding factor level table of copper wire

水平	键合点1			键合点2		
	因素A（超声功率/%）	因素B（键合压力/cN）	因素C（键合时间/ms）	因素D（超声功率/%）	因素E（键合压力/cN）	因素F（键合时间/ms）
1	25	800	80	30	950	110
2	30	950	100	35	1 100	130
3	35	1 100	120	40	1 250	150
4	40	1 250	140	45	1 400	170
5	45	1 400	160	50	1 550	190

表3　铜线键合正交试验结果

Table 3　Orthogonal test results of copper wire bonding

试验组号	因素						键合点1（A/B）剪切力之和/N	键合点2（A/B）剪切力之和/N
	A	B	C	D	E	F		
1	1	1	1	1	1	1	102.4/100.4	182.1/183.1
2	1	2	2	2	2	2	143.3/144.3	255.6/250.6
3	1	3	3	3	3	3	184.2/184.6	309.2/303.2
4	1	4	4	4	4	4	197.9/200.9	310.4/306.4
5	1	5	5	5	5	5	189.7/191.7	309.7/314.7
6	2	1	2	3	4	5	166.4/168.4	290.7/285.7
7	2	2	3	4	5	1	202.1/203.1	287.1/291.1
8	2	3	4	5	1	2	231.1/234.1	231.2/232.2
9	2	4	5	1	2	3	240.7/244.7	215.3/218.3
10	2	5	1	2	3	4	220.3/223.3	273.1/277.1
11	3	1	3	5	2	4	201.8/199.8	295.4/299.4
12	3	2	4	1	3	5	223.9/221.9	240.6/240.6
13	3	3	5	2	4	1	269.9/269.9	276.9/273.9
14	3	4	1	3	5	2	247.2/247.2	272.2/277.2
15	3	5	2	4	1	3	270.7/265.7	274.3/270.3
16	4	1	4	2	5	3	228.2/226.2	301.1/300.1
17	4	2	5	3	1	4	233.9/231.9	290.9/289.9
18	4	3	1	4	2	5	262.3/266.3	259.3/255.3
19	4	4	2	5	3	1	288.9/293.9	280.1/279.1
20	4	5	3	1	4	2	286.9/289.9	245.1/241.1
21	5	1	5	4	3	2	197.1/200.1	311.4/317.4
22	5	2	1	5	4	3	211.3/207.3	299.4/299.4
23	5	3	2	1	5	4	280.2/277.2	251.5/253.5
24	5	4	3	2	1	5	302.1/299.1	265.8/261.8
25	5	5	4	3	2	1	302.3/306.3	299.5/296.5

1.3　极差分析法

对正交试验的结果进行极差分析，极差值R越大，表明该因素对试验结果的影响越显著，该因素为主要因素；极差值R越小，表明该因素为次要因素。A品牌与B品牌的铜线键合点剪切力均值与极差响应分析结果分别如表4所示。由表4可知，2种品牌的铜线键合试验结果具有一致性，影响单一键合点剪切强度的主要因素皆为该点的超声功率、键合压力与键合时间，其中超声功率对剪切强度的影响最为明显。

由极差分析结果可得出2种品牌铜线的最优键合参数组合：对于键合点1，最优工艺参数组合为A4B4C4；对于键合点2，最优工艺参数组合为D3E4F3。

2　工艺参数优化

2.1　剪切力预测模型

本文所建立的BP神经网络采用双隐含层的结构[11-13]。最佳隐含层节点数的选取如下：

$$N_{\mathrm{h}}=\mathrm{round}\left(\frac{N_{\mathrm{s}}}{\alpha\left(N_{\mathrm{i}}+N_{\mathrm{o}}\right)}\right) \tag{1}$$

式中：N_{h}为隐含层节点数；N_{s}为训练集中的样本数；N_{i}为输入层节点数；N_{o}为输出层节点数；α的取值范围通常为2~10；round( )表示取整。

在工程中，一般先由式(1)确定隐含层节点数的大致范围，再采用试凑法确定隐含层最佳节点数。如将输入层节点数6、输出层节点数2和样本数250代入式(1)，用试凑法确定的最佳值为9[14]，由此得最佳隐含层节点数为10。

表4　A/B两种品牌键合点剪切力均值与极差响应

Table 4　Bonding point shear force mean and extreme difference response of brand A/B　　N

