

(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
2024 年 12 月 19 日 (19.12.2024)



(10) 国际公布号
WO 2024/255919 A1

- (51) 国际专利分类号:
G06T 7/00 (2017.01)
- (21) 国际申请号: PCT/CN2024/107018
- (22) 国际申请日: 2024 年 7 月 23 日 (23.07.2024)
- (25) 申请语言: 中文
- (26) 公布语言: 中文
- (30) 优先权:
63/508,275 2023年6月15日 (15.06.2023) US
202410709277.5 2024年6月3日 (03.06.2024) CN
- (71) 申请人: 人工智能设计研
究 有 限 公 司 (**LABORATORY FOR ARTIFICIAL
INTELLIGENCE IN DESIGN LIMITED**) [CN/CN]; 中
国香港特别行政区新界沙田香港科学园科技大道西19号19W大楼16楼1613-1615室, Hong Kong
999077 (CN)。香港理工大学(**THE HONG KONG**

POLYTECHNIC UNIVERSITY) [CN/CN]; 中国香港
特别行政区九龙红磡香港理工大学, Hong Kong
999077 (CN)。皇家艺术学院(**ROYAL COLLEGE
OF ART**) [GB/GB]; 英国大伦敦南肯辛顿区肯辛
顿角里, Greater London SW72EU (GB)。

- (72) 发明人: 黄伟强(**WONG, Wai Keung Calvin**); 中国香港特别行政区新界沙田香港科学园科技大道西19号19W大楼16楼1613-1615室, Hong Kong 999077 (CN)。陈哲玮(**CHEN, Zhewei**); 中国香港特别行政区新界沙田香港科学园科技大道西19号19W大楼16楼1613-1615室, Hong Kong 999077 (CN)。张容琛(**ZHANG, Rongchen**); 中国香港特别行政区新界沙田香港科学园科技大道西19号19W大楼16楼1613-1615室, Hong Kong 999077 (CN)。
- (74) 代理人: 隆天知识产权代理有限公司(**LUNG TIN
INTELLECTUAL PROPERTY AGENT LTD.**); 中国

(54) Title: DEFECT DETECTION METHOD AND RELATED DEVICE

(54) 发明名称: 瑕疵检测方法及相关设备




图 1

- S110 ACQUIRE AN IMAGE TO BE PROCESSED
- S120 PROCESS SAID IMAGE BY MEANS OF A FEATURE EXTRACTION MODULE IN A DEEP-LEARNING DEFECT DETECTION MODEL, WHEREIN THE FEATURE EXTRACTION MODULE COMPRISES AN INTERMEDIATE FEATURE LAYER, THE INTERMEDIATE FEATURE LAYER COMPRISES A DROPOUT LAYER, AND THE DROPOUT LAYER IS CONFIGURED TO RANDOMLY DROP FEATURES WHICH ARE EXTRACTED BY MEANS OF THE INTERMEDIATE FEATURE LAYER PROCESSING SAID IMAGE, SUCH THAT A PLURALITY OF FEATURES SUBJECTED TO RANDOM DROPOUT ARE OBTAINED AFTER SAID IMAGE IS PROCESSED BY MEANS OF THE FEATURE EXTRACTION MODULE
- S130 BY MEANS OF A DETECTION HEAD IN THE DEEP-LEARNING DEFECT DETECTION MODEL, PROCESS THE PLURALITY OF FEATURES SUBJECTED TO RANDOM DROPOUT, SO AS TO OBTAIN A PLURALITY OF CATEGORY PREDICTION RESULTS AND A PLURALITY OF POSITION PREDICTION RESULTS OF DEFECTS IN SAID IMAGE
- S140 OBTAIN CATEGORY DETECTION RESULTS, POSITION DETECTION RESULTS, CATEGORY UNCERTAINTIES AND POSITION UNCERTAINTIES OF THE DEFECTS IN SAID IMAGE ACCORDING TO THE PLURALITY OF CATEGORY PREDICTION RESULTS AND THE PLURALITY OF POSITION PREDICTION RESULTS OF THE DEFECTS

(57) Abstract: The present disclosure belongs to the technical fields of computers and defect detection. Provided are a defect detection method and a related device. The method comprises: obtaining an image to be processed; processing said image by means of a feature extraction module in a deep-learning defect detection model, wherein the feature extraction module comprises an intermediate feature layer, the intermediate feature layer comprises a dropout layer, and the dropout layer is configured to randomly drop features which are extracted by means of the intermediate feature layer processing said image, such that a plurality of features subjected to random dropout are obtained after said image is processed by means of the feature extraction module; by means of a detection head in the deep-learning defect detection model, processing the plurality of features subjected to random dropout, so as to obtain a plurality of category prediction results and a plurality of position prediction results of defects in said image; and obtaining category detection results, position detection

北京市朝阳区慧忠路5号远大中心B座
18层, Beijing 100101 (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, CV, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IQ, IR, IS, IT, JM, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, MG, MK, MN, MU, 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, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, 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, CV, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SC, 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, ME, 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))。
— 包括关于请求恢复一项或多项优先权要求的信息
(细则26之二.3和48.2(b)(vii))。

results, category uncertainties and position uncertainties of the defects in said image according to the plurality of category prediction results and the plurality of position prediction results of the defects. (FIG. 1)

(57) 摘要: 本公开提供一种瑕疵检测方法及相关设备, 属于计算机和缺陷检测技术领域。该方法包括: 获得待处理图像; 通过深度学习瑕疵检测模型中的特征提取模块处理待处理图像, 特征提取模块包括中间特征层, 中间特征层中包括丢弃层, 丢弃层用于对中间特征层处理待处理图像后提取的特征进行随机丢弃, 以使得待处理图像经过特征提取模块处理后获得经过随机丢弃处理后的多个特征; 通过深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理, 获得待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果; 根据瑕疵的多个类别预测结果和多个位置预测结果, 获得待处理图像中的瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。(图1)

瑕疵检测方法及相关设备

相关申请的交叉引用

本公开要求于 2024 年 06 月 03 日提交的申请号为 202410709277.5、名称为“瑕疵检测方法及相关设备”的中国专利申请的优先权，并要求于 2023 年 6 月 15 日提交的申请号为 63/508,275 的美国专利申请的优先权，该中国专利申请和该美国专利申请的全部内容通过引用全部并入本文。

技术领域

本公开涉及计算机和缺陷检测技术领域，具体而言，涉及一种瑕疵检测方法、装置及系统、电子设备、计算机可读存储介质及计算机程序产品。

背景技术

在现实的生产生活场景中，产品或物品可能会存在各种缺陷。这些产品或物品在出厂之前，需要对其进行缺陷检测，以避免有缺陷的产品或物品流通到市场上。

发明内容

本公开实施例提供了一种瑕疵检测方法，包括：获得待处理图像；通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像，所述特征提取模块包括中间特征层，所述中间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征；通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理，获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果；根据所述瑕疵的多个类别预测结果和多个位置预测结果，获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

本公开实施例提供了一种瑕疵检测装置，包括：图像获得模块，用于获得待处理图像；图像处理模块，用于通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像，所述特征提取模块包括中间特征层，所述中间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征；所述图像处理模块还用于，通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处

理，获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果；所述图像处理模块还用于，根据所述瑕疵的多个类别预测结果和多个位置预测结果，获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

本公开实施例提供了一种瑕疵检测系统，包括：图像采集组件，用于获取处于生产过
5 程中的待检测对象的所述待处理图像；瑕疵检测装置，与所述图像采集组件连接，用于从
所述图像采集组件获得所述待处理图像；其中，所述瑕疵检测装置包括：图像处理模块，
用于通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像，所述特征提取模
块包括中间特征层，所述中间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处
理所述待处理图像后提取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取
10 模块处理后获得经过随机丢弃处理后的多个特征；通过所述深度学习瑕疵检测模型中的检
测头对经过随机丢弃处理后的多个特征进行处理，获得所述待处理图像中的瑕疵的多个类
别预测结果、多个位置预测结果；根据所述瑕疵的多个类别预测结果和多个位置预测结果，
获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置
不确定性。

15 本公开实施例提供了一种瑕疵检测系统，包括：图像拍摄设备，用于采集处于生产过
程中的待检测对象的所述待处理图像；处理器和用于存储计算机程序的存储器；当所述处
理器执行所述计算机程序时，实现如本公开任一实施例所述方法中的步骤。

本公开实施例提供了一种电子设备，包括：一个或多个处理器；存储器，配置为存储
一个或多个程序，当所述一个或多个程序被所述一个或多个处理器执行时，使得所述电子
20 设备实现本公开任一实施例中所述的方法。

