



(12) 发明专利

(10) 授权公告号 CN 108615075 B

(45) 授权公告日 2021.09.28

(21) 申请号 201810439606.3

(22) 申请日 2018.05.09

(65) 同一申请的已公布的文献号

申请公布号 CN 108615075 A

(43) 申请公布日 2018.10.02

(73) 专利权人 深圳市微埃智能科技有限公司

地址 518052 广东省深圳市前海深港合作区前湾一路35号前海深港青年梦工厂7栋1层104室

(72) 发明人 褚英昊 赵辛 秦诗玮 黄琛

何英杰 赵紫州 叶丹微 吴嘉杰

(51) Int. Cl.

G06N 3/08 (2006.01)

G06F 30/20 (2020.01)

(56) 对比文件

CN 101807265 A, 2010.08.18

CN 103959769 A, 2014.07.30

US 6556876 B1, 2003.04.29

US 2016155065 A1, 2016.06.02

审查员 张驰

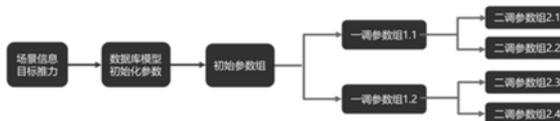
权利要求书1页 说明书4页 附图1页

(54) 发明名称

一种自动化调参方法

(57) 摘要

本发明涉及一种自动化调参方法,该方法可以应用在半导体封装的超声焊线设备上,包括以下步骤:根据历史数据库生成初始参数组合,所述参数组合包括冲击预压力、冲击时间、冲击压力、焊线时间、焊线压力、和焊线能量中的一种或多种;超声焊线设备根据初始参数组合执行并测量产品的质量系数;根据产品质量系数反馈更新参数组合;重复上述步骤直到产品质量系数全部合格。本发明以场景信息和目标效果(量化)分别作为“输入”和“结果”,以目标优化参数(量化)作为模型优化的“内置参数”。该模型在实际应用中生成现场收集少量数据即可生成一个状态空间模型,同时通过基于反向传播算法的VNN算法搜索所需的优化参数组合。



1. 一种自动化调参方法,应用在半导体封装超声焊线设备上,其特征在于,包括以下步骤:

根据历史数据库生成初始参数组合,所述参数组合包括冲击预压力、冲击时间、冲击压力、焊线时间、焊线压力、和焊线能量中的一种或多种;

超声焊线设备根据初始参数组合执行并测量产品的质量系数;

根据产品质量系数反馈更新参数组合;

重复上述步骤直到产品质量系数全部合格;

所述根据产品质量系数反馈更新参数组合步骤,包括:

基于MLP状态模型,输入初始参数X向量,计算输出推力;

微调各个输入参数 Δx ,分别计算每个参数变化带来的最终推力的变化 Δy ;

计算每个参数维度上的梯度变化 $\Delta G = \Delta y / \Delta x$;

计算输出推力到目标推力的距离值 ϵ ;

计算当前距离 ϵ 下,基于梯度变化 ΔG 的每个输入维度的参数更新量: $D = \epsilon / \Delta G$;

通过常用的学习速率 α 更新初始参数 $X_{new} = X + \alpha D$;

重复上述6步,直到 ϵ 小于一个阈值 $\theta = 1$,输出最新的X向量,即为通过VNN搜索方法获得的优化的参数组合。

2. 根据权利要求1所述的方法,其特征在于,如果搜索结果未能满足需求,则将新测量结果和旧结果合并重新在线训练MLP状态空间模型和进行VNN搜索;输入到所述MLP状态空间模型的参数包括冲击预压力、冲击时间、冲击压力、焊线时间、焊线压力、和焊线能量中的一种或多种。

3. 根据权利要求1所述的方法,其特征在于,所述MLP状态空间映射模型方法如下:在现场收集最少3个数据点,每个数据点包一组参数和一个推力测量结果,采用MLP多层感知神经网络。

4. 根据权利要求1所述的方法,其特征在于,所述根据产品质量系数反馈更新参数组合步骤,包括:

通过基于反向传播算法的VNN算法搜索所需的优化参数组合。

5. 根据权利要求1所述的方法,其特征在于,所述方法包括应用于半导体封装。

一种自动化调参方法

技术领域

[0001] 本发明涉及人工智能深度学习技术,具体涉及一种自动化调参方法。

背景技术

[0002] 焊线机的一个重要应用场景是在LED行业,目前焊线机在技术难度较高,只有为数不多的几家厂商可以生产,国外主要生产商为KS,国内为大族激光和翠涛自动化。进口设备仍然占领国内主要市场,特别是高端市场。国产设备主要问题之一为一致性问题,即同样设备在同样的参数选择的情况下生产产品的差距较大,其中有部分设备不能达到质检标准,需要对参数进行调整。

