



(12) 发明专利

(10) 授权公告号 CN 108305243 B

(45) 授权公告日 2021. 11. 30

(21) 申请号 201711298006.1

G01N 21/88 (2006.01)

(22) 申请日 2017.12.08

(56) 对比文件

(65) 同一申请的已公布的文献号  
申请公布号 CN 108305243 A

CN 104517122 A, 2015.04.15

CN 106093066 A, 2016.11.09

US 2006029257 A1, 2006.02.09

(43) 申请公布日 2018.07.20

严俊龙等.LVQ 神经网络在磁瓦表面缺陷分类中的运用.《计算机与数字工程》.2009,(第12期),第147-150页.

(73) 专利权人 五邑大学  
地址 529020 广东省江门市蓬江区东成村  
22号

审查员 李妍

(72) 发明人 严俊龙 郑晓曦

(74) 专利代理机构 广州市红荔专利代理有限公司  
44214

代理人 吴伟文

(51) Int.Cl.

G06T 7/00 (2017.01)

G06N 3/04 (2006.01)

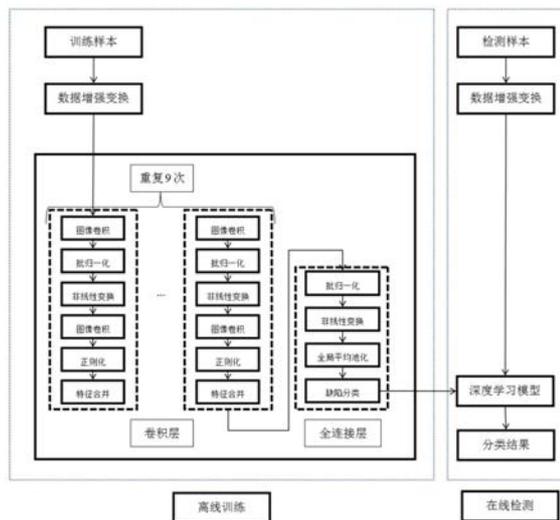
权利要求书1页 说明书4页 附图1页

(54) 发明名称

一种基于深度学习的磁瓦表面缺陷检测方法

(57) 摘要

本发明涉及一种基于深度学习的磁瓦表面缺陷检测方法,包括如下步骤:对训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像进行数据增强变换处理,以得到扩大的训练样本数据集及检测样本数据集;以卷积神经网络为基础建立包含卷积层和全连接层的深度学习模型,其中卷积层包括九个单元,且每个单元均依次由图像卷积层、批归一化层、非线性变换层、图像卷积层、正则化层及特征合并层构成,全连接层依次由批归一化层、非线性变换层、全局平均池化层及缺陷分类层构成;用扩大的训练样本数据集离线训练已建立的深度学习模型,学习最优参数,以得到训练好的深度学习模型;在线检测时将扩大的检测样本数据集输入到已训练好的深度学习模型中,完成缺陷的自动分类识别;分类精度高,特征工程要求低,且泛化性能高。



1. 一种基于深度学习的磁瓦表面缺陷检测方法,其特征在于,包括如下步骤:

S1. 扩大训练样本数据集及检测样本数据集:对训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像进行数据增强变换处理,以得到扩大的训练样本数据集及检测样本数据集;

S2. 建立并训练深度学习模型:以卷积神经网络为基础建立包含卷积层和全连接层的深度学习模型,其中卷积层包括九个单元,且每个单元均依次由图像卷积层、批归一化层、非线性变换层、图像卷积层、正则化层及特征合并层构成,全连接层依次由批归一化层、非线性变换层、全局平均池化层及缺陷分类层构成;用扩大的训练样本数据集离线训练已建立的深度学习模型,学习最优参数,以建立训练样本数据集中的磁瓦表面缺陷图像与缺陷类别的关系,得到训练好的深度学习模型;

S3. 识别缺陷:在线检测时将扩大的检测样本数据集输入到已训练好的深度学习模型中,完成缺陷的自动分类识别;

在步骤S2中训练深度学习模型时,图像卷积层使用的卷积核为  $\begin{bmatrix} 8 & 1 & 6 \\ 3 & 5 & 7 \\ 4 & 9 & 2 \end{bmatrix}$ , 批归一化层使