水平	因素A	因素B	因素C	因素D	因素E	因素F
1	163.5/164.4	179.2/179.0	208.7/208.9	226.8/226.8	228.0/226.2	233.1/234.7
2	212.1/214.7	202.9/201.7	229.9/229.9	232.8/232.6	230.1/232.3	221.1/223.1
3	242.7/240.9	245.5/246.4	235.4/235.3	226.8/227.7	222.9/224.8	227.0/225.7
4	260.0/261.6	255.4/257.2	236.7/237.9	226.0/227.2	226.5/227.3	226.8/226.6
5	258.6/258.0	254.0/255.4	226.3/227.7	224.6/225.4	229.5/229.1	228.9/229.5
极差	96.5/97.2	76.2/78.2	28.0/29.0	8.2/7.2	7.2/7.5	12.0/11.6
排秩（A/B）	1/1	2/2	3/3	5/6	6/5	4/4
水平	因素A	因素B	因素C	因素D	因素E	因素F
1	268.5/261.6	274.7/263.1	262.2/258.4	226.9/227.3	248.9/247.5	259.1/264.7
2	271.9/263.9	276.1/268.3	270.4/261.8	274.5/272.7	265.0/264.0	267.1/263.7
3	273.4/267.3	280.6/274.6	272.5/269.3	292.5/290.5	282.9/283.5	279.9/278.3
4	280.3/272.1	278.8/272.6	273.6/264.2	288.5/288.1	284.5/287.3	284.3/285.3
5	275.3/270.7	270.3/265.9	269.8/262.8	283.2/285.0	284.3/281.3	273.2/271.6
极差	11.8/10.5	10.3/11.5	11.4/10.9	65.6/63.2	35.6/39.8	25.2/21.6
排秩（A/B）	4/6	6/4	5/5	1/1	2/2	3/3

为了避免输入数据之间存在不同量级而导致误差波动，本文对训练样本进行了归一化处理[15]，具体计算如下：

$$x=\frac{x_{\mathrm{m}}-x_{\min}}{x_{\max}-x_{\min}} \tag{2}$$

式中：x为归一化后的数据；x_{m}为某个输入参数的实际值；$x_{\min}$, $x_{\max}$分别表示训练集中此参数的最小值和最大值。

均方误差（Mean Square Error，MSE）函数可以较为精准地反映预测值与实际之间的估计量，因此选择将BP神经网络的损失函数确定为MSE函数，如下所示：

$$\mathrm{MSE}\left(y_i-\hat{y}_i\right)=\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2 \tag{3}$$

式中：n为样本总数；$\hat{y}_i$为样本i的预测值；y_i为样本i的实际值。

由于A、B这2种品牌铜线键合点的剪切力与极差分析结果具有一致性，为了减少运算量提升运算速度，只选取其中1组数据进行BP神经网络建模分析。选择A品牌铜线键合点1与键合点2的超声功率比、键合压力和键合时间作为BP神经网络的输入，键合点1与键合点2的剪切力值作为BP神经网络的输出，可建立如图2所示的6×p×q×2的BP神经网络，其中p和q为隐含层1和隐含层2神经元的数目。

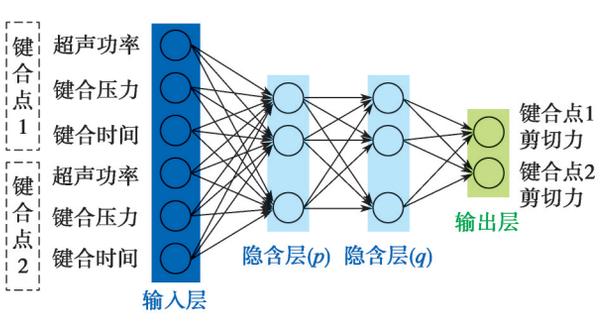
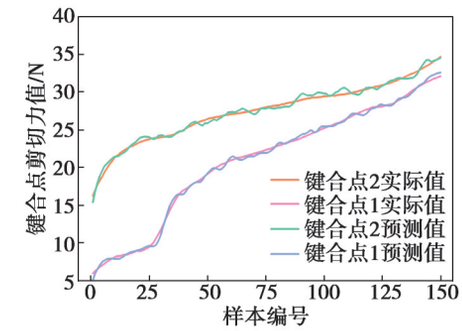


