

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局

(43) 国际公布日
2019 年 12 月 12 日 (12.12.2019)



(10) 国际公布号
WO 2019/233166 A1

(51) 国际专利分类号:
G06K 9/62 (2006.01)

(21) 国际申请号: PCT/CN2019/079746

(22) 国际申请日: 2019 年 3 月 26 日 (26.03.2019)

(25) 申请语言: 中文

(26) 公布语言: 中文

(30) 优先权:
201810563651.X 2018年6月4日 (04.06.2018) CN

(71) 申请人: 杭州海康威视数字技术股份有限公司 (HANGZHOU HIKVISION DIGITAL TECHNOLOGY CO., LTD.) [CN/CN]; 中国浙江省杭州市滨江区阡陌路 555 号, Zhejiang 310051 (CN)。

(72) 发明人: 王雪(WANG, Xue); 中国浙江省杭州市滨江区阡陌路555号, Zhejiang 310051 (CN)。

(74) 代理人: 北京柏杉松知识产权代理事务所 (普通合伙) (PATENTSINO IP FIRM); 中国北京市西城区北三环中路 27 号商厦大厦 413 室, Beijing 100029 (CN)。

(81) 指定国 (除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL,

(54) **Title:** SURFACE DEFECT DETECTION METHOD AND APPARATUS, AND ELECTRONIC DEVICE

(54) 发明名称: 一种表面缺陷检测方法、装置及电子设备




图4

(57) **Abstract:** The embodiments of the present application provide a surface defect detection method and apparatus, and an electronic device. The surface defect detection method comprises: acquiring an image to be tested; inputting the image to be tested into a pre-trained deep learning network model, so as to obtain a defect-free reconstructed image corresponding to the image to be tested, the deep learning network model being a deep learning network model obtained by performing pre-training on the basis of a sample training set comprising a plurality of defect-free training sample images; calculating the difference between the reconstructed image and the image to be tested, so as to obtain a difference image; and in the difference image, if there is an area of which the difference value is greater than a preset difference value, determining that the image to be tested has a surface defect. The present solution can improve the surface defect detection rate.

SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG,
US, UZ, VC, VN, ZA, ZM, ZW。

- (84) 指定国 (除另有指明, 要求每一种可提供的地区
保护): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ,
NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚 (AM,
AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE, BG,
CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU,
IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT,
RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI,
CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG)。

本国际公布:

- 包括国际检索报告 (条约第21条(3))。

(57) 摘要: 本申请实施例提供了一种表面缺陷检测方法、装置及电子设备, 其中, 表面缺陷检测方法包括:
获取待检测图像; 将待检测图像输入预先训练得到的深度学习网络模型, 得到待检测图像对应的无缺陷
的重建图像, 深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集, 预先训练得到的
深度学习网络模型; 将重建图像与待检测图像作差, 得到差值图像; 在差值图像中, 若存在差值大于预设
差值的区域, 则确定待检测图像存在表面缺陷。通过本方案, 可以提高表面缺陷的检出率。

一种表面缺陷检测方法、装置及电子设备

本申请要求于2018年6月4日提交中国专利局、申请号为201810563651.X发明名称为“一种表面缺陷检测方法、装置及电子设备”的中国专利申请的
5 优先权，其全部内容通过引用结合在本申请中。

技术领域

本申请涉及目标检测技术领域，特别涉及一种表面缺陷检测方法、装置及电子设备。

背景技术

10 表面缺陷检测是判断产品表面是否存在斑点、凹坑、色差、划痕、缺损等缺陷，产品表面缺陷具有种类繁多、形态多变、位置不固定以及背景纹理多样化等特点。在工业领域，表面缺陷直接影响着产品的美观、性能等属性，因此，产品的表面质量至关重要，传统的表面缺陷检测是在生产线上配备质检员，由质检员对产品表面进行质检，通过人眼观察判断产品表面是否存在
15 缺陷。然而，这种人工检测的方式效率低下、人工耗时大，且易出现检测错误。

基于机器学习的表面缺陷检测方法要求样本图像为包含有缺陷的样本图像，并且需要通过人工标定的方式标定缺陷在产品上的位置，然而，由于包含有缺陷的样本图像数量有限，并不能保证覆盖可能出现的所有类型的缺陷，
20 因此，上述方法无法检测出样本图像中未出现过的缺陷。

发明内容

本申请实施例的目的在于提供一种表面缺陷检测方法、装置及电子设备，以提高表面缺陷的检出率。具体技术方案如下：

25 第一方面，本申请实施例提供了一种表面缺陷检测方法，所述方法包括：获取待检测图像；

将所述待检测图像输入预先训练得到的深度学习网络模型，得到所述待检测图像对应的无缺陷的重建图像，所述深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型；

将所述重建图像与所述待检测图像作差，得到差值图像；

30 在所述差值图像中，若存在差值大于预设差值的区域，则确定所述待检测图像存在表面缺陷。

第二方面，本申请实施例提供了一种表面缺陷检测装置，所述装置包括：获取模块，用于获取待检测图像；

35 计算模块，用于将所述待检测图像输入预先训练得到的深度学习网络模型，得到所述待检测图像对应的无缺陷的重建图像，所述深度学习网络模型

-2-

为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型；将所述重建图像与所述待检测图像作差，得到差值图像；

确定模块，用于在所述差值图像中，若存在差值大于预设差值的区域，则确定所述待检测图像存在表面缺陷。

5 第三方面，本申请实施例提供了一种电子设备，包括处理器和存储器，其中，

所述存储器，用于存放计算机程序；

所述处理器，用于执行所述存储器上所存放的计算机程序时，实现本申请实施例第一方面所述的任一方法步骤。

10 第四方面，本申请实施例提供了一种计算机可读存储介质，所述计算机可读存储介质内存储有计算机程序，所述计算机程序被处理器执行时实现本申请实施例第一方面所述的任一方法步骤。

15 综上所述，本申请实施例提供的方案中，通过将获取的待检测图像输入预先训练得到的深度学习网络模型，得到该待检测图像对应的无缺陷的重建图像，将重建图像与待检测图像作差，得到差值图像，在差值图像中，若存在差值大于预设差值的区域，则确定待检测图像存在表面缺陷，深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型。由于深度学习网络模型是由无缺陷的训练样本图像训练得到的，相较于包含有缺陷的样本图像，无缺陷的训练样本图像更易获取到，且数量多，则将待检测图像输入深度学习网络模型后，可以得到该待检测图像对应的无缺陷的重建图像，由于有缺陷的图像与无缺陷的图像相比，缺陷部分具有较大差异，因此，通过将重建图像与待检测图像作差，如果差值图像中存在差值大于预设差值的区域，可确定待检测图像存在表面缺陷，不受样本图像的限制，有表面缺陷会导致重建图像与待检测图像之间差异明显，这样，既增加了检测出未知的表面缺陷类型的可能性，又提高了表面缺陷的检出率。