本公开实施例提供了一种计算机可读存储介质，其上存储有计算机程序，当所述计算
机程序在计算机上运行时，使得计算机执行时实现本公开任一实施例中所述的方法。

本公开实施例提供了计算机程序产品，包括计算机程序，该计算机程序被计算机执行
时实现本公开实施例中所述的方法。

附图说明

图 1 是本公开一示例性实施例的瑕疵检测方法的流程图。

图 2 是本公开一示例性实施例的深度学习瑕疵检测模型的示意图。

图 3 是本公开另一示例性实施例的深度学习瑕疵检测模型的示意图。

30 图 4 是图 3 所示的第一跨阶段卷积块和第二跨阶段卷积块的示意图。

图 5 是图 4 所示的第一中间层和第二中间层的示意图。

图 6 是图 5 所示的第一深度可分离卷积层和第二深度可分离卷积层的示意图。

图 7 是图 3 所示的第三跨阶段卷积块的示意图。

图 8 是本公开又一示例性实施例的深度学习瑕疵检测模型的示意图。

图 9 是本公开再一示例性实施例的深度学习瑕疵检测模型的示意图。

5 图 10 是本公开一示例性实施例的空间金字塔池化块的示意图。

图 11 是本公开实施例中的空间金字塔池化块的替代实施例的示意图。

图 12 是图 9 所示的注意力块的示意图。

图 13 是本公开一示例性实施例的瑕疵检测系统的示意图。

图 14 是本公开另一示例性实施例的瑕疵检测系统的示意图。

10 图 15 是本公开又一示例性实施例的瑕疵检测系统的示意图。

图 16 是本公开一示例性实施例的瑕疵检测装置的结构示意图。

图 17 示意性示出了根据本公开的一实施例的电子设备的示意性结构图。

具体实施方式

15 为了使得本公开的目的、技术方案和优点更为明显，下面将参照附图详细描述根据本公开的示例实施例。在附图中，相同的参考标号自始至终表示相同的元件。应当理解：这里描述的实施例仅仅是说明性的，而不应被解释为限制本公开的范围。

本公开实施例中，术语“模块”或“单元”是指有预定功能的计算机程序或计算机程序的一部分，并与其他相关部分一起工作以实现预定目标，并且可以通过使用软件、硬件
20 （如处理电路或存储器）或其组合来全部或部分实现。同样的，一个处理器（或多个处理器或存储器）可以用来实现一个或多个模块或单元。此外，每个模块或单元都可以是包含该模块或单元功能的整体模块或单元的一部分。

在本公开中，术语“第一”、“第二”、“第三”仅用于描述的目的，而不能理解为指示或暗示相对重要性；术语“多个”则指两个或两个以上，除非另有明确的限定。术语
25 “安装”、“相连”、“连接”、“固定”等术语均应做广义理解，例如，“连接”可以是固定连接，也可以是可拆卸连接，或一体地连接；“相连”可以是直接相连，也可以通过中间媒介间接相连。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在本公开中的具体含义。

本公开的描述中，需要理解的是，术语“上”、“下”、“左”、“右”、“前”、
30 “后”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公开和简化描述，而不是指示或暗示所指的装置或单元必须具有特定的方向、以特定的方

位构造和操作，因此，不能理解为对本公开的限制。

在本说明书的描述中，术语“一个实施例”、“一些实施例”、“具体实施例”等的描述意指结合该实施例或示例描述的具体特征、结构、材料或特点包含于本公开的至少一个实施例或示例中。在本说明书中，对上述术语的示意性表述不一定指的是相同的实施例或实例。而且，描述的具体特征、结构、材料或特点可以在任何的一个或多个实施例或示例中以合适的方式结合。

以上所述仅为本公开的优选实施例而已，并不用于限制本公开，对于本领域的技术人员来说，本公开可以有各种更改和变化。凡在本公开的精神和原则之内，所作的任何修改、等同替换、改进等，均应包含在本公开的保护范围之内。

图 1 实施例提供的瑕疵检测方法可以有任意的电子设备执行，例如终端和/或服务器，本公开对此不做限定。如图 1 所示，本公开实施例提供的方法包括如下步骤。

在 S110 中，获得待处理图像。

本公开实施例中的待处理图像可以是任意需要检测其是否包含缺陷或瑕疵的待检测对象的图像。该待检测对象例如可以是卫生及个人护理产品，例如医疗、卫生用产品，如手术衣、防护服、消毒包布、口罩、尿片、民用抹布、擦拭布、湿面巾、魔术毛巾、柔巾卷、美容化妆品等；也可以是家庭装饰用产品，如贴墙布、台布、床单、床罩等；还可以是服装用产品，如衬里、粘合衬、絮片、定型棉、各种合成革底布等；也可以是工业用产品，如过滤材料、绝缘材料、水泥包装袋、土工布、包覆布等；也可以是农业用产品，如作物保护布、育秧布、灌溉布、保温幕帘等；还可以是其它产品，如太空棉、保温隔音材料、吸油毡、烟过滤嘴、袋包茶叶袋等。

在下面的实施例中，均以待检测对象为口罩（包括已经缝制成型的口罩和处于裁剪过程中的口罩），对应的该待处理图像为口罩图像为例进行举例说明。在另一些实施例中，待检测对象为处于生产流水线（以下简称为生产线）高速运动的口罩布，对应的待处理图像为口罩布图像。例如，该口罩布可以是无纺布，但本公开并不限于此，也可以采用其它合适的材料作为口罩布。此时，本公开涉及无纺布材料检测技术领域，主要面向口罩布瑕疵检测细分领域，该方法也可以称之为无纺口罩布瑕疵检测方法或口罩布瑕疵检测方法。

例如，采用无纺布制作口罩的工序主要包括材料准备、裁剪、缝制和整理等环节。在准备好原材料后，进行裁剪。将无纺布铺平，用切割机进行剪裁，剪出口罩的主体部分。接着是缝制环节，将无纺布、鼻梁条、耳带等部件缝制在一起，形成完整的口罩。最后，还需要进行整理和质量检查，确保每个口罩都符合质量标准，相关技术中主要涉及成品口

罩的瑕疵检测，未涉及处于口罩生产线上的口罩布的瑕疵检测，无法在生产阶段实现质量管理和控制。

由于近年来爆发的全球性流行病（例如 covid-19）对公共安全造成了巨大的威胁，使得人们对口罩的需求激增。而口罩质量对于流行病的防控具有不可忽视的作用。因此，口罩生产企业需要在保证质量的前提下，提高口罩的生产效率。而相关技术中，主要采用人工检测方式，基于人工检测实现口罩质量控制的方式缺乏效率，而且存在标准不统一和精度低的问题。本公开实施例提供的方法通过机器视觉技术实现对处于生产流水线上的口罩布的自动化的瑕疵检测，能够在保证口罩质量的前提下，较大的提高生产效率，同时可以有效减少人工成本。

在 S120 中，通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像，所述特征提取模块包括中间特征层，所述中间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征。

本公开实施例中的深度学习瑕疵检测模型是一种基于深度学习的、能够对图像进行处理，检测出图像中是否存在瑕疵，以及在检测出瑕疵时，预测出该瑕疵的瑕疵信息的模型，该瑕疵信息例如包括瑕疵的尺寸、位置、类别等中的任意一种或者多种。例如，该深度学习瑕疵检测模型可以基于目标检测模型，例如 YOLO（You Only Look Once）系列（例如 YOLOv3、YOLOv4、Yolov5 等）、Faster R-CNN、SSD、CNN（卷积神经网络）、循环神经网络（RNN）和变换器（Transformer）等中的任意一种或者多种的组合。在下面的实施例中，以 YOLO 模型进行举例说明，但本公开并不限于此。

本公开实施例中的深度学习瑕疵检测模型是一种实时目标检测模型，将输入的待处理图像分割成网格，每个网格负责检测一个目标（即瑕疵），并预测目标的边界框（也称为锚框）和类别。深度学习瑕疵检测模型包括特征提取模块，特征提取模块为深度学习瑕疵检测模型中的骨干网络（Backbone），主要负责提取输入的待处理图像的特征。骨干网络可以包括卷积层、池化层和其它可能的网络层等，能够逐步提取待处理图像中的深层特征，用于将待处理图像转化为多层的特征图（feature maps）。这些特征图随后被用于目标检测任务，如边界框预测和类别分类。例如，骨干网络可以包含 Conv 模块（卷积模块）、C3 模块（由三个标准卷积层组成，每个卷积层具有特定的卷积核大小和步长）和 SPPF 模块（空间金字塔池化层，用于在多个尺度上聚合特征）等，这些模块通过卷积、池化等操作，提取并融合不同层次的特征信息。

Backbone 的中间特征层是指在 Backbone 网络中,位于输入层之后(如果存在输出层,则位于输入层和输出层之间)的隐藏层(不包括特征金字塔和检测头),以用于产生待处理图像的特征图。这些中间特征层捕捉了待处理图像在不同层次和不同尺度上的信息。中间特征层的信息不仅可以被用于生成最终的检测结果,有时还可以被用于其他任务,如特征融合或进一步的分析。例如,可以利用 Backbone 的中间特征层与其他网络部分(如 FPN,即特征金字塔网络/模块)进行融合,以提高检测性能。

本公开实施例中,在深度学习瑕疵检测模型的特征提取模块的中间特征层新增了丢弃(dropout)层,dropout 通过随机的地“关闭”或“擦除”隐藏层中的一部分神经元(或特征),使得被删除的神经元不再进行信号的传递,来模拟不同子网络之间的集成学习。这样可以有效地防止模型过拟合,并提高其在未见数据(即训练数据集中未包含的数据)上的泛化能力。通过 dropout,模型被迫学习更加鲁棒的特征表示,因为它不能依赖于任何特定的神经元组合。dropout 在一定程度上可以被看作是一种贝叶斯近似方法,通过随机地“关闭”一部分神经元,模拟了模型参数的稀疏性,这与贝叶斯推断中的参数后验分布有一定的相似性。dropout 并不是直接模拟贝叶斯的后验分布,而是通过其随机性提供了一种正则化的效果,有助于减少过拟合。本公开实施例将 dropout 添加在 Backbone 的中间特征层,可以利用其防止过拟合的能力,提高模型的泛化性能。同时还可以降低神经网络的复杂度和参数数量。如果 dropout 只在训练阶段开启,在推理阶段关闭,则是用于防止模型过拟合。本公开实施例中,不论训练阶段还是推理阶段均开启 dropout,以用于模拟贝叶斯不确定。

在 S130 中,通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理,获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果。