用的批大小为64,非线性变换层使用ReLU非线性处理,正则化层使用Dropout正则化处理,特征合并层将输入图像卷积层中的图像与经过正则化层处理后的图像合并在一起;扩大的训练样本数据集在卷积层中依次经过九个单元的处理后即可得到高维磁瓦表面缺陷的特征表示,再经过全连接层中全局平均池化层的处理后即可得到一维样本特征向量,最后对该一维样本特征向量进行训练学习以得到训练好的深度学习模型。

2. 根据权利要求1所述的一种基于深度学习的磁瓦表面缺陷检测方法,其特征在于,步骤S1中的训练样本数据集及检测样本数据集中均包括四类缺陷的原始磁瓦表面缺陷图像,分别为裂纹、崩烂、起级及其他类缺陷。

3. 根据权利要求2所述的一种基于深度学习的磁瓦表面缺陷检测方法,其特征在于,步骤S1中的训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像均是在同一工位独立采样获取的。

4. 根据权利要求1所述的一种基于深度学习的磁瓦表面缺陷检测方法,其特征在于,步骤S1中的数据增强变换处理包括翻转、旋转、平移、缩放及加噪声变换处理;其中,旋转、平移、缩放及加噪声变换处理均为两个尺度,且加噪声变换处理为高斯噪声变换处理。

## 一种基于深度学习的磁瓦表面缺陷检测方法

### 技术领域

[0001] 本发明涉及机器视觉检测技术领域,更具体地,涉及一种基于深度学习的磁瓦表面缺陷检测方法。

### 背景技术

[0002] 磁瓦是铁氧体永磁材料的主要产品之一,应用于众多领域,是电动机中的重要组成部件。由于磁瓦本身材料和制造过程的特点,在表面很容易破损产生缺陷,这直接影响了磁瓦的正常使用,因此含有缺陷的磁瓦应该在出厂前予以剔除,防止在装入电动机后工作状态下突发损坏,产生恶劣后果。磁瓦表面缺陷的检测一直是厂家十分关心的问题。

[0003] 经检索,中国专利申请号201610479587.8,申请日为2016年6月24日,发明创造名称为:一种基于改进的机器视觉注意机制的磁瓦表面缺陷检测方法,该申请案采用以下步骤:一、输入磁瓦图像,利用形态学的顶帽和底帽变换相结合的方法,增强图像整体灰度对比度;二、将所得图像均匀分成 $a*b$ 个图像块,然后利用分块后的图像块的灰度特征量区分缺陷图像块和非缺陷图像块;三、采用改进Itti视觉注意机制模型计算所得缺陷图像块的显著度,选择初级特征用以形成综合显著图;四、选用大津阈值分割算法对综合显著图阈值化,提取缺陷区域。

[0004] 又如中国专利申请号201310020370.7,申请日为2013年1月18日,发明创造名称为:一种基于机器视觉的磁瓦表面缺陷特征提取及缺陷分类方法,该申请案首先构造用于表面缺陷特征提取的5尺度、8方向Gabor滤波器组,并对原始图像滤波,得到40幅分量图;提取分量图的灰度均值和方差特征,组成80维特征向量;用PCA主成分法和ICA独立成分法对80维特征向量降维,去除相关和冗余,得到20维特征向量,并对数据归一化处理;采用网格法和K-CV交叉验证法实现SVM参数寻优,基于样本数据离线训练SVM模型;在线检测时,数据经预处理至SVM,实现缺陷的自动分类识别。

[0005] 又如中国专利申请号201110251473.5,申请日为2011年8月30日,发明创造名称为:一种磁瓦表面缺陷检测系统及其检测方法,该申请案包括由多个相机组成的图像采集模块、图像传输和处理模块以及多个传感器组成的相机触发和计算机中断模块,所述图像采集模块中的相机用于获取磁瓦不同表面图像,所述图像传输和处理模块包括交换机和计算机,所述相机分别与交换机连接,交换机与计算机连接,所述相机触发和计算机中断模块中的传感器用于对磁瓦位置进行检测,并触发相机,所述多个相机与多个传感器对应连接,所述传感器通过I/O接口与计算机连接。

[0006] 以上三个技术主要采用传统图像模式识别和机器学习算法,但是传统方法存在以下3类不足:1)分类精度不高,难以满足实用要求;2)特征工程要求高,需领域专家长期摸索、反复调试获得,系统开发周期长;3)泛化性能低,改变检测目标或环境,需重新设计系统和算法,难以现代化生产作业的需要。由于传统方法本身存在的局限,导致实用性较差,目前很多生产磁瓦的厂家主要还是以人工目视检测为主,这种检测方法由于存在精度差、效率低、接触式等缺点,已无法满足现代化生产作业的需要。