20

25

附图说明

图 1 为相应的缺陷检测流程示意图；

图 2 为相应的基于深度学习的表面检测方法流程示意图；

30 图 3 为本申请实施例的表面缺陷检测方法的流程简图；

图 4 为本申请实施例的表面缺陷检测方法的流程示意图；

图 5 为本申请实施例的深度学习网络模型训练的流程示意图；

图 6 为本申请实施例的数据构造示意图；

图 7 为本申请实施例的深度学习网络模型的训练过程的流程简图；

35 图 8 为本申请实施例的测试过程的流程简图；

图 9a 为相应的 DBNs 训练中预训练的流程示意图；

图 9b 为相应的 DBNs 训练中网络模型展开的流程示意图；

—3—

图 9c 为相应的 DBNs 训练中网络模型微调的流程示意图；

图 10 为相应的 RBM 模型的结构示意图；

图 11a 为相应的 SDAE 训练中预训练的流程示意图；

图 11b 为相应的 SDAE 训练中网络模型展开的流程示意图；

5 图 11c 为相应的 SDAE 训练中网络模型微调的流程示意图；

图 12 为相应的 DAE 计算流程示意图；

图 13 为相应的 SDAE 计算流程示意图；

图 14 为本申请实施例的表面缺陷检测装置的结构示意图；

图 15 为本申请实施例的电子设备的结构示意图。

10 具体实施方式

为使本申请的目的、技术方案、及优点更加清楚明白，以下参照附图并举实施例，对本申请进一步详细说明。显然，所描述的实施例仅仅是本申请一部分实施例，而不是全部的实施例。基于本申请中的实施例，本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例，都属于本

15 申请保护的范围。

传统的表面缺陷检测方法传统的机器视觉算法流程类似，如图 1 所示，一般将拍摄得到的图片进行预处理，然后设计滤波器提取特征，对提取的特征进行分析处理确定阈值，经过形态学等处理检测出缺陷。自从机器学习广泛应用后，表面缺陷检测领域也开始大量使用机器学习的方法，例如基于深度学习

20 深度学习的表面检测方法，基于深度学习的表面检测方法流程如图 2 所示，深度学习能够自动提取特征，而不需要人工设计特征，能够学习图像更加抽象的表达，进一步提高缺陷检测精度。

基于深度学习的表面检测方法需要预先对深度学习网络进行训练，要求进行训练的样本图像为包含有缺陷的样本图像，然而，由于包含有缺陷的样本图像数量有限，并不能保证覆盖可能出现的所有类型的缺陷，因此，基于深度学习

25 深度学习的表面缺陷检测方法并不能检测出样本图像中未出现过的缺陷。

因此，为了提高表面缺陷的检出率，本申请实施例提供了一种表面缺陷检测方法、装置及电子设备。下面，首先对本申请实施例所提供的一种表面缺陷检测方法进行介绍。

本申请实施例所提供的一种表面缺陷检测方法的执行主体可以为一种电子设备，该电子设备用于实现图像处理、目标识别等功能，可以为具有逻辑处理能力的摄像机、远程处理器等，电子设备中至少包括可以完成逻辑处理的芯片。实现本申请实施例所提供的一种表面缺陷检测方法的方式可以为设置于执行主体中的软件、硬件电路和逻辑电路中的至少一种。

30

本申请实施例提供了一种表面缺陷检测方法，表面缺陷检测方法的流程简图如图 3 所示。主要步骤包括：针对训练图像构建数据集；利用构建的数据集训练深度学习网络模型；将测试图像输入训练好的深度学习网络模型，

35

-4-

模型输出；对模型输出进行后处理，得到表面缺陷检测的结果。

下面，对如图 3 所示的表面缺陷检测方法进行更为详细的介绍，如图 4 所示，该表面缺陷检测方法可以包括如下步骤。

S401，获取待检测图像。

- 5 待检测图像为需要进行表面缺陷检测的图像，待检测图像可以为数据库中已存储的产品图像，也可以为对产品进行实时拍摄得到的图像，这里所提及的产品为泛指的产品，并不局限于某一种类型的产品，可以为例如手机、便携式计算机、布匹、筷子等等。

- 10 S402，将待检测图像输入预先训练得到的深度学习网络模型，得到待检测图像对应的无缺陷的重建图像。

- 深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型。深度学习网络模型可以为卷积神经网络模型，卷积神经网络是一种前馈神经网络，卷积神经网络中的人工神经元可以响应一部分覆盖范围内的周围单元，对于大型图像处理有出色表现。卷积神经网络一般由卷积层、池化层、非线性层和全连接层等网络层组成，本申请实施例中的深度学习网络模型还可以为全卷积神经网络模型（不包含全连接层的卷积神经网络）。

- 20 由于深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型，则将待检测图像输入深度学习网络模型后，所得到的重建图像为接近于与待检测图像对应的无缺陷的样本图像的图像，且重建图像中的产品图就是待检测图像中的产品图，两者唯一区别在于重建图像中的产品图无缺陷，而待检测图像中的产品图可能存在缺陷。由于受深度学习网络模型的训练精准度影响，重建图像中有可能包含有缺陷，但是缺陷已深度弱化，与待检测图像中的缺陷仍然存在较大差异。

- 25 在本申请的一种可能的实施方式中，深度学习网络模型的训练方式如图 5 所示，具体可以包括如下步骤。

S501，获取样本训练集。

- 30 样本训练集中包括多个无缺陷的训练样本图像。样本训练集为无缺陷的训练样本图像构成的集合，无缺陷的训练样本图像可以为采集的原始无缺陷的样本图像，也可以为对采集的原始无缺陷的样本图像进行数据构造得到的图像。

- 在本申请的一种可能的实施方式中，S501 具体可以为：获取原始训练样本图像，其中，原始训练样本图像包括无缺陷的样本图像；对原始训练样本图像进行变换扩充，得到变换图像；基于所有变换图像和所有原始训练样本图像，构成第一数量的训练样本图像；将第一数量的训练样本图像按照预设尺寸进行裁剪分块，得到第二数量的训练样本图像；将第二数量的训练样本图像作为样本训练集。

-5-

获取样本训练集时，需要对训练样本图像进行数据构造，数据构造主要分为两块，如图 6 所示，一个是数据扩充，另一个是对扩充后的数据进行分块。

5 由于无缺陷的样本图像的数量较大，并且场景、类型等区别也较大，获取的原始训练样本图像可能仅仅有十几二十张，并且在同一场景中不同时刻的亮度、对比度等属性不同，则会导致难以覆盖所有可能存在的情况，因此，为了提高检测的准确性，可以按照亮度变换、对比度变换和尺度变换等方式对原始训练样本图像进行变换扩充，得到训练样本图像变换扩充后的变换图像。可以将所有变换图像和原始训练样本图像一起构成第一数量的训练样本
10 图像，这样，就将训练样本图像扩充了几倍，有效的扩大了样本的覆盖。