本公开实施例在 dropout 的作用下,通过随机关闭隐藏层中的神经元(让一部分的隐藏层的节点值为 0),可以随机刻画隐藏层的网络结构的生成过程,例如神经网络的层数,每一层的神经元的连接方式等,能够得到该中间特征层的多个不同网络结构,从而对同一个待处理图像(在训练过程中是对同一个目标样本图像)通过该中间特征层的多个不同的网络结构进行多次预测,从而获得该待处理图像中每个瑕疵的多个类别预测结果和多个位置预测结果。不确定性估计就是计算多次预测的结果的分布指标。

本公开实施例中,类别预测结果是指通过深度学习瑕疵检测模型的检测头(例如其中的深度可分离卷积块)预测输出的该瑕疵所属的类别结果。位置预测结果是指通过深度学习瑕疵检测模型的检测头(例如其中的深度可分离卷积块)预测输出的该瑕疵在该图像(包

括待处理图像和/或目标样本图像) 中所处的位置, 可以是绝对位置, 也可以是相对位置。类别预测结果可以包括预测出来的该瑕疵属于各个类别的概率, 位置预测结果可以包括预测出来的该瑕疵在该图像中的边界框的中心坐标、宽度和高度等信息。

在 S140 中, 根据所述瑕疵的多个类别预测结果和多个位置预测结果, 获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

本公开实施例中深度学习瑕疵检测模型的检测头在目标检测任务中, 主要负责预测待处理图像中瑕疵的类别、边界框的位置以及置信度, 还可以预测所预测出来的瑕疵的类别的类别不确定性和位置的位置不确定性。在一些实施例中, 检测头可以利用多个卷积层来进一步提取和整合特征, 然后输出瑕疵的多个类别预测结果、多个位置预测结果, 并基于瑕疵的多个类别预测结果和多个位置预测结果, 获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

本公开实施例中, 类别检测结果和位置检测结果分别是指深度学习瑕疵检测模型的检测头对外输出的该瑕疵的类别结果和该瑕疵在该图像中所处的位置。

本公开实施例中, 类别不确定性是指采用深度学习瑕疵检测模型预测图像(包括待处理图像和/或目标样本图像) 中的瑕疵的类别预测结果时, 用于评估其预测的类别结果与该瑕疵的真实类别是否匹配的确定程度的指标, 类别不确定性越高, 表示该深度学习瑕疵检测模型对该瑕疵的类别预测结果越不确定, 类别不确定性越低, 表示该深度学习瑕疵检测模型对该瑕疵的类别预测结果越确定。

本公开实施例中, 位置不确定性是指采用深度学习瑕疵检测模型预测图像(包括待处理图像和/或目标样本图像) 中的瑕疵的位置预测结果时, 用于评估其预测的位置结果与该瑕疵的真实位置是否匹配的确定程度的指标, 位置不确定性越高, 表示该深度学习瑕疵检测模型对该瑕疵的位置预测结果越不确定, 位置不确定性越低, 表示该深度学习瑕疵检测模型对该瑕疵的位置预测结果越确定。

本公开实施例中, 在深度学习瑕疵检测模型中, 除了预测边界框的位置和类别, 还可以预测输出边界框的置信度, 预测输出的置信度是一个介于 0 和 1 之间的数值, 用于表示模型对检测到的瑕疵的确信程度。置信度可以表示边界框内是否有瑕疵(也可称之为疵点) 的概率(也可以称之为目标置信度), 即边界框内是否只是背景还是包含瑕疵。可选的, 还可以表示当边界框有瑕疵时, 模型预测的边界框与瑕疵的真实框之间的匹配程度; 也可以表示当边界框有瑕疵时, 模型预测的类别结果与该瑕疵的真实类别之间的匹配程度。例如, 置信度可以通过计算预测的边界框与实际瑕疵之间的 IoU (Intersection over Union,

交并比)来得出的。如果 IoU 大于某个设定的阈值,则认为检测到了瑕疵,此时置信度即为该边界框的 IoU 得分;如果 IoU 小于设定的阈值,则认为未检测到瑕疵,置信度则为 0。

不确定性估计是衡量检测结果可信程度的有效方法。目标检测任务中的不确定性可以分为数据不确定性和模型不确定性。数据不确定性主要来源于真实数据(例如输入的待处理图像或目标样本图像)中的固有噪声,模型不确定性则来源于模型参数的不确定性。本公开实施例中的类别不确定性中可以同时包含数据不确定性和模型不确定性,位置不确定性中也可以同时包含数据不确定性和模型不确定性。其中,数据不确定性占比相对较小,跟噪声、样本的标注质量相关。

当预测不确定性不足时,模型可能会过于自信地给出错误的类别检测结果和位置检测结果。例如,在生产线上的质量检测中,模型可能会错误地将一个有缺陷/瑕疵的产品分类为无缺陷,或者反之。这种错误的分类可能导致生产线的效率低下,甚至影响产品的整体质量。对于需要依赖模型预测结果进行质量控制的生产过程来说,如果模型不能提供可靠和准确的预测,那么这些预测结果就可能不会被最终用户所信任。

在示例性实施例中,可以计算瑕疵的多个类别预测结果的均值作为该瑕疵的类别检测结果。类别预测结果表示检出的瑕疵为哪种类型瑕疵的概率,类别预测结果也可以称之为类别置信度,因此类别检测结果也可称之为类别置信度均值。可以将该瑕疵的多个位置预测结果的均值作为该瑕疵的位置检测结果。当采用坐标表示位置,则位置检测结果也可称之为坐标均值。

本公开实施例中,类别不确定性是类别置信度的不确定性,是类别置信度的概率分布指标,即类别置信度概率分布情况表示了类别不确定性,因此也可以称之为类别置信度不确定性,例如可以用类别置信度的方差来计算,此时可称之为类别置信度方差。位置不确定性是边界框的概率分布指标,边界框概率分布情况表示了位置不确定性,例如可以计算位置预测结果的方差来获得位置不确定性。当采用坐标表示位置、且计算坐标的方差作为位置不确定性时,位置不确定性也可称之为坐标方差。

例如,模型输出包括 [坐标均值,坐标方差(位置不确定性),类别置信度均值,类别置信度方差(类别不确定性),目标置信度]。其中,目标置信度表示该检出是否为疵点的概率。类别置信度均值表示该检出为哪种类型疵点的概率。

本公开实施例中,可以设置置信度阈值,若模型输出的目标置信度小于该置信度阈值,则将该目标置信度较低的瑕疵检出,例如提示人工进行判断。该置信度阈值为大于 0 且小于 1 的实数,例如可以设置为 0.3,但本公开并不限于此。

假设每个边界框的位置或坐标用 (x, y, w, h) 表示,其中 x, y, w, h 分别表示

边界框的中心横坐标和纵坐标、宽度和高度，则坐标均值表示为： $\text{mean}_{b_x}, \text{mean}_{b_y}, \text{mean}_{b_w}, \text{mean}_{b_k}$ 。坐标方差表示为： $\text{variance}_{b_x}, \text{variance}_{b_y}, \text{variance}_{b_w}, \text{variance}_{b_h}$ 。再例如类别置信度均值和类别置信度方差分别是： $\text{mean}_{z_c}, \text{variance}_{z_c}$ 。则类别置信度 $p(c | \text{Object})$ 可以表示为(c 表示当前类别， k 表示遍历所有类别)：

$$p(c | \text{Object}) = \frac{\exp(\text{mean}_{z_c})}{\sum_k \exp(\text{mean}_{z_k})} \quad (1)$$

但本公开并不限于此，例如也可以选择该瑕疵的多个类别预测结果中出现频次最高的类别预测结果作为该瑕疵的类别检测结果，选择该瑕疵的多个位置预测结果中出现频次最高的位置预测结果作为该瑕疵的位置检测结果。由于本公开实施例中的瑕疵的类别检测结果和位置检测结果综合考虑了该瑕疵的多个类别预测结果和多个位置预测结果，因此其输出的检测结果（包括类别检测结果和位置检测结果）的准确性更高。

需要说明的是，本公开实施例中，深度学习瑕疵模型预测输出的类别预测结果是类别置信度均值。模型输出的类别置信度均值采用上述公式（1）进行系统的后处理过程，后处理实际上是在模型输出后新增一个 softmax 过程，将类别置信度映射到[0,1]之间的实数。可选的，后处理过程还可以保护边界框 NMS（非极大值抑制）等。

在示例性实施例中，可以计算瑕疵的多个类别预测结果的方差作为该瑕疵的类别不确定性，将该瑕疵的多个位置预测结果的方差作为该瑕疵的位置不确定性。

本公开不限于直接将方差作为不确定性，例如，还可以通过如下公式计算不确定性：

$$\text{Uncertainty} = \exp(-\lambda \cdot \text{variance}) \quad (2)$$

其中 λ 表示调节项，为大于 0 且小于 1 的实数。 variance 表示多个类别预测结果的方差或多个位置预测结果的方差。 Uncertainty 表示类别不确定性或位置不确定性。

在一些实施例中，可以设置不确定阈值，以用于过滤不确定性较高的预测结果。

对环境因素的敏感性可能会影响模型的检测性能，诸如光线、阴影和杂乱背景等环境因素。本公开实施例通过优化模型，以提高其在实际环境中的稳定性和准确性。例如，引入贝叶斯估计/贝叶斯预测，来提高模型对自然环境的泛化能力和鲁棒性。贝叶斯估计通过新增了 dropout 层，随机擦除一部分特征的输出来模拟随机性。同时改了模型的检测头的输出，将输出解释为概率分布，而不仅仅是回归问题，将输出解释为概率分布可以更好地捕捉瑕疵的位置和类别的不确定性。这样，模型不仅能够给出预测的确定性估计，还能够提供关于这些估计的不确定性度量。这对于处理复杂的自然环境尤为重要，因为在这种环境中，目标的位置、大小和外观可能会受到多种因素的影响而发生变化。通过结合贝叶斯估计和 dropout 层以及将输出解释为概率分布，可以构建出更加健壮和泛化能力更强的深度学习瑕疵检测模型。这样的模型能够更好地适应自然环境中的变化，提高检测的准确性和可靠性。