[0003] 对于焊线机产品的质量检测,主要考察一焊点,二焊点和线弧。其中针对一焊点主要有焊球推力,焊球大小,焊球外形,毛边球等考量因素。其中焊球推力是最关键的标准之一,推力值过小表明焊球与电极粘的不好,产品的可靠性有风险。一般要求大于30克,但是不能过大,否则会带来其他问题,一般会有一个建议的目标优化值,比如合金丝是45克,铜丝是35克。推力的测量用专业推力计检测,推刀高度大于5um。相同焊接参数的情况下产品一焊点的推力的一致性不好,是国产设备急需解决的问题。

发明内容

[0004] 本发明的目的在于,解决现有技术的焊线机产品的质量检测存在的上述技术问题。

[0005] 为实现上述目的,本发明提供了一种自动化调参方法,该方法可以应用在半导体封装的超声焊线设备上,其包括以下步骤:

[0006] 根据历史数据库生成初始参数组合,所述参数组合包括冲击预压力、冲击时间、冲击压力、焊线时间、焊线压力、和焊线能量中的一种或多种;超声焊线设备根据初始参数组合执行并测量产品的质量系数;根据产品质量系数反馈更新参数组合;重复上述步骤直到产品质量系数全部合格。

[0007] 优选地,所述根据产品质量系数反馈更新参数组合步骤,包括:基于MLP状态模型,输入初始参数X向量,计算输出推力;微调各个输入参数 Δx ,分别计算每个参数变化带来的最终推力的变化 Δy ;计算每个参数维度上的梯度变化 $\Delta G = \Delta y / \Delta x$;计算输出推力到目标推力的距离值(误差) ϵ ;计算当前距离 ϵ 下,基于梯度变化 ΔG 的每个输入维度的参数更新量: $D = \epsilon / \Delta G$;通过常用的学习速率 α (0.01)更新初始参数 $X_{new} = X + \alpha D$;重复上述6步,直到 ϵ 小于一个阈值 $\theta = 1$,输出最新的X向量,即为通过VNN搜索方法获得的优化的参数组合。

[0008] 本发明通过将反向传播算法从深度学习标准流程中提炼出来,发明没有指定结构的虚拟参数网络(Virtual Parameters Neural Network,简称VNN),以场景信息和目标效果(量化)分别作为“输入”和“结果”,以目标优化参数(量化)作为模型优化的“内置参数”。该模型在实际应用中生成现场收集少量数据即可生成一个状态空间模型,同时通过基于反向传播算法的VNN算法搜索所需的优化参数组合。另外,本发明通过深度学习人工智能与

自动化生产设备结合的方式,帮助国内焊线机设备厂商弯道超车赶超国际上暂时处于领先地位的焊线机设备生产厂。

附图说明

[0009] 图1为本发明实施例提供的一种自动化调参方法流程示意图;

[0010] 图2为本发明实施例图表示意图。

具体实施方式

[0011] 通过以下结合附图以举例方式对本发明的实施方式进行详细描述后,本发明的其他特征、特点和优点将会更加明显。

[0012] 全自动超声波焊线机(以下简称焊线机),一般多应用于大功率器件:发光二极管(LED)、激光管(激光)、中小型功率三极管、集成电路和一些特殊半导体器件的内引线焊接。焊线机是一种复杂的光、机、电一体化设备,通常集计算机控制、运动控制、图像处理、网络通信。焊线机通过物理变化实现不同介质的表面焊接,利用超声频率的机械振动能量产生的超声波(一般为40~140KHz),引线与待焊金属表面相互摩擦,表面氧化层破解,在焊接面形成牢固的金属键合。有效地避免了焊接时所产生的飞溅和氧化等现象。

[0013] 深度学习(deep learning)是一种用多个处理层对数据进行高层抽象的算法,使用包含复杂结构或由多重非线性变换构成的处理工程。神经网络是一种常见的深度学习模型,是一种模仿生物神经网络的结构和功能的数学模型或计算模型,用于对函数进行估计或近似。深度学习神经网络、比如卷积神经网络和深度置信网络和递归神经网络已被广泛应用在计算机视觉、语音识别、自然语言处理、音频识别与生物信息学等领域。深度学习模型,不论其结构复杂与否(从三层的全连接网络到上百层的ResNet),其基础是从1986Rumelhart,Hinton,Williams等人研发和实践的用于深度学习神经网络学习训练用的反向传播算法(backpropagation)。