并且，一般工业上用于表面缺陷检测的图像尺寸都比较大，例如图像的尺寸可能为 1280*1024，为了解决大尺寸图像上表面缺陷检测的问题，可以按照预设尺寸对第一数量的训练样本图像进行裁剪分块，例如预设尺寸为 250*250，则可以从第一数量的训练样本图像中选取若干点，以这些点为中心，
15 裁剪 250*250 大小的图像，最终得到若干个大小为 250*250 的图像作为第二数量的训练样本图像；还可以是以均匀采样的方式进行裁剪，从第一数量的训练样本图像的左上角开始，每隔 25 个像素采集 250*250 范围的图像作为第二数量的训练样本图像。

20 S502，对样本训练集中的各训练样本图像进行加噪处理，得到各训练样本图像分别对应的加噪图像。

由于在实际场景中，不可避免的存在噪声，而样本训练集中的训练样本图像往往是在不确定的噪声下采集的，因此，为了保证深度学习网络的稳定性，可以在各训练样本图像上加入噪声，从而使得深度学习网络模型能够更好的学习到无缺陷样本的数据分布。加入的噪声对最终深度学习网络模型影响比较大，如何设计噪声也是比较关键的，为了提高深度学习网络模型的泛化能力，更程度的应对不同的噪声，从受污染的输入中重构出纯净的输入，
25 因此，在加入噪声时，可以针对各训练样本图像，使用高斯噪声、零掩模噪声、块状噪声等对该训练样本图像进行加噪处理。加入噪声的方式与噪声的类型相关，例如，在加入零掩膜噪声时，可以随机地将训练样本图像中预设比例的像素点设置为 0，加入其他类型的噪声的方式这里不再一一赘述。
30

S503，将各加噪图像输入预设训练模型进行训练，得到深度学习网络模型。

在得到加噪图像之后，进行深度学习网络模型的训练，加噪图像经过深度学习网络模型后可以得到输出图像。对预设训练模型进行训练得到深度学习网络模型的方式，可以是传统的卷积神经网络的训练方式。
35

如何训练深度学习模型是整个表面缺陷检测方法的关键，加入噪声的加噪图像经过卷积神经网络得到加噪图像的输出图像，为了能够使得输出图像

-6-

更加接近原始的训练样本图像，可以根据预设的误差最优化策略进行模型训练，预设的误差最优化策略可以为最优化输出图像与训练样本图像之间的像素均方误差，也可以为最优化输出图像与训练样本图像之间的逐像素点的像素均方误差及梯度均方误差，还可以为最优化其他类型的误差，这里不再一一赘述。

在本申请的一种可能的实施方式中，S503 具体可以包括以下步骤。

步骤 A，将各加噪图像输入预设卷积神经网络，得到各加噪图像的输出图像。

在第一次得到输出图像时，加噪图像输入的可以是一个初始深度学习网络模型，初始深度学习网络模型可以为基本的或者业内最为常用的网络模型。

步骤 B，计算各输出图像与各加噪图像对应的训练样本图像之间的逐像素点的像素均方误差及梯度均方误差。

步骤 C，基于逐像素点的像素均方误差及梯度均方误差，计算总误差函数值。

在本申请的一种可能的实施方式中，步骤 C 具体可以为：基于逐像素点的像素均方误差及梯度均方误差，利用总误差函数，计算得到总误差函数值。

总误差函数为：

$$\text{loss} = \frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2 + \frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$$

其中， m 为输入的加噪图像对应的训练样本图像上的像素点个数， $\frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2$ 为逐像素点的像素均方误差， x'_i 为输出图像上第 i 个像素点的像素值， x_i 为输入的加噪图像对应的训练样本图像上第 i 个像素点的像素值， $\frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$ 为逐像素点的梯度均方误差， $\nabla x'_i$ 为输出图像上第 i 个像素点的梯度值， ∇x_i 为输入的加噪图像对应的训练样本图像上第 i 个像素点的梯度值。

步骤 D，判断总误差函数值是否小于或等于误差阈值，若是，则确定深度学习网络模型训练完成；否则根据总误差函数值，调整深度学习网络模型的网络参数，并返回执行步骤 A。

本实施例中误差最优化策略为最优化输出图像与训练样本图像之间的逐像素点的像素均方误差及梯度均方误差方式，一方面，从像素值的角度使得输出图像尽可能的与训练样本图像接近，另一方面，从边缘梯度的角度使得输出图像更接近训练样本图像。有缺陷的图像中往往存在许多纹理信息及边缘信息，包括缺陷本身也是具有边缘信息的，因此，加入梯度的信息能够更好的检测表面缺陷。

具体的，深度学习网络模型的训练过程如图 7 所示，在训练图像 x 中添加噪声，然后基于添加了噪声的训练图像对卷积神经网络进行训练，得到重建图像 x' ，并将重建图像作为训练图像重新进行训练。可以采用类似 SDAE

-7-

(Stacked Denoise Autoencode, 堆叠降噪自动编码器)的方法在训练数据上加入噪声,使得深度学习网络模型能够更好的学习到无缺陷样本的数据分布。深度学习网络模型的训练过程,可以在已有的深度学习网络平台上进行,也可以通过搭建的程序框架实现,这里不做限定。

5 S403,将重建图像与待检测图像作差,得到差值图像。

重建图像与待检测图像作差为重建图像中的像素点与待检测图像中的对应像素点分别作差,对于灰度图,可以是像素值直接作差,对于 RGB 图,可以是三通道分量分别作差,像素值相同或者 RGB 三通道分量相同的像素点在作差之后差值接近于 0,而像素值或者 RGB 三通道分量差别较大时,在作差之后差值较大,因此,可以通过差值的大小来判断是否存在缺陷。为了计算
10 简便,在得到差值图像后,可以将差值图像中的各差值进行归一化处理,将所有差值都归一化至 0~1 的范围内。

测试过程的流程简图如图 8 所示,对于待检测图像,将待检测图像输入训练好的深度学习网络模型中获得重建图像,将重建图像与待检测图像做差,
15 获得一张差值图像,有缺陷的区域会有较大的差异,没有缺陷的区域差异较小,因此,可以通过值的大小来判断该区域是否存在缺陷。

S404,在差值图像中,若存在差值大于预设差值的区域,则确定待检测图像存在表面缺陷。

由于重建图像为无缺陷的图像,而待检测图像中可能存在表面缺陷,通过
20 将重建图像与待检测图像作差,差值较小的区域说明待检测图像中该区域无缺陷,而差值较大的区域说明待检测图像中该区域存在表面缺陷,为了提高检测的准确性,可以设置一预设差值,如果存在差值大于预设差值的区域,则说明待检测图像存在表面缺陷,并且通过能够确定出待检测图像中具体哪一个区域存在表面缺陷。