本公开实施方式提供的瑕疵检测方法，通过在深度学习瑕疵检测模型的特征提取模块

中的中间特征层中新增丢弃层，简化了对后验概率分布的近似，从而不仅能够快速有效的对待处理图像中的瑕疵的类别和位置做出预测，还能够对预测结果的类别不确定性和位置不确定性做出评估。本公开实施例开发了一个更加精确、高效且具有良好泛化能力的新型的深度学习瑕疵检测模型。能够在不牺牲检测速度的情况下，提高瑕疵识别准确率，并能够适应各种生产环境和待检测对象类型的需求，具有广泛的应用前景，例如可以应用于口罩布料瑕疵检测系统中，以对不同口罩类型中的瑕疵进行识别。

如图 2 所示，本公开实施例提供的深度学习瑕疵检测模块 1 包括特征提取模块 11 和检测头 12。特征提取模块 11 包括输入块 111 和中间特征层 112。输入块 111 用于接收待处理图像，并将该待处理图像发送至中间特征层 112。中间特征层 112 包括丢弃层 1121。输入块 111 还可以用于对接收到的输入的待处理图像进行预处理，如调整尺寸和归一化，以便适应模型的输入要求。

通过深度学习瑕疵检测模型 1 中的特征提取模块 11 处理待处理图像，特征提取模块 11 的中间特征层 112 中的丢弃层 1121，用于对中间特征层 112 处理待处理图像后提取的特征进行随机丢弃，以使得待处理图像经过特征提取模块 11 处理后获得经过随机丢弃处理后的多个（具体采样的个数，可以根据实际需求进行设定）特征。然后，通过深度学习瑕疵检测模型 1 中的检测头 12 对经过随机丢弃处理后的多个特征分别进行处理，获得待处理图像中的瑕疵的多个类别预测结果和多个位置预测结果。检测头 12 还根据瑕疵的多个类别预测结果和多个位置预测结果，获得待处理图像中的瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

在示例性实施例中，所述中间特征层包括第一跨阶段卷积块，所述丢弃层包括第一丢弃层。其中，所述第一跨阶段卷积块包括第一跨阶段输入层、第一卷积层、第一中间层、第二卷积层、第一融合层、第三卷积层和所述第一丢弃层。所述第一卷积层用于将所述第一跨阶段输入层输入的第一跨阶段输入特征图进行卷积处理，向所述第一中间层输入第一卷积特征图。所述第一中间层用于对所述第一卷积特征图进行处理，向所述第一融合层输入第一待融合特征图。所述第二卷积层用于对所述第一跨阶段输入特征图进行卷积处理，向所述第一融合层输入第二待融合特征图。所述第一融合层用于对所述第一待融合特征图和所述第二待融合特征图进行融合处理，向所述第三卷积层输入第一融合特征图。所述第三卷积层用于对所述第一融合特征图进行卷积处理，向所述第一丢弃层输入第二卷积特征图。所述第一丢弃层用于对所述第二卷积特征图中的特征进行随机丢弃，获得多个第一丢弃特征图，所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个

特征包括多个所述第一丢弃特征图。

本公开实施例中的跨阶段输入层（包括第一至第三跨阶段输入层）、中间输入层（包括第一至第三中间输入层）、深度分离输入层（包括第一至第三深度分离输入层）均为模型中相应模块的输入层，其命名仅是为了区分该输入层属于哪个模块，例如跨阶段输入层表示其为跨阶段卷积块的输入层。输入层用于对输入的特征图或图像数据进行预处理，如调整尺寸，以便适应模型中相应模块的输入要求。

本公开实施例中的卷积特征图（例如包括第一至六卷积特征图）是指进行卷积处理后获得的特征图；待融合特征图（例如包括第一至第六待融合特征图）是指待进行融合处理的特征图，这里的融合处理例如可以是拼接或者级联，例如将第一待融合特征图和第二待融合特征图进行级联获得第一融合特征图。丢弃特征图（例如包括第一至第三丢弃特征图）是指通过相应的 dropout 层进行特征的随机丢弃处理生成的特征图。空间池化特征图（例如包括第一至第三空间池化特征图）是指经过空间金字塔池化块（例如包括第一至第三空间金字塔池化块）处理后生成的特征图。

在示例性实施例中，所述中间特征层还包括第二跨阶段卷积块和第三跨阶段卷积块，所述丢弃层还包括第二丢弃层和第三丢弃层。

其中，所述第二跨阶段卷积块的输入端连接所述第一跨阶段卷积块的输出端，以分别接收多个所述第一丢弃特征图，并对多个所述第一丢弃特征图进行处理，通过所述第二丢弃层向所述第三跨阶段卷积块输入多个第二丢弃特征图。所述第三跨阶段卷积块的输入端连接所述第二跨阶段卷积块的输出端，以分别接收多个所述第二丢弃特征图，并对多个所述第二丢弃特征图进行处理，通过所述第三丢弃层输出多个第三丢弃特征图。

其中，所述第二跨阶段卷积块包括第二跨阶段输入层、第四卷积层、第二中间层、第五卷积层、第二融合层、第六卷积层和所述第二丢弃层。所述第二跨阶段输入层连接所述第一丢弃层，用于分别将多个所述第一丢弃特征图作为第二跨阶段输入特征图。所述第四卷积层用于将所述第二跨阶段输入层输入的第二跨阶段输入特征图进行卷积处理，向所述第二中间层输入第三卷积特征图。所述第二中间层用于对所述第三卷积特征图进行处理，向所述第二融合层输入第三待融合特征图。所述第五卷积层用于对所述第二跨阶段输入特征图进行卷积处理，向所述第二融合层输入第四待融合特征图。所述第二融合层用于对所述第三待融合特征图和所述第四待融合特征图进行融合处理，向所述第六卷积层输入第二融合特征图。所述第六卷积层用于对所述第二融合特征图进行卷积处理，向所述第二丢弃层输入第四卷积特征图。所述第二丢弃层用于对所述第四卷积特征图中的特征进行随机丢

弃，获得多个第二丢弃特征图，所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征还包括多个所述第二丢弃特征图。

本公开实施例中的跨阶段卷积块（例如包括第一至第三跨阶段卷积块）采用了跨阶段部分连接的思想，通过将不同阶段的特征图进行融合，增强了特征的多样性和鲁棒性。这种设计有助于提升模型的性能，特别是在处理复杂的目标检测任务时。具体来说，跨阶段卷积块采用了分阶段处理的方式，将输入的特征图划分为多个阶段，每个阶段都包含一系列卷积操作。在每个阶段的末尾，跨阶段卷积块会将当前阶段的特征图与前一阶段的特征图进行融合，从而得到更丰富的特征表示。这种跨阶段的连接方式有助于模型捕获到不同尺度和层次的特征信息，提高了模型对目标的感知能力。

在另一些实施例中，跨阶段卷积块还可以采用部分连接的策略，即不是将所有阶段的特征图都进行融合，而是选择性地融合部分特征图。这种设计可以减少模型的计算量，同时保持较高的性能。

在示例性实施例中，所述深度学习瑕疵检测模型还包括特征金字塔模块，所述特征金字塔模块包括第一空间金字塔池化块、第二空间金字塔池化块和第三空间金字塔池化块。所述第一空间金字塔池化块连接所述第一跨阶段卷积块，用于接收多个所述第一丢弃特征图。所述第二空间金字塔池化块连接所述第二跨阶段卷积块，用于接收多个所述第二丢弃特征图，并分别对多个所述第二丢弃特征图进行处理，获得多个第二空间池化特征图。所述第三空间金字塔池化块连接所述第三跨阶段卷积块，用于接收多个所述第三丢弃特征图，并分别对多个所述第三丢弃特征图进行处理，获得多个第三空间池化特征图。所述第一空间金字塔池化块还连接所述第二空间金字塔池化块，用于接收多个所述第二空间池化特征图，根据多个所述第一丢弃特征图和多个所述第二空间池化特征图获得多个第一空间池化特征图。所述第二空间金字塔池化块还连接所述第三空间金字塔池化块，用于接收多个所述第三空间池化特征图，根据多个所述第二丢弃特征图和多个所述第三空间池化特征图获得多个第二空间池化特征图。

本公开实施例中，可以在骨干网络（例如特征提取模块 11）和检测头 12 之间增加特征金字塔模块，用于对骨干网络提取的特征进行进一步的处理和增强。在示例性实施例中，该特征金字塔模块可以包括 FPN（Feature Pyramid Networks，特征金字塔网络）和 PANet（Path Aggregation Network，路径聚合网络）等中的一种或多种，它们通过多尺度特征融合的方式，将不同层次的特征信息结合起来，提高模型的检测性能。在下面的实施例中，以特征金字塔模块包括空间金字塔池化块进行举例说明，但本公开并不限定与此。

空间金字塔池化块（Spatial Pyramid Pooling block，简称为 SSP block）采用了空间金字塔池化的技术。空间金字塔池化的思想源自金字塔形状的网络单元的应用，这些网络单元覆盖了不同大小的感受野。每个网络单元都会进行相同的池化操作，最终将所有不同尺寸的特征图连接在一起，形成一个固定长度的特征向量。具体来说，空间金字塔池化块对