[0014] 反向传播算法又称“误差反向传播”,一般与最优化方法(如梯度下降法)结合用于训练神经网络。通常是一种监督式学习方法,它是神经网络的Delta规则的推广,可以用链式法则对每层迭代计算梯度。反向传播要求人工神经元的激励函数可微。该方法对网络中所有权重计算损失函数的梯度。这个梯度会反馈给最优化方法,用来更新权值以最小化损失函数。反向传播要求有对每个输入值想得到的已知输出,来计算损失函数梯度。

[0015] 然而已知的深度学习模型在用于工业调参领域(焊线机)寻找最优参数组合时候,面临下面三个问题:

[0016] 1、深度学习模型针对相对固定的场景/环境,以历史数据学习为主:工业设备结构复杂,生产过程中影响因素繁多,同一型号设备在同样参数下结果也会不同,关机再开机也会发生变化,因此基于历史数据训练的模型表现不佳,现实应用每个场景都会有变化,没有完全一样场景的历史数据可供参考。

[0017] 2、传统的模型训练需要大量的数据(多维度,有已知结果):工业领域数据收集仍然不完善,数据收集成本高,在实际的场景应用中,焊线机新设备或者新场景中的数据收集需要在有限的轮次内完成(最少只有不到10个数据点)。

[0018] 3、参数是输入,优化是过程,目标是准确度:传统深度学习的功能以识别,分类,预

测为主,模型为有明确数学表达的深度学习算法,通过优化内置参数最大化模型的准确度,然而调参类别应用的功能为参数的优化,“模型”为现实的设备/生产流程,难以建立确定的数学表达,需优化的“参数”为实际调参的可选参数。对于工业调参,准确度是输入,优化是过程,参数是目标,但是在新场景中并没有先验的参数作为已知结果。

[0019] 图1为本发明实施例提供的一种自动化调参方法流程示意图。如图1所示,该方法包括以下步骤:

[0020] 步骤一,根据历史数据库生成初始参数组合。具体地,根据场景信息如线材,设备型号,磁嘴规格,芯片类别等,数据库中匹配出最接近的一组参数组合,参数组合主要为影响一焊推力最重要的6个参数:1、冲击预压力;2、冲击时间;3、冲击压力;4、焊线时间;5、焊线压力;6、焊线能量以及这些参数对应合理的变化范围(调参的上下限)。

[0021] 本发明实施例采用的VNN方法在于初始参数组合不能达标的情况下寻找新参数的方法。VNN的应用需要满足两点关于状态空间(状态空间指参数到质检目标(推力大小)的数学映射关系)的前提假设:1状态空间连续,在连续空间状态下,可根据测量数据的倒数斜率等关联性分析搭建数学模型,推导下一次搜索的方位,这是VNN可以应用的前提条件。如果非连续空间状态下,每次状态与前次搜索位置没有关联性,那么满足质检合格的状态位置可能出现在空间任何区域,只能搜索随机。2状态空间相似。相似状态空间下,历史的数据和经验具有参考价值,可用于生成初始参数组合和增强搜索算法,如存在相似状态空间,相同应用场景下,可根据历史数据搭建的状态空间模型快速评估合适的参数组合。如状态空间相差大,则每次调参都需要从零开始,需要迭代的次数限制增加。

[0022] 步骤二,超声焊线设备根据初始参数组合执行并测量产品的质量系数。

[0023] 步骤三,根据产品质量系数反馈更新参数组合。

[0024] 具体地,本发明实施例的VNN算法包含两个组成部分:1,一个基于MLP多层感知神经网络用于搭建状态空间映射模型寻找调节参数和目标推力的数学映射关系;2一个基于反向传播算法的参数搜索算法(VNN搜索)用于寻找合适参数,将合适的参数输入到MLP状态空间模型后得到的输出结果为目标推力。

[0025] MLP状态空间映射模型方法如下:在现场收集到少量数据(最少3个数据点),每个数据点包一组参数和一个推力测量结果,采用MLP多层感知神经网络。MLP网络的基本结构如下:

[0026] 深度学习中的多层感知神经网络模型更适应此类变动数据的场景,因此本发明模型的架构流程如下:

[0027] 多层感知神经网络,除输入(6个单元)与输出(1个单元,对应推力值)层外,隐藏层包括10个神经元。模型自由化参数矩阵为88个权重/偏差。

[0028] 实现平台为Python,采用Anacoda3(64bit)环境,调用了keras(tensorflow backend),numpy模组。

[0029] 隐藏层激活函数为tanh,输出层激活函数为linear。

[0030] 每次根据新收集数据进行在线学习,训练方法为标准Adam后传导训练法,成本函数为预测方差值,训练周期为500循环,学习速率为0.01

[0031] 模型训练目标函数预测准确率 $MAE = \frac{\sum |Y - \hat{Y}|}{\sum |Y|}$, 其中Y为实测推力, \hat{Y} 为预测推力。