25 在确定待检测图像中存在表面缺陷之后,还可以采用 SVM(Support Vector Machine,支持向量机)、回归模型 softmax、ANN(Artificial Neural Networks,人工神经网络)等分类器,识别表面缺陷的类别,分类器识别表面缺陷类别的具体识别方法这里不再赘述。

目前涉及到无监督的表面缺陷检测方法主要是采用无监督学习方式
30 进行预训练,结合有监督的方法对网络进行微调,无监督学习中训练集样本的特性未知,没有对样本进行标记。完全采用无监督的方法主要分为两种方法,一种采用 DBNs(Deep Belief Networks,深度置信网络),另一种采用 SDAE。

DBNs 的训练过程如下:采用无缺陷的样本图像,逐层训练堆叠的 RBM
(Restricted Boltzmann Machines,受限玻尔兹曼机),如图 9a 所示;同样采用
35 无缺陷的样本图像将网络模型展开,然后进行微调,如图 9b、图 9c 所示。

DBNs 通过训练其神经元间的权重,可以让整个神经网络按照最大概率来生成训练数据。DBNs 的组成元件是 RBM。在 RBM 中,神经元是随机的,

-8-

且只有未激活和激活两种状态，一般用二进制的 0 和 1 表示，取值根据概率统计法则决定。RBM 具有一个可见层，一个隐藏层，如图 10 所示，其层内无连接，这种结构使得 RBM 在给定可见层单元状态时，各隐藏层单元的激活条件独立；反之在给定隐藏层单元状态时，可见层单元的激活条件也独立。

- 5 当给定可见单元状态时，各隐藏层单元的激活状态之间是条件独立的，由此可得第 j 个隐藏层单元的激活概率为：

$$P(h_j=1|v)=\text{Sigm}\left(-b_j-\sum_i v_i W_{ij}\right)$$

根据RBM的对称结构，同理可得第 i 个可见层单元的激活概率为：

$$P(v_i=1|h)=\text{Sigm}\left(-c_i-\sum_j h_j W_{ij}\right)$$

- 10 h_i 表征第 i 个隐藏层单元， v_i 表征第 i 个可见层单元， W_{ij} 、 b_j 和 c_j 为 RBM 网络参数，需拟合给定的训练数据，用极大似然法最大化上述公式，一般采用 CD (Contrastive Divergence，对比分歧) 算法进行优化。

- SDAE 的训练过程如下：(1) 训练第一个 DAE (Denoising Auto-encoder，降噪自动编码器) 网络，采用最优梯度下降法优化，计算得到训练样本在隐藏层的输出值；(2) 将 (1) 的结果作为第二个 DAE 网络训练的输入值，同样采用最优梯度下降法来优化，并计算 DAE 网络输出值，用同样的方法训练第 3 个 DAE 网络和第 4 个 DAE 网络；将上面的 4 个 DAE 网络展开连接成新的网络，且分成编码和解码两部分，用 (1) 和 (2) 得到的权值给网络赋初值；(4) 将输入值作为 SDAE 网络的目标输出，同样用最优梯度下降法来优化，得到最终的网路权值。以输入样本图像为 $64*64$ 的灰度图为例，SDAE 的输入层是 4096 维，4 个隐藏层维度分别为 1000、500、250、200、50。按照图 11a 的形式创建网络并得到相应的预训练权值；按图 11b 的形式展开；把输入样本图像作为网络的目标输出，按图 11c 对权值做进一步的微调，微调的过程可以采用 BP (Back Propagation，反向传播) 算法。

- 25 DAE 与传统的 AE (Auto-encoder，自动编码器) 具有相同的结构，只是在样本输入时加入了某种类型的噪声，其学习目标是从受污染的输入中重构出纯净的输入。其计算过程如图 12 所示，计算过程如下。

设输入样本为 X ，污染后的随机映射样本为 $\tilde{X} \sim q_D(\tilde{X}|X)$ ，则 DAE 的编码输出为：

$$Y=f_\theta(X)=s(W\tilde{X}+b)$$

重构后的解码输出为：

—9—

$$Z=g_{\theta'}(Y)=s(W'Y+b')$$

其参数、结构与基本的AE完全相同，不同点在于损失函数：

$$L_2(X,Z)=C(\sigma^2)\|X-Z\|^2, \text{ 线性解码器}$$

或，

$$L_H(X,Z)=H(B(X)\|B(Z)), \text{ 非线性解码器}$$

5 其中， W 、 b 、 W' 、 b' 为DAE网络参数。损失函数虽然仍旧是最小化纯净输入信号 X 和重构 Y 之间的误差，或者说是最大化纯净输入信号和重构信号之间的共有信息，但传统的AE不同的是，重构信号 Y 是由受污染信号 $\tilde{X}$ 重构得到的。

样本 X 每训练一次，都会根据噪声发生器 $q_D(\tilde{X}|X)$ 产生一个不同的 $\tilde{X}$ 。

10 为了得到更高级的特征表达，用深度网络结构的形式，把DAE逐层堆叠起来，形成一个由DAE上下连接而成的模型结构（称为SDAE）。在训练时，前一层的输出作为后一层的纯净输入，逐层进行训练。学习过程如图13所示。

上述两种方法从训练方法上来看，均要分成两步进行，先逐层训练，得到网络模型，再将训练得到的网络模型展开进行微调，过程比较繁琐。而在
15 本申请实施例中，深度学习网络模型的训练过程并不需要分步进行，直接通过训练可得到深度学习网络模型，而不需要再进行展开微调，简化了训练过程。

应用本实施例，通过将获取的待检测图像输入预先训练得到的深度学习网络模型，得到该待检测图像对应的无缺陷的重建图像，将重建图像与待检测图像作差，得到差值图像，在差值图像中，若存在差值大于预设差值的区域，则确定待检测图像存在表面缺陷，深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型。由于深度学习网络模型是由无缺陷的训练样本图像训练得到的，相较于包含有缺陷的样本图像，无缺陷的训练样本图像更易获取到，且数量多，则将待检测图像输入深度学习网络模型后，可以得到该待检测图像对应的无缺陷的重建图像，由于有缺陷的图像与无缺陷的图像相比，缺陷部分具有较大差异，因此，通过将重建图像与待检测图像作差，如果差值图像中存在差值大于预设差值的区域，可确定待检测图像存在表面缺陷，不受样本图像的限制，有表面缺陷会导致重建图像与待检测图像之间差异明显，这样，既增加了检测
25 出未知的表面缺陷类型的可能性，又提高了表面缺陷的检出率。