5 输入的特征图进行尺度变化，并在每个尺度上进行池化操作。这种多尺度的池化方式使得网络能够处理任意大小的输入，并生成固定大小的输出。它通过将不同尺度的特征图拼接在一起，得到一个多尺度的特征表示，从而提高了模型的灵活性和适应性。由于空间金字塔池化块采用了这种多尺度池化的技术，使得它能够灵活处理不同大小的输入，并生成固定长度的特征表示，故称之为空间金字塔池化块。

10 在示例性实施例中，所述检测头包括第一深度可分离卷积块、第二深度可分离卷积块和第三深度可分离卷积块。所述瑕疵包括第一瑕疵、第二瑕疵和第三瑕疵；所述第一深度可分离卷积块与所述第一空间金字塔池化块连接，用于接收多个所述第一空间池化特征图，并分别对多个所述第一空间池化特征图进行处理，获得所述第一瑕疵的多个第一类别预测结果和多个第一位置预测结果。所述第二深度可分离卷积块与所述第二空间金字塔池

15 化块连接，用于接收多个所述第二空间池化特征图，并分别对多个所述第二空间池化特征图进行处理，获得所述第二瑕疵的多个第二类别预测结果和多个第二位置预测结果。所述第三深度可分离卷积块与所述第三空间金字塔池化块连接，用于接收多个所述第三空间池化特征图，并分别对多个所述第三空间池化特征图进行处理，获得所述第三瑕疵的多个第三类别预测结果和多个第三位置预测结果。

20 本公开实施例中的检测头可以包括两个或两个以上的深度可分离卷积块（例如包括第一至第三深度可分离卷积块），检测头中的深度可分离卷积块的数量与中间特征层中的跨阶段卷积块的数量对应，当模型还包括特征金字塔模块时，深度可分离卷积块的数量还与特征金字塔模块中的空间金字塔池化块的数量对应。在下面的实施例中，分别以检测头中包括 2 个或 3 个深度可分离卷积块举例说明，本公开并不限于此，例如还可以包括更多的

25 深度可分离卷积块，以提取更多尺度的瑕疵。

本公开实施例中，每个深度可分离卷积块将一个完整的卷积运算分解为两步进行，分别为 Depthwise Convolution（深度卷积）与 Pointwise Convolution（点卷积）。深度卷积步骤中，例如一个大小为 64×64 像素、三通道彩色的特征图（例如可以来自对应的跨阶段卷积块的输出或空间金字塔池化块的输出）首先经过第一次卷积运算，此次的卷积完全是在二维平面内进行，且过滤器（Filter）的数量与上一层的 Depth（深度，这里是指通道数

30

而非网络层级)相同。所以一个三通道的特征图经过运算后生成了3个特征图。其中一个Filter包含一个大小为 3×3 的Kernel(卷积核)。Depthwise Convolution完成后的Feature map数量与输入层的Depth相同。然后再通过Pointwise Convolution利用不同Feature map在相同空间位置上的信息,将这些Feature map进行组合生成新的Feature map。Pointwise Convolution的卷积核的尺寸为 $1 \times 1 \times M$,M为上一层的Depth。这里的卷积运算会将上一步的Feature map在深度方向上进行加权组合,生成新的Feature map。经过Pointwise Convolution之后,同样输出了4张Feature map,与常规卷积的输出维度相同。相同的输入,同样是得到4张Feature map,深度可分离卷积的参数个数是常规卷积的约1/3,运算量可缩小8-9倍。因此,在参数量相同的前提下,采用深度可分离卷积的神经网络层数可以做的更深。

本公开实施例中,检测头中的深度可分离卷积块的结构可参考中间特征层中的深度可分离卷积层(例如第一至第三深度可分离卷积层),检测深度可分离卷积块的卷积核大小可以与深度可分离卷积层不一样,卷积方式可以一样。例如,检测头中的卷积核大小可以分别为 1×1 和 3×3 。中间特征层中的深度可分离卷积层的卷积核大小可以分别为 1×1 , 3×3 , 5×5 , 7×7 。不同卷积核的作用是具有不同的特征感受野,深度可分离卷积可以有效减少卷积参数量从而加强处理速度。例如,对于正常卷积,例如 $128 \times 3 \times 3 \times 256(c1 \times w \times h \times c2)$ 128表示输入通道数,3x3表示卷积核大小,256表示输出通道数,参数量为294912。深度可分离卷积是先通过一个3x3的深度卷积对输入的每个通道进行卷积,参数量为 $128 \times 3 \times 3 = 1152$,再通过1x1点卷积对每个子区域进行卷积扩展通道,参数量为 $128 \times 1 \times 1 \times 256 = 32768$ 。总参数量为 $1152 + 32768 = 33920$ 。对比普通卷积参数量减少了88%。但是精度只有轻微损失。深度可分离卷积是可以完全替换普通卷积的,激活方式都是一样,连接方式也一样。

在另一些实施例中,检测头中也可以不采用深度可分离卷积块,即检测头可以包括采用正常卷积操作实现预测。

其中,根据所述瑕疵的多个类别预测结果和多个位置预测结果,获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性,包括:根据所述第一瑕疵的多个第一类别预测结果和多个第一位置预测结果,获得所述第一瑕疵的第一类别检测结果、第一位置检测结果、第一类别不确定性和第一位置不确定性;根据所述第二瑕疵的多个第二类别预测结果和多个第二位置预测结果,获得所述第二瑕疵的第二类别检测结果、第二位置检测结果、第二类别不确定性和第二位置不确定性;根据所述第

三瑕疵的多个第三类别预测结果和多个第三位置预测结果，获得所述第三瑕疵的第三类别检测结果、第三位置检测结果、第三类别不确定性和第三位置不确定性。

本公开实施例中，第一瑕疵、第二瑕疵以及第三瑕疵等是指待处理图像中不同尺度的瑕疵，而不是用于限定瑕疵的数量。

5 在示例性实施例中，所述第一中间层包括第一中间输入层、第一深度可分离卷积层和第一累加层。所述第一中间输入层用于接收所述第一卷积层输出的第一卷积特征图，并将所述
10 所述第一卷积特征图分别输入至所述第一深度可分离卷积层和所述第一累加层。所述第一深度可分离卷积层用于对所述第一卷积特征图进行深度可分离卷积处理，向所述第一累加层输入第一深度分离卷积特征图。所述第一累加层对所述第一卷积特征图和所述第一深度
15 分离卷积特征图进行累加处理，获得所述第一待融合特征图。

 在示例性实施例中，所述第一深度可分离卷积层包括第一深度分离输入层、第一深度卷积层、第一点卷积层和第一激活函数层。所述第一深度分离输入层用于接收所述第一中间
15 输入层输出的第一卷积特征图，并将所述第一卷积特征图分别输入至所述第一深度卷积层和所述第一激活函数层。所述第一深度卷积层用于对所述第一卷积特征图进行深度卷积
20 处理，并向所述第一点卷积层输入第一深度卷积特征图。所述第一点卷积层用于对所述第一深度卷积特征图进行点卷积处理，并向所述第一激活函数层输入第一点卷积特征图。所
25 述第一激活函数层用于对所述第一点卷积特征图和所述第一卷积特征图进行处理，获得所
30 述第一深度分离卷积特征图。

 在示例性实施例中，所述特征提取模块还包括与所述中间特征层连接的注意力块。所
20 述注意力块用于对所述待处理图像进行处理，获得所述待处理图像的下采样特征图，并将
25 所述下采样特征图输入至所述中间特征层。

 在示例性实施例中，所述深度学习瑕疵检测模型还包括背景移除模块。所述背景移除模块用于移除所述待处理图像中的背景信息，并将移除所述背景信息之后的所述待处理图像输入至所述特征提取模块。

25 本公开实施例中，可以通过背景移除从待处理图像中移除或分离出与待检测对象无关的部分，以便更准确地聚焦于待检测对象本身及其可能存在的瑕疵。这些背景可能包括工厂生产线、传送带、支撑结构、环境光照等因素，在图像处理和分析过程中，它们可能引入噪声、干扰边缘或影响颜色、纹理等特征的提取。通过去除背景，可以更加专注于待检测对象本身，从而更准确地识别和定位瑕疵。背景移除可以涉及到如背景建模、阈值分割、
30 形态学操作等，以从原始的待处理图像中分离出前景（即待检测对象）和背景。需要注意

的是，去除背景并不意味着完全消除背景在图像中的所有痕迹。相反，它的目的是减少背景对瑕疵检测过程的干扰，同时保留足够的上下文信息，以便能够准确判断待检测对象的状态和质量。

本公开实施例中，中间特征层可以包括 3 个或 3 个以上的跨阶段卷积块，检测头中的深度可分离卷积块的数量与中间特征层中的跨阶段卷积块的数量相同。当模型中包括特征金字塔模块时，特征金字塔模块中包括的空间金字塔池化块的数量与检测头中的深度可分离卷积块的数量相同。

下面结合图 3 至图 11 对本公开实施例提供的深度学习瑕疵检测模型进行举例说明，但本公开并不限于此。

图 3 是本公开另一示例性实施例的深度学习瑕疵检测模型的示意图。如图 3 所示，图 2 中的中间特征层 112 包括第一跨阶段卷积块、第二跨阶段卷积块和第三跨阶段卷积块。可选的，检测头 12 包括第一深度可分离卷积块、第二深度可分离卷积块和第三深度可分离卷积块。输入块 111 将接收到的待处理图像输入第一跨阶段卷积块，第一跨阶段卷积块对该第一待处理图像进行处理后，获得该待处理图像的多个第一丢弃特征图，并将多个第一丢弃特征图分别输入至第一深度可分离卷积块进行处理。第一深度可分离卷积块分别对多个第一丢弃特征图进行处理，基于每个第一丢弃特征图预测出该待处理图像中的第一瑕疵的多个第一类别预测结果和多个第一位置预测结果。