## 发明内容

[0007] 本发明的目的在于克服现有技术的不足,提供一种基于深度学习的磁瓦表面缺陷检测方法,分类精度高,特征工程要求低,且泛化性能高,能快速、有效地对各类工况下不同磁瓦表面缺陷进行自动识别。

[0008] 为解决上述技术问题,本发明采用的技术方案是:

[0009] 提供一种基于深度学习的磁瓦表面缺陷检测方法,包括如下步骤:

[0010] S1. 扩大训练样本数据集及检测样本数据集:对训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像进行数据增强变换处理,以得到扩大的训练样本数据集及检测样本数据集;

[0011] S2. 建立并训练深度学习模型:以卷积神经网络为基础建立包含卷积层和全连接层的深度学习模型,其中卷积层包括九个单元,且每个单元均依次由图像卷积层、批归一化层、非线性变换层、图像卷积层、正则化层及特征合并层构成,全连接层依次由批归一化层、非线性变换层、全局平均池化层及缺陷分类层构成;用扩大的训练样本数据集离线训练已建立的深度学习模型,学习最优参数,以建立训练样本数据集中的磁瓦表面缺陷图像与缺陷类别的关系,得到训练好的深度学习模型;

[0012] S3. 识别缺陷:在线检测时将扩大的检测样本数据集输入到已训练好的深度学习模型中,完成缺陷的自动分类识别。

[0013] 上述方案中,通过采用深度学习模型实现端到端的表征学习,直接将磁瓦表面缺陷图像输入深度学习模型,无需人工手动做特征工程,使得特征工程要求低,通过对原始磁瓦表面缺陷图像进行数据增强变换处理,扩大训练样本数据集及检测样本数据集,有效提升了该检测方法对环境 and 目标的适应性,泛化性能高,能快速、有效地对各类工况下不同磁瓦表面缺陷进行自动识别,且数据增强变换处理和深度学习模型相结合能降低检测方法过拟合的风险,有效提高分类精度。

[0014] 优选地,步骤S1中的训练样本数据集及检测样本数据集中均包括四类缺陷的原始磁瓦表面缺陷图像,分别为裂纹、崩烂、起级及其他类缺陷。进一步优选地,步骤S1中的训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像均是在同一工位独立采样获取的。

[0015] 优选地,步骤S1中的数据增强变换处理包括翻转、旋转、平移、缩放及加噪声变换处理;其中,旋转、平移、缩放及加噪声变换处理均为两个尺度,且加噪声变换处理为高斯噪声变换处理。

[0016] 优选地,在步骤S2中训练深度学习模型时,图像卷积层使用的卷积核为

$$\begin{bmatrix} 8 & 1 & 6 \\ 3 & 5 & 7 \\ 4 & 9 & 2 \end{bmatrix}$$
,批归一化层使用的批大小为64,非线性变换层使用ReLU非线性处理,正则化层

使用Dropout正则化处理,特征合并层将输入图像卷积层中的图像与经过正则化层处理后的图像合并在一起;扩大的训练样本数据集在卷积层中依次经过九个单元的处理后即可得到高维磁瓦表面缺陷的特征表示,再经过全连接层中全局平均池化层的处理后即可得到一维样本特征向量,最后对该一维样本特征向量进行训练学习以得到训练好的深度学习模型。

[0017] 与现有技术相比,本发明的有益效果是:

[0018] 本发明一种基于深度学习的磁瓦表面缺陷检测方法,通过采用深度学习模型实现端到端的表征学习,直接将磁瓦表面缺陷图像输入深度学习模型,无需人工手动做特征工程,使得特征工程要求低,通过对原始磁瓦表面缺陷图像进行数据增强变换处理,扩大训练样本数据集及检测样本数据集,有效提升了该检测方法对环境 and 目标的适应性,泛化性能高,能快速、有效地对各类工况下不同磁瓦表面缺陷进行自动识别,且数据增强变换处理和深度学习模型相结合能降低检测方法过拟合的风险,有效提高分类精度。