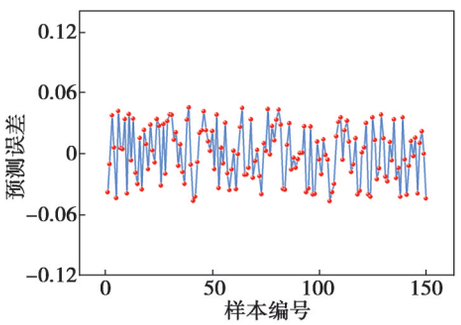
图2 BP神经网络结构

Fig. 2 Structure of BP neural network

图3为BP神经网络预测图与相对误差图，其中最大相对误差不超过4.7%。训练完成后的BP神经网络具有较高的预测性能，可通过任意输入工艺参数值较为准确地预测键合点的剪切力值，既能有效地检验键合设备的运行工况，及时对磨损的劈刀进行更换，又能为铜线键合工艺参数优化提供可靠的模型依据。



(a) BP神经网络预测



(b) 相对误差

图3 BP神经网络预测与相对误差

Fig. 3 BP neural network prediction and relative error

2.2 遗传算法优化

通过在训练完成后的BP神经网络中输出预测值，将此预测值编写成适应度函数，并在遗传算法中进行选择、交叉与变异，不断迭代优化，进而反向求解寻找到最佳适应度值[16]。本文采取在已有较优工艺参数组合的条件下，结合经验值，对工艺参数组合数值进行小范围调整，然后利用遗传算法进行迭代寻优。分别设定键合点1与键合点2的超声功率范围为32%~43%和36%~52%，键合压力范围为955~1 180 cN和1 030~1 285 cN，键合时间范围为135~155 ms和140~165 ms。遗传算法进化迭代次数N为500次，种群规模n=20，交换概率为0.4，变异概率为0.02。

迭代开始时的适应度值最高，其值为0.043 1。随着迭代的进行，在算法进化至157次之后，适应度值达到最低，为0.037 6，如图4所示。对比遗传算法寻优前后的适应度值可发现，适应度值下降了14.6%，优化效果明显。适应度函数收敛处的最优个体平均值为最佳工艺参数。使用“BP–遗传算法”与传统优化方法所得到的最优工艺参数值如表5所示。

表5 优化后的铜线键合最佳工艺参数值

Table 5 Optimal process parameters of copper wire bonding after optimization

算法	键合点1			键合点2		
	超声功率/%	键合压力/cN	键合时间/ms	超声功率/%	键合压力/cN	键合时间/ms
BP–遗传算法	35	1 045	142	39	1 155	153
极差分析法	40	1 250	140	40	1 400	150
RSM	36	1 230	135	37	1 340	145

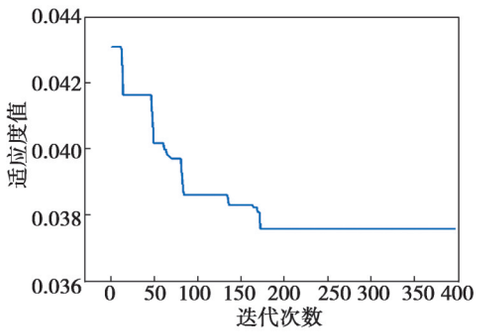


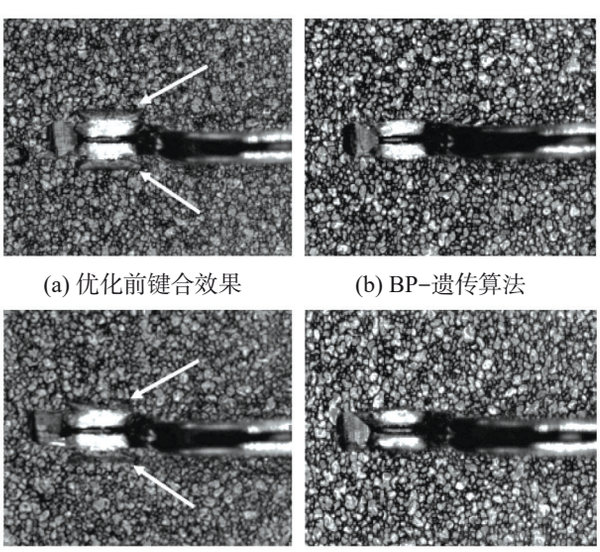
图4　遗传算法寻优迭代曲线

Fig. 4　Genetic algorithm optimization iteration curve

3　优化验证分析

3.1　不同优化方法优化结果对比

采用不同优化方法得到的最佳工艺参数在AMB衬板上进行铜线键合试验，键合点2的键合效果图如图5所示。在保持剪切强度25 N的前提下，工艺参数优化前后键合点呈现出不同的键合效果：参数优化前，劈刀在键合点两侧产生了明显压痕，如图5(a)中的箭头标识所示，这是由于给定的工艺参数过大所导致的；而在参数优化后，只有极差分析法组的键合点两侧出现了明显的压痕。分析不同优化方法所得到的最佳工艺参数数值可知，虽然该组的超声功率数值与“BP–遗传算法”组的相近，但其键合压力给定过大；而RSM组的键合压力数值偏大，不过其超声功率数值较小，从而导致了不同的键合效果。