需要说明的是，本公开实施例中 backbone 的网络结构并不限于所列举的跨阶段卷积块，例如还可以替换为 RepVGG、EfficientNet、ConvNeXt 等中的至少一种。

图 3 实施例中，第一跨阶段卷积块还将多个第一丢弃特征图分别输入至第二跨阶段卷积块。该第二跨阶段卷积块对每个第一丢弃特征图分别进行处理，输出多个第二丢弃特征图。

第二跨阶段卷积块将每个第二丢弃特征图分别输入至第二深度可分离卷积块。第二深度可分离卷积块接收多个第二丢弃特征图，分别对每个第二丢弃特征图进行处理，预测出该待处理图像中的第二瑕疵的多个第二类别预测结果和多个第二位置预测结果。

第二跨阶段卷积块还将多个第二丢弃特征图分别输入至第三跨阶段卷积块。该第三跨阶段卷积块对每个第二丢弃特征图分别进行处理，输出多个第三丢弃特征图。

第三跨阶段卷积块将每个第三丢弃特征图分别输入至第三深度可分离卷积块。第三深度可分离卷积块接收多个第三丢弃特征图，分别对每个第三丢弃特征图进行处理，预测出该待处理图像中的第三瑕疵的多个第三类别预测结果和多个第三位置预测结果。

继续参考图 3，检测头 12 还用于根据每个深度可分离卷积块预测的多个类别预测结果和多个位置预测结果进行贝叶斯预测/分析，以获得每个瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

例如，针对第一深度可分离卷积块预测输出的第一瑕疵的多个第一类别预测结果和多个第一位置预测结果进行贝叶斯预测处理（例如求均值和方差），获得第一瑕疵的第一类别检测结果、第一位置检测结果、第一类别不确定性和第一位置不确定性。

再例如，针对第二深度可分离卷积块预测输出的第二瑕疵的多个第二类别预测结果和多个第二位置预测结果进行贝叶斯预测处理，获得第二瑕疵的第二类别检测结果、第二位置检测结果、第二类别不确定性和第二位置不确定性。

再例如，针对第三深度可分离卷积块预测输出的第三瑕疵的多个第三类别预测结果和多个第三位置预测结果进行贝叶斯预测处理，获得第三瑕疵的第三类别检测结果、第三位置检测结果、第三类别不确定性和第三位置不确定性。

本公开实施例中，获得的待处理图像中的瑕疵的多个类别预测结果包括第一瑕疵的多个第一类别预测结果、第二瑕疵的多个第二类别预测结果和第三瑕疵的多个第三类别预测结果。获得的待处理图像中的瑕疵的多个位置预测结果包括第一瑕疵的多个第一位置预测结果、第二瑕疵的多个第二位置预测结果和第三瑕疵的多个第三位置预测结果。获得的待处理图像中的瑕疵的类别检测结果包括第一瑕疵的第一类别检测结果、第二瑕疵的第二类别检测结果和第三次的第三类别检测结果。获得的待处理图像中的瑕疵的位置检测结果包括第一瑕疵的第一位置检测结果、第二瑕疵的第二位置检测结果和第三瑕疵的第三位置检测结果。获得的待处理图像中的瑕疵的类别不确定性包括第一瑕疵的第一类别不确定性、第二瑕疵的第二类别不确定性和第三瑕疵的第三类别不确定性。获得的待处理图像中的瑕疵的位置不确定性包括第一瑕疵的第一位置不确定性、第二瑕疵的第二位置不确定性和第三瑕疵的第三位置不确定性。

图 3 中，以待处理图像为通过拍摄处于生产流水线上的口罩布图像为例，该类别检测结果即分类结果可以是胶纸/贴纸、污渍、印刷错误、折痕（口罩织物褶皱）等中的任何一种。可以理解的是，这四种分类结果（例如 $C=4$ ）仅用于举例说明，并不限定一次，可以根据实际场景进行设置。位置检测结果即该瑕疵在该待处理图像中的定位/位置信息。

如图 4 所示，丢弃层 1121 包括第一丢弃层和第二丢弃层。第一丢弃层位于第一跨阶段卷积块中，第二丢弃层位于第二跨阶段卷积块中。

第一跨阶段卷积块中的第一跨阶段输入层的输入端连接图 3 实施例中的输入块 111 的

输出端。第一跨阶段输入层的输出端分别连接第一卷积层和第二卷积层的输入端。第一卷积层的输出端连接第一中间层的输入端。第一中间层的输出端连接第一融合层的第一输入端。第二卷积层的输出端连接第一融合层的第二输入端。第一融合层的输出端连接第三卷积层的输入端。第三卷积层的输入端连接第一丢弃层的输入端。第一丢弃层的输出端分别

5 连接第二跨阶段卷积块中的第二跨阶段输入层的输入端和第一深度可分离卷积块的输入端。

第二跨阶段卷积块中的第二跨阶段输入层的输出端分别连接第四卷积层和第五卷积层的输入端。第四卷积层的输出端连接第二中间层的输入端。第二中间层的输出端连接第二融合层的第一输入端。第五卷积层的输出端连接第二融合层的第二输入端。第二融合层的

10 输出端连接第六卷积层的输入端。第六卷积层的输入端连接第二丢弃层的输入端。第二丢弃层的输出端连接第二深度可分离卷积块的输入端。

图 4 实施例中，第一卷积层、第二卷积层、第三卷积层、第四卷积层、第五卷积层和第六卷积层的卷积核大小可以均为 1×1 。

如图 5 所示，第一中间层中包括第一深度可分离卷积层，第二中间层中包括第二深度

15 可分离卷积层。

第一中间层的第一中间输入层的输入端连接图 4 实施例中的第一卷积层的输出端。第一中间输入层的输出端分别连接第一深度可分离卷积层的输入端和第一累加层的输入端。第一累加层的输出端连接图 4 实施例中的第一融合层的输入端。

第二中间层的第二中间输入层的输入端连接图 4 实施例中的第四卷积层的输出端。第二中间输入层的输出端分别连接第二深度可分离卷积层的输入端和第二累加层的输入端。第二累加层的输出端连接图 4 实施例中的第二融合层的输入端。

20

如图 6 所示，第一深度可分离卷积层包括第一深度分离输入层、第一深度卷积层、第一点卷积层和第一激活函数层。第二深度可分离卷积层包括第二深度分离输入层、第二深度卷积层、第二点卷积层和第二激活函数层。

第一深度分离输入层的输入端连接图 5 实施例中的第一中间输入层的输出端。第一深度分离输入层的输出端分别连接第一深度卷积层的输入端和第一激活函数层的输入端。第一深度卷积层的输出端连接第一点卷积层的输入端。第一点卷积层的输出端连接第一激活函数层。

25

第二深度分离输入层的输入端连接图 5 实施例中的第二中间输入层的输出端。第二深度分离输入层的输出端分别连接第二深度卷积层的输入端和第二激活函数层的输入端。第

30

二深度卷积层的输出端连接第二点卷积层的输入端。第二点卷积层的输出端连接第二激活函数层。

图 7 实施例中，丢弃层还包括第三丢弃层。如图 7 所示，第三跨阶段卷积块包括第三跨阶段输入层、第七卷积层、第三中间层、第八卷积层、第三融合层、第九卷积层和所述第三丢弃层。第三跨阶段输入层的输入端连接第二跨阶段卷积块的输出端，例如连接第二丢弃层的输出端，将第二丢弃层输出的多个第二丢弃特征图分别作为第三跨阶段输入特征图。

所述第七卷积层用于将所述第三跨阶段输入层输入的第三跨阶段输入特征图进行卷积处理，向所述第三中间层输入第五卷积特征图。所述第三中间层用于对所述第五卷积特征图进行处理，向所述第三融合层输入第五待融合特征图。所述第八卷积层用于对所述第三跨阶段输入特征图进行卷积处理，向所述第三融合层输入第六待融合特征图。所述第三融合层用于对所述第五待融合特征图和所述第六待融合特征图进行融合处理，向所述第九卷积层输入第三融合特征图。所述第九卷积层用于对所述第三融合特征图进行卷积处理，向所述第三丢弃层输入第六卷积特征图。所述第三丢弃层用于对所述第六卷积特征图中的特征进行随机丢弃，获得多个第三丢弃特征图，所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征包括多个所述第三丢弃特征图。

继续参考图 7，第三中间层包括第三中间输入层、第三深度可分离卷积层和第三累加层。所述第三中间输入层用于接收所述第七卷积层输出的第五卷积特征图，并将所述第五卷积特征图分别输入至所述第三深度可分离卷积层和所述第三累加层。所述第三深度可分离卷积层用于对所述第五卷积特征图进行深度可分离卷积处理，向所述第三累加层输入第三深度分离卷积特征图。所述第三累加层对所述第五卷积特征图和所述第三深度分离卷积特征图进行累加处理，获得所述第五待融合特征图。