[0032] 需要说明的是,VNN搜索方法如下:基于MLP状态模型,任何一组参数都可以通过数学映射投影至唯一的推力值,但是因为参数维度(比如推力相关的6个参数)超过3维,只能通过数学关系求解。而在确定了数学映射关系后,在多维空间中搜索合格的参数组合的方法就是标准的反向传导学习法:

[0033] 基于MLP状态模型,输入初始参数X向量,计算输出推力;

[0034] 微调各个输入参数 Δx ,分别计算每个参数变化带来的最终推力的变化 Δy ;

[0035] 计算每个参数维度上的梯度变化 $\Delta G = \Delta y / \Delta x$;

[0036] 计算输出推力到目标推力的距离值(误差) ϵ ;

[0037] 计算当前距离 ϵ 下,基于梯度变化 ΔG 的每个输入维度的参数更新量: $D = \epsilon / \Delta G$;

[0038] 通过常用的学习速率 α (0.01)更新初始参数 $X_{new} = X + \alpha D$;

[0039] 重复上述6步,直到 ϵ 小于一个阈值 $\theta = 1$,输出最新的X向量,即为通过VNN搜索方法获得的优化的参数组合。

[0040] 如果搜索结果未能满足需求,则将新测量结果和旧结果合并重新在线训练MLP状态空间模型和进行VNN搜索。

[0041] 步骤四,重复上述步骤直到产品质量系数全部合格,如当焊点推力接近目标值10%范围以内时,产品质量系数合格。

[0042] 本发明实施例通过将反向传播算法从深度学习标准流程中提炼出来,发明没有指定结构的虚拟参数网络,以场景信息和目标效果(量化)分别作为“输入”和“结果”,以目标优化参数(量化)作为模型优化的“内置参数”。该模型在实际应用中生成现场收集少量数据即可生成一个状态空间模型,同时通过基于反向传播算法的VNN算法搜索所需的优化参数组合。

[0043] 在一个实施例中,在某焊线机厂新型自动化焊线机上采用合金线焊线LED的调参作业,实测结果显示,算法结果在3轮参数(二调)建议7个数据点内达到90.2%的准确度,如下表以及图2所示。

[0044]

设备	第一台焊线机
产品	LED
线材	合金线(0.9um)
磁嘴	GAISER1572A-13TR
保护气	无
芯片焊点	右侧
目标推力	45g

[0045] 需要说明的是,上述实施例仅用来说明本发明的结构及其工作效果,而并不用作限制本发明的保护范围。本领域内的普通技术人员在不违背本发明思路及结构的情况下对上述实施例进行的调整或优化,仍应视作为本发明权利要求所涵盖。

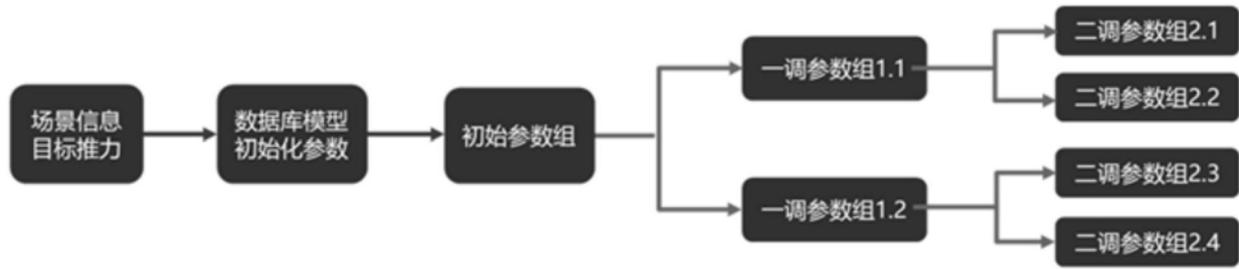


图1

备注	初始建议	算法一调		算法二调			
序号	数据点0	数据点1.1	数据点1.2	数据点2.1	数据点2.2	数据点2.3	数据点2.4
冲击预压力	32.45	32.45	37.34	32.45	34.59	33.11	31.10
冲击时间	1.00	1.00	1.00	1.00	1.00	1.00	1.00
冲击压力	26.21	26.21	20.00	26.21	23.50	27.25	24.49
焊线时间	10.14	12.84	12.41	10.94	11.13	8.72	15.00
焊线压力	18.10	24.10	15.00	19.89	16.75	19.01	19.35
焊线能量	61.38	76.30	80.00	65.77	69.46	62.54	62.78
平均推力	34.8	67.60	57.40	53.10	50.9	40.6	57.9
推力标准差	3.3	7.28	5.78	7.41	8.5	8.4	7.01

图2