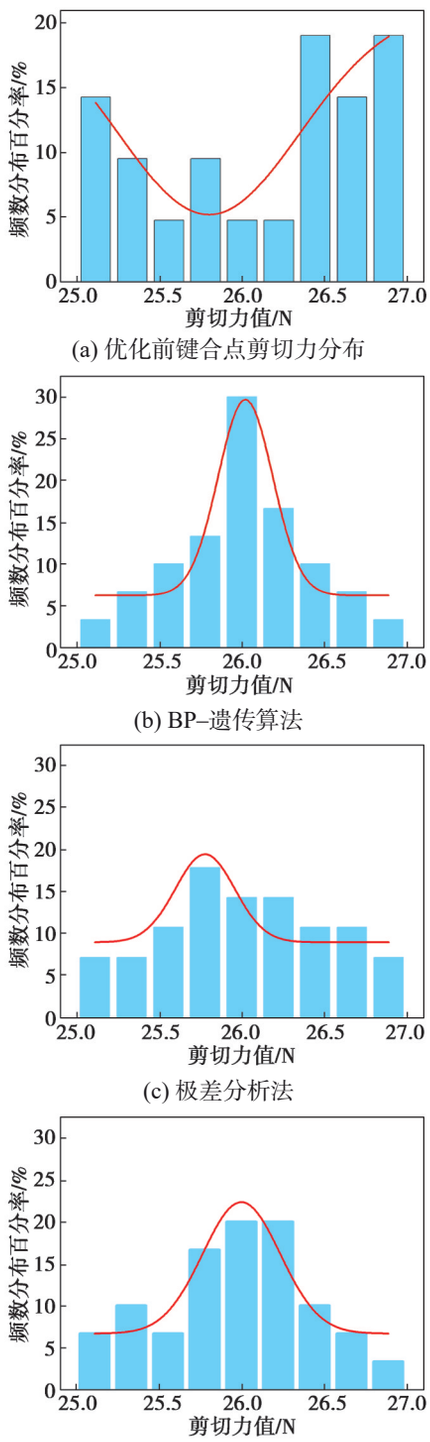
(a) 优化前键合效果　(b) BP–遗传算法

(c) 极差分析法　(d) RSM

图5　各种优化方法键合效果对比

Fig. 5　Comparison of bonding effect among optimization methods

参数优化前后键合点的剪切力分布如图6所示。从图6(a)中可知，在工艺参数优化前，键合点剪切力分布不均匀，频数波动较大，影响了键合工艺的稳定性，不利于实际生产。对使用3种不同优化方法下的键合点剪切力分布进行高斯拟合，并进行决定系数（Coefficient Of Determination，COD）比较，COD值越大，表明高斯拟合优度越高，结果如表6所示，“BP–遗传算法”组的COD值最大，相比于传统的极差分析法与RSM分别提升了36.2%与13.3%，表明其键合点剪切力分布最趋近于正态分布，键合工艺的稳定性更高。



(a) 优化前键合点剪切力分布

(b) BP–遗传算法

(c) 极差分析法

(d) RSM

图6　各优化方法优化后剪切力分布对比

Fig. 6　Comparison of shear force distribution among optimization methods

表6　各优化方法高斯拟合COD决定系数对比

Table 6　Comparison of Gaussian fitting coefficient of determination (COD) among optimization methods

算法	COD 系数
BP–遗传算法	0.94
极差分析法	0.69
RSM	0.83

3.2　功率模块试制与功率循环试验

当功率模块工作时，键合点1与DTS铜箔端直接接触，其承受的温度应力变化相比于键合点2更大。为评估工艺参数优化对整模块可靠性的影响，选取“BP–遗传算法”组参数与2个试验组进行功率模块试制与功率循环试验，其中2个试验组工艺参数为仅在“BP–遗传算法”组的基础上对键合点1的超声功率做梯度变化。图7为试制的1 200 V SiC 汽车级功率模块，芯片背面互连采用银烧结工艺，芯片正面采用DTS工艺进行铜线键合。