## 附图说明

[0019] 图1为本实施例一种基于深度学习的磁瓦表面缺陷检测方法的流程图。

## 具体实施方式

[0020] 下面结合具体实施方式对本发明作进一步的说明。其中,附图仅用于示例性说明,表示的仅是示意图,而非实物图,不能理解为对本专利的限制;为了更好地说明本发明的实施例,附图某些部件会有省略、放大或缩小,并不代表实际产品的尺寸;对本领域技术人员来说,附图中某些公知结构及其说明可能省略是可以理解的。

[0021] 本发明实施例的附图中相同或相似的标号对应相同或相似的部件;在本发明的描述中,需要理解的是,若有术语“上”、“下”、“左”、“右”等指示的方位或位置关系为基于附图所示的方位或位置关系,仅是为了便于描述本发明和简化描述,而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作,因此附图中描述位置关系的用语仅用于示例性说明,不能理解为对本专利的限制,对于本领域的普通技术人员而言,可以根据具体情况理解上述术语的具体含义。

[0022] 实施例

[0023] 本实施例一种基于深度学习的磁瓦表面缺陷检测方法,流程图如图1所示,包括如下步骤:

[0024] S1. 扩大训练样本数据集及检测样本数据集:对训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像进行数据增强变换处理,以得到扩大的训练样本数据集及检测样本数据集;

[0025] S2. 建立并训练深度学习模型:以卷积神经网络为基础建立包含卷积层和全连接层的深度学习模型,其中卷积层包括九个单元,且每个单元均依次由图像卷积层、批归一化层、非线性变换层、图像卷积层、正则化层及特征合并层构成,全连接层依次由批归一化层、非线性变换层、全局平均池化层及缺陷分类层构成;用扩大的训练样本数据集离线训练已建立的深度学习模型,学习最优参数,以建立训练样本数据集中的磁瓦表面缺陷图像与缺陷类别的关系,得到训练好的深度学习模型;

[0026] S3. 识别缺陷:在线检测时将扩大的检测样本数据集输入到已训练好的深度学习模型中,完成缺陷的自动分类识别。

[0027] 本发明一种基于深度学习的磁瓦表面缺陷检测方法,通过采用深度学习模型实现端到端的表征学习,直接将磁瓦表面缺陷图像输入深度学习模型,无需人工手动做特征工程,使得特征工程要求低,通过对原始磁瓦表面缺陷图像进行数据增强变换处理,扩大训

练样本数据集及检测样本数据集,有效提升了该检测方法对环境和目标的适应性,泛化性能高,能快速、有效地对各类工况下不同磁瓦表面缺陷进行自动识别,且数据增强变换处理和深度学习模型相结合能降低检测方法过拟合的风险,有效提高分类精度。

[0028] 其中,步骤S1中的训练样本数据集及检测样本数据集中均包括四类缺陷的原始磁瓦表面缺陷图像,分别为裂纹、崩烂、起级及其他类缺陷。

[0029] 本实施例中,步骤S1中的训练样本数据集及检测样本数据集中的每一幅原始磁瓦表面缺陷图像均是在同一工位独立采样获取的。

[0030] 另外,步骤S1中的数据增强变换处理包括翻转、旋转、平移、缩放及加噪声变换处理;其中,旋转、平移、缩放及加噪声变换处理均为两个尺度,且加噪声变换处理为高斯噪声变换处理。

[0031] 其中,在步骤S2中训练深度学习模型时,图像卷积层使用的卷积核为 
$$\begin{bmatrix} 8 & 1 & 6 \\ 3 & 5 & 7 \\ 4 & 9 & 2 \end{bmatrix},$$

批归一化层使用的批大小为64,非线性变换层使用ReLU非线性处理,正则化层使用Dropout正则化处理,特征合并层将输入图像卷积层中的图像与经过正则化层处理后的图像合并在一起;扩大的训练样本数据集在卷积层中依次经过九个单元的处理后即可得到高维磁瓦表面缺陷的特征表示,再经过全连接层中全局平均池化层的处理后即可得到一维样本特征向量,最后对该一维样本特征向量进行训练学习以得到训练好的深度学习模型。