相应于上述方法实施例，本申请实施例提供了一种表面缺陷检测装置，如图14所示，该表面缺陷检测装置包括：

获取模块 1410, 用于获取待检测图像。

计算模块 1420, 用于将所述待检测图像输入预先训练得到的深度学习网络模型, 得到所述待检测图像对应的无缺陷的重建图像, 所述深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集, 预先训练得到的深度学习网络模型; 将所述重建图像与所述待检测图像作差, 得到差值图像。

确定模块 1430, 用于在所述差值图像中, 若存在差值大于预设差值的区域, 则确定所述待检测图像存在表面缺陷。

在本申请的一种可能的实施方式中, 所述获取模块 1410, 还可以用于: 获取样本训练集, 所述样本训练集中包括多个无缺陷的训练样本图像。

所述装置, 还可以包括: 加噪模块, 用于对所述样本训练集中的各训练样本图像进行加噪处理, 得到各训练样本图像分别对应的加噪图像; 训练模块, 用于将各所述加噪图像输入预设训练模型进行训练, 得到所述深度学习网络模型。

在本申请的一种可能的实施方式中, 所述获取模块 1410, 具体可以用于: 获取原始训练样本图像, 所述原始训练样本图像包括无缺陷的样本图像; 对所述原始训练样本图像进行变换扩充, 得到变换图像; 基于所有变换图像和所有原始训练样本图像, 构成第一数量的训练样本图像; 将所述第一数量的训练样本图像按照预设尺寸进行裁剪分块, 得到第二数量的训练样本图像; 将所述第二数量的训练样本图像作为样本训练集。

在本申请的一种可能的实施方式中, 所述训练模块, 具体可以用于: 将各所述加噪图像输入预设卷积神经网络, 得到各所述加噪图像的输出图像; 计算各所述输出图像与各所述加噪图像对应的训练样本图像之间的逐像素点的像素均方误差及梯度均方误差; 基于所述逐像素点的像素均方误差及梯度均方误差, 计算总误差函数值; 判断所述总误差函数值是否小于或等于误差阈值; 若是, 则确定所述深度学习网络模型训练完成; 否则根据所述总误差函数值, 调整所述深度学习网络模型的网络参数, 并返回执行所述将各所述加噪图像输入预设卷积神经网络, 得到各所述加噪图像的输出图像。

在本申请的一种可能的实施方式中, 所述训练模块在实现所述基于所述逐像素点的像素均方误差及梯度均方误差, 计算总误差函数值时, 具体可以用于: 基于所述逐像素点的像素均方误差及梯度均方误差, 利用总误差函数, 计算得到总误差函数值。

其中, 所述总误差函数为:

$$\text{loss} = \frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2 + \frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$$

其中, 所述m为输入的加噪图像对应的训练样本图像上的像素点个数, 所

述 $\frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2$ 为逐像素点的像素均方误差, 所述 x'_i 为所述输出图像上第 i 个像素点的像素值, 所述 x_i 为输入的加噪图像对应的训练样本图像上第 i 个像素点的像素值, 所述 $\frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$ 为逐像素点的梯度均方误差, 所述 $\nabla x'_i$ 为所述输出图像上第 i 个像素点的梯度值, 所述 ∇x_i 为输入的加噪图像对应的训练样本图像上第 i 个像素点的梯度值。

应用本实施例, 通过将获取的待检测图像输入预先训练得到的深度学习网络模型, 得到该待检测图像对应的无缺陷的重建图像, 将重建图像与待检测图像作差, 得到差值图像, 在差值图像中, 若存在差值大于预设差值的区域, 则确定待检测图像存在表面缺陷, 深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集, 预先训练得到的深度学习网络模型。由于深度学习网络模型是由无缺陷的训练样本图像训练得到的, 相较于包含有缺陷的样本图像, 无缺陷的训练样本图像更易获取到, 且数量多, 则将待检测图像输入深度学习网络模型后, 可以得到该待检测图像对应的无缺陷的重建图像, 由于有缺陷的图像与无缺陷的图像相比, 缺陷部分具有较大差异, 因此, 通过将重建图像与待检测图像作差, 如果差值图像中存在差值大于预设差值的区域, 可确定待检测图像存在表面缺陷, 不受样本图像的限制, 有表面缺陷会导致重建图像与待检测图像之间差异明显, 这样, 既增加了检测出未知的表面缺陷类型的可能性, 又提高了表面缺陷的检出率。

为了提高表面缺陷的检出率, 本申请实施例还提供了一种电子设备, 如图 15 所示, 该电子设备包括处理器 1501 和存储器 1502, 其中, 所述存储器 1502, 用于存放计算机程序; 所述处理器 1501, 用于执行所述存储器 1502 上所存放的计算机程序时, 实现如下步骤。

获取待检测图像;
将所述待检测图像输入预先训练得到的深度学习网络模型, 得到所述待检测图像对应的无缺陷的重建图像, 所述深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集, 预先训练得到的深度学习网络模型;
将所述重建图像与所述待检测图像作差, 得到差值图像;
在所述差值图像中, 若存在差值大于预设差值的区域, 则确定所述待检测图像存在表面缺陷。

在本申请的一种可能的实施方式中, 所述处理器 1501 还可以实现如下步骤: 获取样本训练集, 所述样本训练集中包括多个无缺陷的训练样本图像; 对所述样本训练集中的各训练样本图像进行加噪处理, 得到各训练样本图像

分别对应的加噪图像；将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型。

在本申请的一种可能的实施方式中，所述处理器 1501 在实现所述获取样本训练集的步骤时，具体可以实现如下步骤：获取原始训练样本图像，所述原始训练样本图像包括无缺陷的样本图像；对所述原始训练样本图像进行变换扩充，得到变换图像；基于所有变换图像和所有原始训练样本图像，构成第一数量的训练样本图像；将所述第一数量的训练样本图像按照预设尺寸进行裁剪分块，得到第二数量的训练样本图像；将所述第二数量的训练样本图像作为样本训练集。

在本申请的一种可能的实施方式中，所述处理器 1501 在实现所述将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型的步骤时，具体可以实现如下步骤：将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像；计算各所述输出图像与各所述加噪图像对应的训练样本图像之间的逐像素点的像素均方误差及梯度均方误差；基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值；判断所述总误差函数值是否小于或等于误差阈值；若是，则确定所述深度学习网络模型训练完成；否则根据所述总误差函数值，调整所述深度学习网络模型的网络参数，并返回执行所述将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像。

在本申请的一种可能的实施方式中，所述处理器 1501 在实现所述基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值的步骤时，具体可以实现如下步骤：基于所述逐像素点的像素均方误差及梯度均方误差，利用总误差函数，计算得到总误差函数值。

其中，所述总误差函数可以为：

$$\text{loss} = \frac{1}{2m} \sum_{i=1}^m (x' - x)^2 + \frac{1}{2m} \sum_{i=1}^m (\nabla x' - \nabla x)^2$$