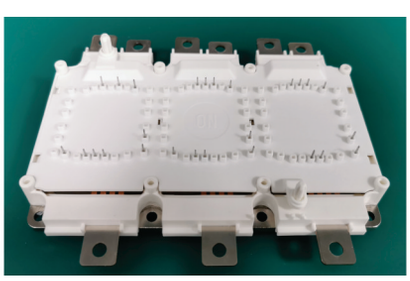


图7　1 200 V SiC 汽车级试制功率模块

Fig. 7　1 200 V SiC power module on automotive grade pilot production

图8为在不同超声功率下3组试制模块与1组直径0.304 mm（12 mils）铝线试制模块的功率循环能力对比图。铝线试制模块中的芯片与衬板互连采用的是传统钎焊工艺，同时由于铝线本身材料属性，因此其功率循环次数最少。

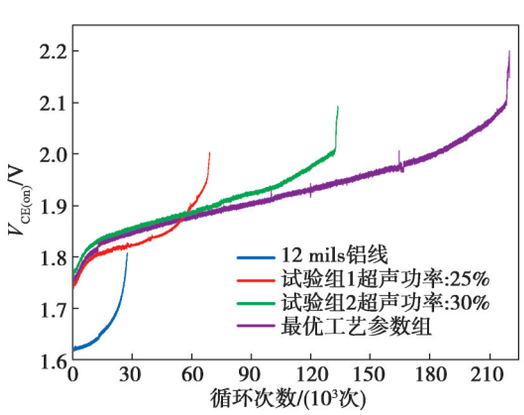


图8　不同超声功率下的模块功率循环能力对比

Fig. 8　Comparison of power cycling capacity among modules with different ultrasonic power

表7为各试制模块的具体功率循环次数结果。由表7可知，随着键合参数的优化，试制模块的功率循环寿命也显著提高；在3组模块的失效模式中，试验组1表现为部分键合点1翘起，这是由于低超声功率的键合点1其底部与衬底的互连层无法承受频繁的切应力变化所导致的；试验组2表现为少数键合点1松动；而最优工艺参数组的失效模式为AMB衬板与散热器基板之间出现了大规模空洞，但这并不是铜线键合工艺所导致的。

表7　不同组别功率循环次数

Table 7　Number of power cycles for different groups

试验组别	12 mils 铝线	试验组 1	试验组 2	最优参数组
循环次数	27 212	67 425	132 519	218 641

4　结论

本文在正交试验的基础上，结合BP神经网络与遗传算法提出了一种新的功率模块铜线键合工艺参数优化策略，以提高铜线的超声键合性能。在工艺参数优化设计中，首先采用极差分析法系统分析了工艺参数对键合点剪切力的影响权重，然后使用BP神经网络建立了对铜线键合点剪切力的预测模型，最后采用遗传算法对键合性能的适应度函数进行求解，从而获得最优工艺参数值。将“BP–遗传算法”与传统优化方法的优化结果进行对比，经“BP–遗传算法”优化后的工艺参数更能提高键合工艺的稳定性；在功率循环试验中，发现随着超声功率比的不断优化，功率模块的功率循环能力得到了显著提升。

参考文献：

[1]　吴义伯, 戴小平, 王彦刚, 等. IGBT功率模块封装中先进互连技术研究进展[J]. 大功率变流技术, 2015(2): 6-11.
WU Yibo, DAI Xiaoping, WANG Yangang, et al. State-of-the-art progress of advanced interconnection technology for IGBT power module packaging[J]. High Power Converter Technology, 2015(2): 6-11.

[2]　LING Jamin, XU Tao, LUECHINGER C, et al. Large-Cu-wire wedge bonding on wafers with Cu pad metallization [C]//VDE-Verlag. PCIM Europe, International Exhibition and Conference for Power Electronics, Intelligent Motion, Renewable Energy and Energy Management. Shanghai: VDE-Verlag, 2012: 767-775.

[3]　王福亮, 韩雷, 钟掘. 超声功率对粗铝丝超声引线键合强度的影响[J]. 中国机械工程, 2005, 16(10): 919-923.
WANG Fuliang, HAN Lei, ZHONG Jue. Effects of ultrasonic power on heavy aluminum wire wedge bonding strength[J]. China Mechanical Engineering, 2005, 16(10): 919-923.

[4]　王福亮, 李军辉, 韩雷, 等. 键合时间对粗铝丝超声引线键合强度的影响[J]. 焊接学报, 2006, 27(5): 47-51.
WANG Fuliang, LI Junhui, HAN Lei, et al. Effect of bond-

ing time on thick aluminum wire wedge bonding strength [J]. Transactions of the China Welding Institution, 2006, 27 (5): 47-51.