[0032] 本实施例中,在步骤S3的识别缺陷中,为了证明该检测方法的有效性,对4000个原始检测样本数据进行测试,具体为:将1个原始检测样本先经数据增强变换,变换后形成10个检测样本,每1个检测样本输入深度学习模型得到1个识别结果,以概率值表示,10个检测样本得到10个概率值,然后对10个识别结果作算术平均,得到该原始检测样本的识别结果概率值;依次对4000个原始检测样本进行以上步骤处理,得到4000个识别结果概率值,最后对4000个识别结果概率值作算术平均,得到4000个原始检测样本的识别结果,以概率值表示。

[0033] 显然,本发明的上述实施例仅仅是为清楚地说明本发明所作的举例,而并非是对本发明的实施方式的限定。对于所属领域的普通技术人员来说,在上述说明的基础上还可以做出其它不同形式的变化或变动。这里无需也无法对所有的实施方式予以穷举。凡在本发明的精神和原则之内所作的任何修改、等同替换和改进等,均应包含在本发明权利要求的保护范围之内。

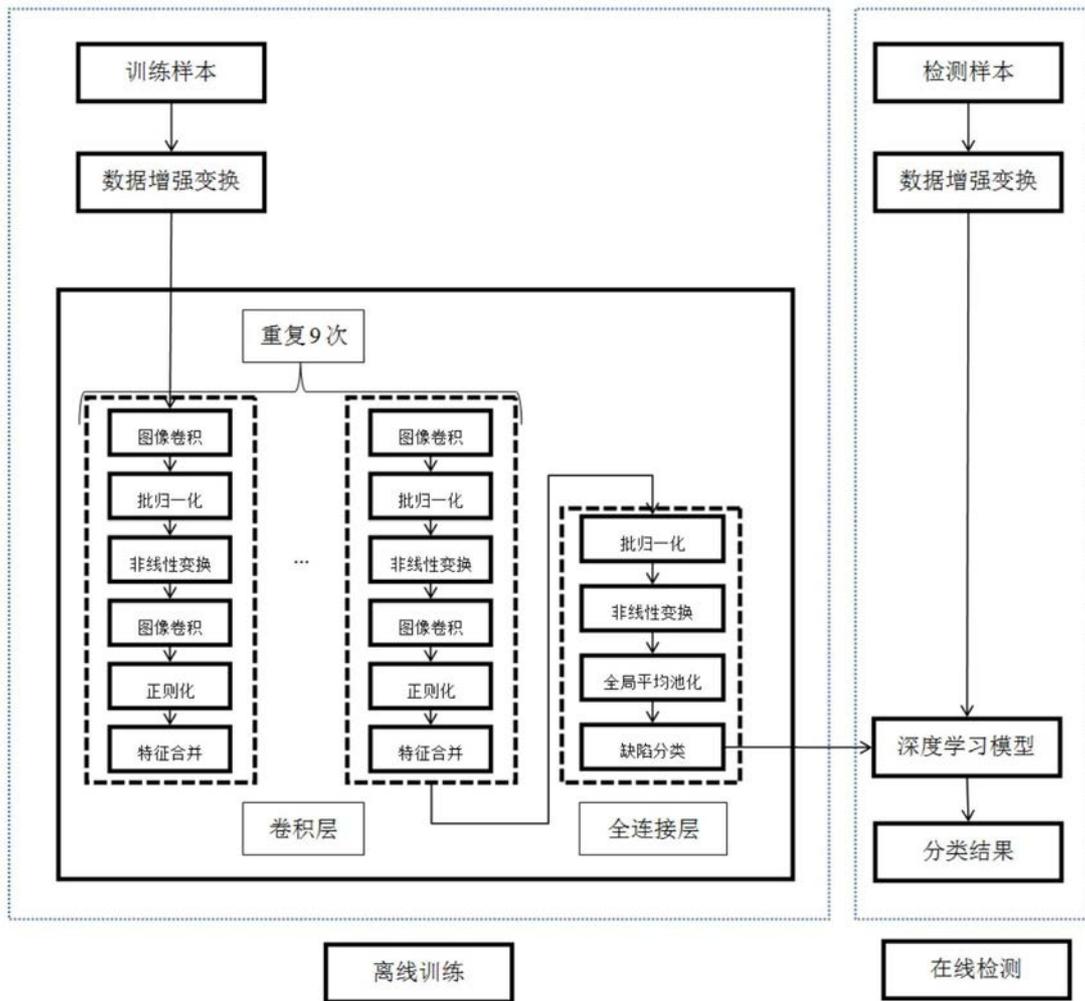


图1