其中，所述m为输入的加噪图像对应的训练样本图像上的像素点个数，所述 $\frac{1}{2m} \sum_{i=1}^m (x' - x)^2$ 为逐像素点的像素均方误差，所述x'为所述输出图像上第i个像素点的像素值，所述x为输入的加噪图像对应的训练样本图像上第i个像素点的像素值，所述 $\frac{1}{2m} \sum_{i=1}^m (\nabla x' - \nabla x)^2$ 为逐像素点的梯度均方误差，所述 $\nabla x'$ 为所述输出图像上第i个像素点的梯度值，所述 ∇x 为输入的加噪图像对应的训练样本图像上第i个像素点的梯度值。

存储器 1502 与处理器 1501 之间可以通过有线连接或者无线连接的方式进行数据传输，并且计算机设备可以通过有线通信接口或者无线通信接口与其他的设备进行通信。需要说明的一点，图 15 中只给出了处理器 1501 与存储器 1502 之间通过总线传输数据的示例，并不是对具体传输方式的限定。

5 上述存储器可以包括 RAM(Random Access Memory, 随机存取存储器), 也可以包括 NVM(Non-Volatile Memory, 非易失性存储器), 例如至少一个磁盘存储器。在本申请的一种可能的实施方式中, 存储器还可以是至少一个位于远端于上述处理器的存储装置。

10 上述处理器可以是通用处理器, 包括 CPU(Central Processing Unit, 中央处理器)、NP(Network Processor, 网络处理器)等; 还可以是 DSP(Digital Signal Processor, 数字信号处理器)、ASIC(Application Specific Integrated Circuit, 专用集成电路)、FPGA(Field-Programmable Gate Array, 现场可编程门阵列)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件。

15 本实施例中, 该电子设备的处理器通过读取存储器中存储的计算机程序, 并通过运行该计算机程序, 能够实现: 通过将获取的待检测图像输入预先训练得到的深度学习网络模型, 得到该待检测图像对应的无缺陷的重建图像, 将重建图像与待检测图像作差, 得到差值图像, 在差值图像中, 若存在差值大于预设差值的区域, 则确定待检测图像存在表面缺陷, 深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集, 预先训练得到的深度学习网络模型。由于深度学习网络模型是由无缺陷的训练样本图像训练得到的, 相较于包含有缺陷的样本图像, 无缺陷的训练样本图像更易获取到, 且数量多, 则将待检测图像输入深度学习网络模型后, 可以得到该待检测图像对应的无缺陷的重建图像, 由于有缺陷的图像与无缺陷的图像相比, 缺陷部分具有较大差异, 因此, 通过将重建图像与待检测图像作差, 如果差值图像
20 中存在差值大于预设差值的区域, 可确定待检测图像存在表面缺陷, 不受样本图像的限制, 有表面缺陷会导致重建图像与待检测图像之间差异明显, 这样, 既增加了检测出未知的表面缺陷类型的可能性, 又提高了表面缺陷的检出率。

25 另外, 相应于上述实施例所提供的表面缺陷检测方法, 本申请实施例提供一种计算机可读存储介质, 该计算机可读存储介质内存储有计算机程序, 所述计算机程序被处理器执行时实现上述表面缺陷检测方法的任一步骤。

30 本实施例中, 计算机可读存储介质在运行时执行本申请实施例所提供的表面缺陷检测方法的应用程序, 因此能够实现: 通过将获取的待检测图像输入预先训练得到的深度学习网络模型, 得到该待检测图像对应的无缺陷的重建图像, 将重建图像与待检测图像作差, 得到差值图像, 在差值图像中, 若存在差值大于预设差值的区域, 则确定待检测图像存在表面缺陷, 深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集, 预先训练得
35

到的深度学习网络模型。由于深度学习网络模型是由无缺陷的训练样本图像训练得到的，相较于包含有缺陷的样本图像，无缺陷的训练样本图像更易获取到，且数量多，则将待检测图像输入深度学习网络模型后，可以得到该待检测图像对应的无缺陷的重建图像，由于有缺陷的图像与无缺陷的图像相比，缺陷部分具有较大差异，因此，通过将重建图像与待检测图像作差，如果差值图像中存在差值大于预设差值的区域，可确定待检测图像存在表面缺陷，不受样本图像的限制，有表面缺陷会导致重建图像与待检测图像之间差异明显，这样，既增加了检测出未知的表面缺陷类型的可能性，又提高了表面缺陷的检出率。

另外，相应于上述实施例所提供的表面缺陷检测方法，本申请实施例提供了一种应用程序，用于在运行时执行：本申请实施例所提供的表面缺陷检测方法。

本实施例中，应用程序在运行时执行本申请实施例所提供的表面缺陷检测方法，因此能够实现：通过将获取的待检测图像输入预先训练得到的深度学习网络模型，得到该待检测图像对应的无缺陷的重建图像，将重建图像与待检测图像作差，得到差值图像，在差值图像中，若存在差值大于预设差值的区域，则确定待检测图像存在表面缺陷，深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型。由于深度学习网络模型是由无缺陷的训练样本图像训练得到的，相较于包含有缺陷的样本图像，无缺陷的训练样本图像更易获取到，且数量多，则将待检测图像输入深度学习网络模型后，可以得到该待检测图像对应的无缺陷的重建图像，由于有缺陷的图像与无缺陷的图像相比，缺陷部分具有较大差异，因此，通过将重建图像与待检测图像作差，如果差值图像中存在差值大于预设差值的区域，可确定待检测图像存在表面缺陷，不受样本图像的限制，有表面缺陷会导致重建图像与待检测图像之间差异明显，这样，既增加了检测出未知的表面缺陷类型的可能性，又提高了表面缺陷的检出率。

对于电子设备以及计算机可读存储介质实施例而言，由于其所涉及的方法内容基本相似于前述的方法实施例，所以描述的比较简单，相关之处参见方法实施例的部分说明即可。

需要说明的是，在本文中，诸如第一和第二等之类的关系术语仅仅用来将一个实体或者操作与另一个实体或操作区分开来，而不一定要求或者暗示这些实体或操作之间存在任何这种实际的关系或者顺序。而且，术语“包括”、“包含”或者其任何其他变体意在涵盖非排他性的包含，从而使得包括一系列要素的过程、方法、物品或者设备不仅包括那些要素，而且还包括没有明确列出的其他要素，或者是还包括为这种过程、方法、物品或者设备所固有的要素。在没有更多限制的情况下，由语句“包括一个……”限定的要素，并不排除在包括所述要素的过程、方法、物品或者设备中还存在另外的相同要素。

本说明书中的各个实施例均采用相关的方式描述，各个实施例之间相同相似的部分互相参见即可，每个实施例重点说明的都是与其他实施例的不同之处。尤其，对于装置、电子设备、计算机可读存储介质以及应用程序实施例而言，由于其基本相似于方法实施例，所以描述的比较简单，相关之处参见方法实施例的部分说明即可。