[5] 高荣芝, 韩雷. 键合压力对粗铝丝引线键合强度的实验研究[J]. 压电与声光, 2007, 29(3): 366-369.
GAO Rongzhi, HAN Lei. Experimental studies of bonding pressure on heavy aluminum wire bonding strength[J]. Piezoelectrics & Acoustooptics, 2007, 29(3): 366-369.

[6] 张玉佩, 张茹, 戎光荣. 功率器件引线键合参数研究[J]. 电子与封装, 2021, 21(7): 070202.
ZHANG Yupei, ZHANG Ru, RONG Guangrong. Research on parameters of wire bonding for power devices[J]. Electronics & Packaging, 2021, 21(7): 070202.

[7] 程顺昌, 王晓强, 吕玉冰, 等. 试验设计方法在超声楔形焊工艺优化中的应用[J]. 半导体光电, 2013, 34(6): 987-989.
CHENG Shunchang, WANG Xiaoqiang, LYU Yubing, et al. Application of DOE in the optimization of ultrasonic wedge bond process[J]. Semiconductor Optoelectronics, 2013, 34 (6): 987-989.

[8] 何怡刚, 周健波, 刘嘉诚, 等. 改进IGBT动态模型与电-热-力多物理场耦合失效分析[J]. 电子测量与仪器学报, 2019, 33(8): 46-54.
HE Yigang, ZHOU Jianbo, LIU Jiacheng, et al. Improved IGBT dynamic model and electro-thermal-force multiphysics coupling failure analysis[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 46-54.

[9] 黄柯勋, 吴松荣, 向碧楠, 等. 基于改进小波神经网络的IGBT时间序列预测算法研究[J]. 机车电传动, 2021(5): 161-166.
HUANG Kexun, WU Songrong, XIANG Binan, et al. Research on IGBT sequentially prediction algorithm based on improved wavelet neural network[J]. Electric Drive for Locomotives, 2021(5): 161-166.

[10] 彭爱红. Minitab软件在有重复试验的正交试验设计中的应用[J]. 集美大学学报(教育科学版), 2013, 14(1): 111-114.
PENG Aihong. Application of Minitab software in orthogonal experimental design with duplicate test[J]. Journal of Jimei University (Education Science Edition), 2013, 14(1): 111-114.

[11] 胡海青, 张琅, 张道宏. 供应链金融视角下的中小企业信用风险评估研究——基于SVM与BP神经网络的比较研究[J]. 管理评论, 2012, 24(11): 70-80.
HU Haiqing, ZHANG Lang, ZHANG Daohong. Research on SMEs credit risk assessment from the perspective of supply chain finance：a comparative study on the SVM model and BP model[J]. Management Review, 2012, 24(11): 70-80.

[12] PANCHAL G, GANATRA A, KOSTA Y P, et al. Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers[J]. International Journal of Computer Theory and Engineering, 2011, 3(2): 332-337.

[13] 左付山, 李政原, 吕晓, 等. 基于BP神经网络的汽油机尾气排放预测[J]. 江苏大学学报(自然科学版), 2020, 41(3): 307-313.
ZUO Fushan, LI Zhengyuan, LYU Xiao, et al. Prediction of gasoline engine exhaust emission based on BP neural network[J]. Journal of Jiangsu University (Natural Science Edition), 2020, 41(3): 307-313.

[14] 王雪辉. 基于数据挖掘技术的股票预测研究与应用[D]. 海口: 海南大学, 2020.
WANG Xuehui. Research and application of stock forecast based on data mining technology[D]. Haikou: Hainan University, 2020.

[15] 周畅, 米红娟. 深度学习中三种常用激活函数的性能对比研究[J]. 北京电子科技学院学报, 2017, 25(4): 27-32.
ZHOU Chang, MI Hongjuan. A comparative study on the performance of three kinds of activation functions in deep learning[J]. Journal of Beijing Electronic Science and Technology Institute, 2017, 25(4): 27-32.

[16] 李岩, 袁弘宇, 于佳乔, 等. 遗传算法在优化问题中的应用综述[J]. 山东工业技术, 2019(12): 242-243.
LI Yan, YUAN Hongyu, YU Jiaqiao, et al. A review on the application of genetic algorithm in optimization problems [J]. Shandong Industrial Technology, 2019(12): 242-243.

收稿日期：2022-08-01
修回日期：2022-12-25