继续参考图 7，所述第三深度可分离卷积层包括第三深度分离输入层、第三深度卷积层、第三点卷积层和第三激活函数层。所述第三深度分离输入层用于接收所述第三中间输入层输出的第五卷积特征图，并将所述第五卷积特征图分别输入至所述第三深度卷积层和所述第三激活函数层。所述第三深度卷积层用于对所述第五卷积特征图进行深度卷积处理，并向所述第三点卷积层输入第三深度卷积特征图。所述第三点卷积层用于对所述第三深度卷积特征图进行点卷积处理，并向所述第三激活函数层输入第三点卷积特征图。所述第三激活函数层用于对所述第三点卷积特征图和所述第五卷积特征图进行处理，获得所述第三深度分离卷积特征图。

本公开实施例中，激活函数层（例如包括第一至第三激活函数层）使用的激活函数可以是任意适当的激活函数。在下面的实施例中，以采用 SiLU（Swish 激活函数）进行举例说明，但本公开并不限于此。SiLU 函数在整个定义域内都是可微的，因此在反向传播过程中的梯度计算更加稳定。SiLU 函数在深层模型上，具有无上界有下界、平滑、非单调的特性，且梯度更大、更稳定。

图 7 实施例中，第七卷积层、第八卷积层和第九卷积层的卷积核大小可以均为 1×1 。

本公开实施例的跨阶段卷积块中引入了深度可分离卷积层，该深度可分离卷积层通过将空间维度和通道（深度）维度的相关性进行拆分，减少了卷积计算所需的参数数量，并提升了卷积核参数的使用效率。深度可分离卷积层的卷积计算过程分为两部分：深度卷积，对每个通道分别进行空间卷积，即对每个输入通道使用单一的卷积核进行卷积操作，然后将这些输出进行拼接；点卷积（Pointwise Convolution），使用单位卷积核（即 1×1 的卷积核）进行通道卷积，以整合各个通道的信息，并得到最终的特征图。深度可分离卷积的优势在于它减少了计算复杂度和模型参数数量，同时保持了模型的表达能力。深度可分离卷积是一种轻量级的卷积方法，通过减少参数和计算量，提高了模型的效率和性能。

图 8 实施例与图 3 实施例的区别在于，特征提取模块 11 还可以包括第四跨阶段卷积块，检测头 12 还可以包括第四深度可分离卷积块。第四跨阶段卷积块的结构可参考上述图 4 至图 7。第四跨阶段卷积块与第三跨阶段卷积块和检测头 12 中的第四深度可分离卷积块连接，用于分别接收多个第三丢弃特征图，并对多个第三丢弃特征图进行处理以生成多个第四丢弃特征图。第四跨阶段卷积块可以包括第四丢弃层，以输出多个第四丢弃特征图至第四深度可分离卷积块。第四深度可分离卷积块可以预测输出第四瑕疵的多个第四类别预测结果和多个第四位置预测结果。检测头 12 可以根据多个第四类别预测结果获得第四瑕疵的第四类别检测结果和第四类别不确定性，根据多个第四位置预测结果获得第四瑕疵的第四位置检测结果和第四位置不确定性。

图 9 实施例与图 3 实施例的区别之一在于，深度学习瑕疵检测模型 1 还包括位于特征提取模块 11 和检测头 12 之间的特征金字塔模块 13。

图 9 实施例通过在特征提取模块 11 和检测头 12 之间引入特征金字塔模块 13，以解决瑕疵检测中的多尺度问题。不同大小的瑕疵在图像中呈现出不同的特征，而特征金字塔可以在不同尺度下提取和融合这些特征。通过网络连接改变，特征金字塔在基本不增加原有模型计算量的情况下，大幅度提升了小瑕疵检测的性能。具体的，特征金字塔通过上采样和下采样操作，将不同尺寸的特征层进行融合。这样，模型可以同时获取到高层次的语

义信息和低层次的细节信息，从而提取出更好的特征。这种融合后的特征不仅有助于提升模型的检测性能，还可以使模型更好地适应不同大小的瑕疵检测任务。首先，特征提取模块 11 中的中间特征层会生成不同尺度的特征图。这些特征图在金字塔结构中，从底层到高层，分别包含了越来越抽象的信息，对应着不同大小的瑕疵。底层特征图通常具有更高的分辨率和更多的细节信息，适合用于检测小瑕疵；而高层特征图则具有更低的分辨率和更抽象的语义信息，适合用于检测大瑕疵。接下来，特征金字塔通过一系列的上采样和下采样操作，将这些不同尺度的特征图进行融合。具体来说，较低层的特征图会经过上采样操作，使其分辨率与较高层的特征图相匹配，然后通过拼接或相加的方式与较高层的特征图进行融合。这样，融合后的特征图既包含了低层的细节信息，又包含了高层的语义信息，有助于提升模型对不同大小瑕疵的检测性能。通过连接不同尺度的特征图，可以生成多个不同尺度的预测结果。这些预测结果分别对应着不同大小的瑕疵，从而实现了多尺度瑕疵检测。这种机制使得模型能够同时关注到图像中的全局信息和局部细节，从而提高了瑕疵检测的准确性和鲁棒性。

例如，如图 9 所示，特征金字塔模块 13 包括第一空间金字塔池化块、第二空间金字塔池化块和第三空间金字塔池化块。本公开实施例中，跨阶段卷积块可以设置实现特征图的降采样。图 9 实施例中，实现 3 个不同尺度的特征图输入到特征金字塔模块 13，作为 YOLO 多尺度检测头 12 的输入。因为跨阶段卷积块可以通过定义参数来使能降采样的功能，所以可以使用 3 个以上跨阶段卷积，实现 3 个不同尺度的特征图输入给特征金字塔模块 13。

第一空间金字塔池化块的第一输入端与第一跨阶段卷积块的输出端连接，例如与第一丢弃层的输出端连接，以接收第一丢弃层输出的多个第一丢弃特征图。第一空间金字塔池化块的第二输入端与第二空间金字塔池化块的输出端连接，以接收第二空间金字塔池化块输出的多个第二空间池化特征图。第一空间金字塔池化块分别对多个第一丢弃特征图中的每一个第一丢弃特征图与多个第二空间池化特征图中对应的一个第二空间池化特征图进行处理，通过其输出端向检测头 12 中的第一深度可分离卷积块输出多个第一空间池化特征图。检测头 12 中的第一深度可分离卷积块分别对每个第一空间池化特征图进行处理，预测出第一瑕疵的多个第一类别预测结果和多个第一位置预测结果。检测头 12 对第一瑕疵的多个第一类别预测结果和多个第一位置预测结果进行贝叶斯预测，获得第一瑕疵的第一类别检测结果、第一位置检测结果、第一类别不确定性和第一位置不确定性。

第二空间金字塔池化块的第一输入端与第二跨阶段卷积块的输出端连接，例如与第二

丢弃层的输出端连接，以接收第二丢弃层输出的多个第二丢弃特征图。第二空间金字塔池化块的第二输入端与第三空间金字塔池化块的输出端连接，以接收第三空间金字塔池化块输出的多个第三空间池化特征图。第二空间金字塔池化块分别对多个第二丢弃特征图中的每一个第二丢弃特征图与多个第三空间池化特征图中对应的一个第三空间池化特征图进行
5 行处理，通过其输出端向检测头 12 中的第二深度可分离卷积块输出多个第二空间池化特征图。检测头 12 中的第二深度可分离卷积块分别对每个第二空间池化特征图进行处理，预测出第二瑕疵的多个第二类别预测结果和多个第二位置预测结果。检测头 12 对第二瑕疵的多个第二类别预测结果和多个第二位置预测结果进行贝叶斯预测，获得第二瑕疵的第二类别检测结果、第二位置检测结果、第二类别不确定性和第二位置不确定性。

10 第三空间金字塔池化块的输入端与第三跨阶段卷积块的输出端连接，例如与第三丢弃层的输出端连接，以接收第三丢弃层输出的多个第三丢弃特征图。第三空间金字塔池化块分别对多个第三丢弃特征图中的每一个第三丢弃特征图进行处理，通过其输出端向检测头 12 中的第三深度可分离卷积块输出多个第三空间池化特征图。检测头 12 中的第三深度可分离卷积块分别对每个第三空间池化特征图进行处理，预测出第三瑕疵的多个第三类别预
15 测结果和多个第三位置预测结果。检测头 12 对第三瑕疵的多个第三类别预测结果和多个第三位置预测结果进行贝叶斯预测，获得第三瑕疵的第三类别检测结果、第三位置检测结果、第三类别不确定性和第三位置不确定性。图 9 实施例中，待处理图像中的瑕疵还包括第三瑕疵，获得的待处理图像中的瑕疵的多个类别预测结果还包括第三瑕疵的第三类别预测结果，多个位置预测结果还包括第三瑕疵的第三位置预测结果。获得的待处理图像中的
20 瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性分别还包括第三瑕疵的第三类别检测结果、第三位置检测结果、第三类别不确定性和第三位置不确定性。

本公开实施例中，特征金字塔模块 13 可以在原本 3 个尺度的特征图下，融合不同大小感受野的卷积特征，实现多尺度特征融合，增强特征的鲁棒性。

图 9 实施例与图 3 实施例的区别之二在于，深度学习瑕疵检测模型 1 还可以包括位于
25 特征提取模块 11 之前的背景移除模块。背景移除模块用于移除待处理图像中的背景信息，并将移除背景信息之后的待处理图像输入至特征提取模块 11。这里以未移除背景信息的待处理图像为口罩布图像进行举例说明，将移除背景信息的口罩布图像称之为待处理图像。

图 10 是本公开一示例性实施例的空间金字塔池化块的示意图。如图 10 所示，特征金字塔模块 13 中的每一个空间金字塔池化块(例如图 9 中的第一至第三空间金字塔池化块)
30 可以具有相同的结构。空间金字塔池化块可以包括输入层、与输入层连接的第一个卷积层、