5

以上所述仅为本申请的较佳实施例而已，并不用以限制本申请，凡在本申请的精神和原则之内，所做的任何修改、等同替换、改进等，均应包含在本申请保护的范围之内。

—16—

权 利 要 求

1、一种表面缺陷检测方法，其特征在于，所述方法包括：

获取待检测图像；

5 将所述待检测图像输入预先训练得到的深度学习网络模型，得到所述待检测图像对应的无缺陷的重建图像，所述深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型；

将所述重建图像与所述待检测图像作差，得到差值图像；

在所述差值图像中，若存在差值大于预设差值的区域，则确定所述待检测图像存在表面缺陷。

10 2、根据权利要求1所述的方法，其特征在于，所述深度学习网络模型的训练方式，包括：

获取样本训练集，所述样本训练集中包括多个无缺陷的训练样本图像；

对所述样本训练集中的各训练样本图像进行加噪处理，得到各训练样本图像分别对应的加噪图像；

15 将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型。

3、根据权利要求2所述的方法，其特征在于，所述获取样本训练集，包括：

获取原始训练样本图像，所述原始训练样本图像包括无缺陷的样本图像；

20 对所述原始训练样本图像进行变换扩充，得到变换图像；

基于所有变换图像和所有原始训练样本图像，构成第一数量的训练样本图像；

将所述第一数量的训练样本图像按照预设尺寸进行裁剪分块，得到第二数量的训练样本图像；

25 将所述第二数量的训练样本图像作为样本训练集。

4、根据权利要求2所述的方法，其特征在于，所述将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型，包括：

将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输

30 出图像；
计算各所述输出图像与各所述加噪图像对应的训练样本图像之间的逐像素点的像素均方误差及梯度均方误差；

基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值；

判断所述总误差函数值是否小于或等于误差阈值；

若是，则确定所述深度学习网络模型训练完成；

35 若否，则根据所述总误差函数值，调整所述深度学习网络模型的网络参

-17-

数，并返回执行所述将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像。

5、根据权利要求4所述的方法，其特征在于，所述基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值，包括：

5 基于所述逐像素点的像素均方误差及梯度均方误差，利用总误差函数，计算得到总误差函数值，其中，所述总误差函数为：

$$\text{loss} = \frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2 + \frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$$

其中，所述m为输入的加噪图像对应的训练样本图像上的像素点个数，所述 $\frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2$ 为逐像素点的像素均方误差，所述 x'_i 为所述输出图像上第i个像素点的像素值，所述 x_i 为输入的加噪图像对应的训练样本图像上第i个像素点的像素值，所述 $\frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$ 为逐像素点的梯度均方误差，所述 $\nabla x'_i$ 为所述输出图像上第i个像素点的梯度值，所述 ∇x_i 为输入的加噪图像对应的训练样本图像上第i个像素点的梯度值。

6、一种表面缺陷检测装置，其特征在于，所述装置包括：

获取模块，用于获取待检测图像；

15 计算模块，用于将所述待检测图像输入预先训练得到的深度学习网络模型，得到所述待检测图像对应的无缺陷的重建图像，所述深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型；将所述重建图像与所述待检测图像作差，得到差值图像；

20 确定模块，用于在所述差值图像中，若存在差值大于预设差值的区域，则确定所述待检测图像存在表面缺陷。

7、根据权利要求6所述的装置，其特征在于，所述获取模块，还用于：获取样本训练集，所述样本训练集中包括多个无缺陷的训练样本图像；所述装置，还包括：

25 加噪模块，用于对所述样本训练集中的各训练样本图像进行加噪处理，得到各训练样本图像分别对应的加噪图像；

训练模块，用于将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型。

8、根据权利要求7所述的装置，其特征在于，所述获取模块，具体用于：

获取原始训练样本图像，所述原始训练样本图像包括无缺陷的样本图像；
对所述原始训练样本图像进行变换扩充，得到变换图像；

基于所有变换图像和所有原始训练样本图像，构成第一数量的训练样本图像；

5 将所述第一数量的训练样本图像按照预设尺寸进行裁剪分块，得到第二数量的训练样本图像；

将所述第二数量的训练样本图像作为样本训练集。

9、根据权利要求7所述的装置，其特征在于，所述训练模块，具体用于：

10 将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像；

计算各所述输出图像与各所述加噪图像对应的训练样本图像之间的逐像素点的像素均方误差及梯度均方误差；

基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值；

判断所述总误差函数值是否小于或等于误差阈值；

15 若是，则确定所述深度学习网络模型训练完成；

若否，则根据所述总误差函数值，调整所述深度学习网络模型的网络参数，并返回执行所述将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像。

20 10、根据权利要求9所述的装置，其特征在于，所述训练模块在实现所述基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值时，具体用于：

基于所述逐像素点的像素均方误差及梯度均方误差，利用总误差函数，计算得到总误差函数值，其中，所述总误差函数为：

$$\text{loss} = \frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2 + \frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$$

其中，所述m为输入的加噪图像对应的训练样本图像上的像素点个数，所述
25 述 $\frac{1}{2m} \sum_{i=1}^m (x'_i - x_i)^2$ 为逐像素点的像素均方误差，所述 x'_i 为所述输出图像上第i个像素点的像素值，所述 x_i 为输入的加噪图像对应的训练样本图像上第i个像素点的像素值，所述 $\frac{1}{2m} \sum_{i=1}^m (\nabla x'_i - \nabla x_i)^2$ 为逐像素点的梯度均方误差，所述 $\nabla x'_i$ 为所述输出图像上第i个像素点的梯度值，所述 ∇x_i 为输入的加噪图像对应的训练样本图像上第i个像素点的梯度值。

30 11、一种电子设备，其特征在于，包括处理器和存储器，其中，

所述存储器，用于存放计算机程序；

所述处理器，用于执行所述存储器上所存放的计算机程序时，实现如下步骤：

获取待检测图像；

5 将所述待检测图像输入预先训练得到的深度学习网络模型，得到所述待检测图像对应的无缺陷的重建图像，所述深度学习网络模型为基于包含多个无缺陷的训练样本图像的样本训练集，预先训练得到的深度学习网络模型；

将所述重建图像与所述待检测图像作差，得到差值图像；

10 在所述差值图像中，若存在差值大于预设差值的区域，则确定所述待检测图像存在表面缺陷。

12、根据权利要求 11 所述的电子设备，其特征在于，所述处理器还用于执行所述存储器上所存放的计算机程序时，实现如下步骤：

获取样本训练集，所述样本训练集中包括多个无缺陷的训练样本图像；

15 对所述样本训练集中的各训练样本图像进行加噪处理，得到各训练样本图像分别对应的加噪图像；

将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型。

13、根据权利要求 12 所述的电子设备，其特征在于，所述处理器在实现所述获取样本训练集时，具体实现如下步骤：

20 获取原始训练样本图像，所述原始训练样本图像包括无缺陷的样本图像；

对所述原始训练样本图像进行变换扩充，得到变换图像；

基于所有变换图像和所有原始训练样本图像，构成第一数量的训练样本图像；

25 将所述第一数量的训练样本图像按照预设尺寸进行裁剪分块，得到第二数量的训练样本图像；

将所述第二数量的训练样本图像作为样本训练集。

14、根据权利要求 12 所述的电子设备，其特征在于，所述处理器在实现所述将各所述加噪图像输入预设训练模型进行训练，得到所述深度学习网络模型时，具体实现如下步骤：

30 将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像；

计算各所述输出图像与各所述加噪图像对应的训练样本图像之间的逐像素点的像素均方误差及梯度均方误差；

35 基于所述逐像素点的像素均方误差及梯度均方误差，计算总误差函数值；判断所述总误差函数值是否小于或等于误差阈值；

若是，则确定所述深度学习网络模型训练完成；

若否，则根据所述总误差函数值，调整所述深度学习网络模型的网络参

—20—

数，并返回执行所述将各所述加噪图像输入预设卷积神经网络，得到各所述加噪图像的输出图像。




图1




图2




图3

—3/11—




图4

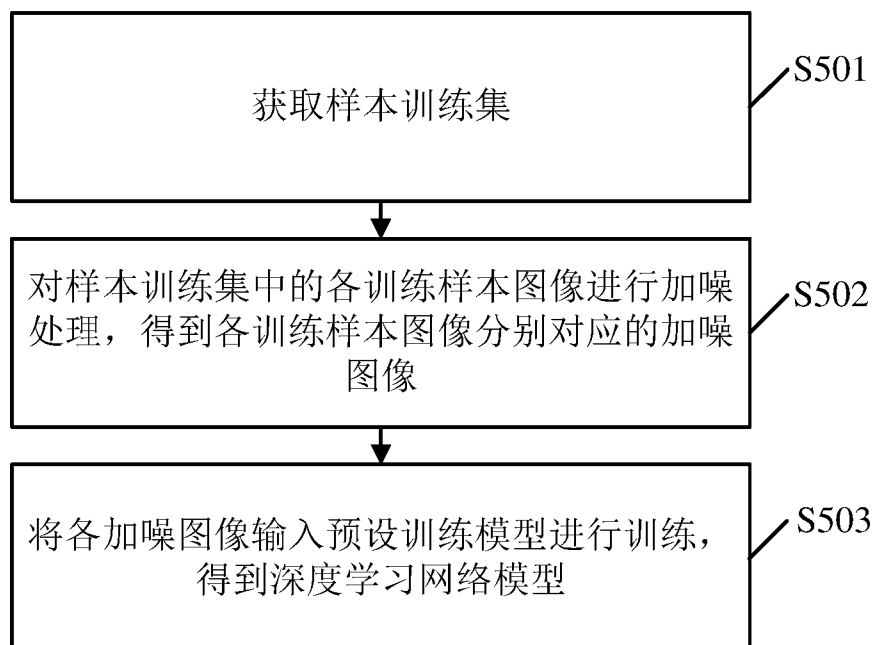


图5




图6




图7




图8




图9a




图9b




图9c




图10




图11a




图11b




图11c




图12




图13




图14




图15

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2019/079746

A. CLASSIFICATION OF SUBJECT MATTER G06K 9/62(2006.01)i According to International Patent Classification (IPC) or to both national classification and IPC		
B. FIELDS SEARCHED Minimum documentation searched (classification system followed by classification symbols) G06K; G06T Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched Electronic data base consulted during the international search (name of data base and, where practicable, search terms used) CNABS, DWPI, CNKI, SIPOABS: 缺陷, 检测, 卷积神经网络, 图像, 检测, 训练, 深度学习, 表面, defect, detect, convolutional neural network, image, training, deep learning, surface		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
X	CN 106650770 A (NANJING UNIVERSITY) 10 May 2017 (2017-05-10) description, paragraphs 0002-0007 and 0071-0134, and figure 1	1-14
☐ Further documents are listed in the continuation of Box C. ☒ See patent family annex.		
* Special categories of cited documents: “A” document defining the general state of the art which is not considered to be of particular relevance “E” earlier application or patent but published on or after the international filing date “L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified) “O” document referring to an oral disclosure, use, exhibition or other means “P” document published prior to the international filing date but later than the priority date claimed “T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention “X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone “Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art “&” document member of the same patent family		
Date of the actual completion of the international search		Date of mailing of the international search report
13 June 2019		01 July 2019
Name and mailing address of the ISA/CN		Authorized officer
State Intellectual Property Office of the P. R. China No. 6, Xitucheng Road, Jimenqiao Haidian District, Beijing 100088 China		
Facsimile No. (86-10)62019451		Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2019/079746

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)	Publication date (day/month/year)
CN	106650770	A	10 May 2017	None	

国际检索报告

国际申请号

PCT/CN2019/079746

A. 主题的分类

G06K 9/62 (2006.01) i

按照国际专利分类(IPC)或者同时按照国家分类和IPC两种分类

B. 检索领域

检索的最低限度文献(标明分类系统和分类号)

G06K; G06T

包含在检索领域中的除最低限度文献以外的检索文献

在国际检索时查阅的电子数据库(数据库的名称, 和使用的检索词(如使用))

CNABS, DWPI, CNKI, SIPOABS:缺陷, 检测, 卷积神经网络, 图像, 检测, 训练, 深度学习, 表面, defect, detect, convolutional neural network, image, training, deep learning, surface

C. 相关文件

类 型*

引用文件, 必要时, 指明相关段落

相关的权利要求

X

CN 106650770 A (南京大学) 2017年 5月 10日 (2017 - 05 - 10)
说明书0002-0007段, 0071-0134段, 图1

1-14

☐ 其余文件在C栏的续页中列出。☒ 见同族专利附件。

* 引用文件的具体类型:

“A” 认为不特别相关的表示了现有技术一般状态的文件

“E” 在国际申请日的当天或之后公布的在先申请或专利

“L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件(如具体说明的)

“O” 涉及口头公开、使用、展览或其他方式公开的文件

“P” 公布日先于国际申请日但迟于所要求的优先权日的文件

“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件

“X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性

“Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性

“&” 同族专利的文件

国际检索实际完成的日期

2019年 6月 13日

国际检索报告邮寄日期

2019年 7月 1日

ISA/CN的名称和邮寄地址

中国国家知识产权局(ISA/CN)
中国北京市海淀区蓟门桥西土城路6号 100088

传真号 (86-10)62019451

授权官员

张一良

电话号码 62089422

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2019/079746

检索报告引用的专利文件	公布日 (年/月/日)	同族专利	公布日 (年/月/日)
CN 106650770 A	2017年 5月 10日	无	