与第一个卷积层连接的三个并列的最大池化层、分别与三个最大池化层连接的融合层、以及
与融合层连接的第二个卷积层。

空间金字塔池化块中的各个最大池化层可以用于降低特征图的参数量，提升计算速度，
增加感受野，是一种降采样操作。通过池化，模型可以更关注全局特征而非局部出现的位置，
这种降维的过程可以保留一些重要的特征信息，提升容错能力，并且还能一定程度上起到防止过拟合的作用。

图 10 实施例中，第一个卷积层和第二个卷积层的卷积核大小可以均为 1×1 。

继续参考图 10，三个并联的最大池化层的卷积核大小可以分别为 3×3 ， 5×5 ， 7×7 。

需要说明的是，本公开实施例中的特征金字塔模块不限于采用图 9 和图 10 中例
举的空间金字塔池化块，可以有其他结构可以替代。图 10 实施例中，对于同一个特征图，
使用了不同大小的卷积核并行处理，然后获得直接融合处理后的特征图。其他的结构例如
如图 11 所示，可以改为不同大小卷积核串行处理输入值特征金字塔模块的特征图，例如
采用三个卷积核大小分别为 3×3 ， 5×5 ， 7×7 的卷积层串行，然后用 shortcut（直连或捷
径）方式，跳接不同卷积核输出的特征图实现融合。

图 9 实施例与图 3 实施例的区别之三在于，输入块 111 可以是注意力块 111'。注意力块
111' 是待处理图像（ $b1, c1, w1, h1$ 分别表示待处理图像的批次大小、通道数、宽度、高度）
进入特征提取模块 11 前，对待处理图像进行切片操作，具体操作是在一张待处理图像中
每隔一个像素拿到一个值，类似邻近下采样，这样就拿到了四张图像，四张图像互补，
没有信息丢失，这样将 $w1/h1$ 信息就集中到了通道空间，输入通道扩充了 4 倍（获得了
 $(b1, 4 * c1, w1, h1)$ 的输入），即拼接起来的图像相对于原先的 c 个通道变成了 $4 * c1$ 个
通道，最后将得到的新图像再经过卷积操作（例如卷积核大小为 1×1 ），最终得到了没有
信息丢失情况下的二倍下采样特征图，输入至第一跨阶段卷积块。经过这样的处理，注意
力块 111' 得到了没有信息丢失情况下的二倍下采样特征图，可以减少参数量、网络层数、
梯度和计算次数，同时提高模型的精度和召回率，这使得模型在保持高效的同时，能够更
准确地检测和识别图像中的瑕疵，尤其是那些尺寸较小、特征不明显的瑕疵。

图 12 实施例中使用了空间注意力机制来设计注意力块。可以理解的是，本公开实施
例中的注意力块不限于采用图 12 所示的结构，还可以通过 Squeeze-Excitation（压缩-激励，
显式的建模特征通道之间的相互依赖关系，通过学习的方式获取每个通道的重要程度，然
后依照这个重要程度来对各个通道上的特征进行加权，突出重要特征，抑制不重要的特征）
操作来实现通道注意力块。此外还可以通过动态卷积实现空间注意力块。

可以理解的是，本公开实施例提供的模型并不限于上述例举的结构。本公开实施例提
供的在中间特征层中加入丢弃层，在模型的训练过程中增加贝叶斯损失函数（例如下述第
二损失函数），本公开实施例提供的方法可以适应各种网络结构，在保持与各种网络架构

兼容的同时实现不确定性估计的集成，在应用中提供灵活性，并进一步提高性能。

本公开实施例中，通过卷积层的使用，可以使模型能够适应不同的图像分辨率和瑕疵/缺陷检测场景。卷积操作允许网络关注图像中的局部特征，而不是整个图像。由于卷积层的这种性质，模型能够处理不同尺寸的输入图像，而不必对模型结构进行大的修改。这使得模型具有很高的灵活性，可以适应各种图像分辨率。在缺陷检测领域，这意味着无论输入的图像是高清还是低分辨率，或者图像中缺陷的大小和位置如何变化，使用卷积层的模型都能够有效地进行缺陷检测。因此，这种模型可以轻松地适应不同的缺陷检测场景，提高了模型的通用性和实用性。

在示例性实施例中，本公开实施例提供的方法还包括：获得目标训练数据集，所述目标训练数据集中包括目标样本图像及所述目标样本图像中的目标样本瑕疵的标注类别和标注位置；将所述目标样本图像输入至所述深度学习瑕疵检测模型，获得所述目标样本瑕疵的多个类别预测结果和多个位置预测结果；根据所述目标样本瑕疵的多个类别预测结果和多个位置预测结果获得所述目标样本瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性；根据所述目标样本瑕疵的标注类别及类别检测结果、标注位置及位置检测结果、以及类别不确定性和位置不确定性构建损失函数以训练所述深度学习瑕疵检测模型。

本公开实施例中，可以获得用于瑕疵检测的数据集，按照预定比例例如按 9:1 的比例划分为目标训练数据集和目标测试数据集。在模型训练时，前向传播的过程中进行 dropout 操作，在 dropout 的作用下通过随机关闭神经元能够得到多个不同网络结构，从而对同一个目标样本图像进行多次预测，获得多个类别预测结果和多个位置预测结果。计算多个类别预测结果的均值和多个位置预测结果的均值分别表示目标样本瑕疵的类别检测结果和位置检测结果，计算多个类别预测结果的均值和多个位置预测结果的方差分别表示目标样本瑕疵的类别不确定性和位置不确定性。

例如，可以设置模型的训练参数：批量大小(batch size)设置为 64，迭代次数(epoch)设置为 100，初始学习速率设置为 0.001，衰减系数设置为 0.005，dropout 概率为 0.3。经过 dropout 后每层的神经元数量变为原来的大约一半。

在示例性实施例中，所述损失函数包括第一损失函数和第二损失函数；当所述目标样本瑕疵的标注类别和类别检测结果的差异越大，标注位置和位置检测结果的差异越大时，所述第一损失函数的取值越大；当所述目标样本瑕疵的类别不确定性和所述位置不确定性越大时，所述第二损失函数的取值越大。

本公开实施例引入贝叶斯方法，在模型中新增 dropout 创造随机不确定性来实现贝叶斯后验分布。同时优化模型的检测头，新增锚框（即位置预测结果）和类别（即类别预测结果）的均值和方差来表示其分布情况，例如，该第二损失函数可以为负对数似然损失函数，以优化不确定性估计，不仅推动模型向准确预测进化，也鼓励模型对其预测的不确定性进行准确估计，从而提高了模型的检测精度和鲁棒性。

例如，第一损失函数 L_1 如下：

$$L_1 = \sum_{i=1}^N \text{MSE}(y_i, y_i^{\text{pre}}) + \sum_{c=1}^C \text{CE}(s_c, s_c^{\text{pre}}) + \text{BCE}(o, o^{\text{pre}}) \quad (3)$$

MSE是表示边界框回归计算， y_i 是真实数据中第 i 个边界框坐标（即第 i 个目标样本瑕疵的标注位置）， y_i^{pre} 是模型预测的第 i 个边界框坐标（即第 i 个目标样本瑕疵的位置检测结果）， N 是边界框的数量（即目标样本候选瑕疵的数量）， N 为大于或等于1的正整数， i 为大于或等于1且小于或等于 N 的正整数。 CE 是表示多元交叉熵计算， s_c^{pre} 表示预测的类别检测结果中类别 c 的类别置信度（即属于类别 c 的概率）。 s_c 是真实数据中类别 c 的置信度（即标注类别中类别 c 的类别置信度）。 C 表示类别数量， C 为大于或等于1的正整数， c 为大于或等于1且小于或等于 C 的正整数。 BCE 是表示二元交叉熵计算， o^{pre} 表示预测的目标置信度， o 表示真实数据中目标的置信度，即目标样本瑕疵中标注的目标的置信度。

再例如，第二损失函数 L_2 如下：

$$L_2 = \sum_{i=1}^N \left(\frac{1}{2\sigma_i^2} (y_i - \mu_i)^2 + \frac{1}{2} \log \sigma_i^2 \right) + \sum_{c=1}^C \left[\frac{1}{2\sigma_c^2} (s_c - \mu_c)^2 + \frac{1}{2} \log \sigma_c^2 \right] \quad (4)$$

μ_i 是预测的第 i 个目标样本瑕疵的位置检测结果，例如是模型预测的第 i 个边界框坐标的均值。 y_i 是第 i 个目标样本瑕疵的标注位置，例如是真实数据中第 i 个边界框坐标。 σ_i^2 是预测的第 i 个目标样本瑕疵的位置不确定性，例如是模型预测的第 i 个边界框坐标的方差。 N 是目标样本瑕疵的数量， N 为大于或等于1的正整数， i 为大于或等于1且小于或等于 N 的正整数。 μ_c 表示预测的类别 c 的类别置信度均值，即类别检测结果。 s_c 是真实数据中类别 c 的类别置信度。 σ_c^2 是预测的类别 c 的类别置信度方差，即类别不确定性。 C 表示类别数量， C 为大于或等于1的正整数， c 为大于或等于1且小于或等于 C 的正整数。

在示例性实施例中，获得目标训练数据集，包括：获取初始样本图像及所述初始样本图像中的初始样本瑕疵的标注类别和标注位置；对所述初始样本图像进行随机裁剪、旋转、缩放、光照变化模拟、瑕疵合成中的任意一项或多项处理，生成扩增样本图像及所述扩展增益图像中的扩展样本瑕疵的标注类别和标注位置。其中，所述目标样本图像包括所述初始样本图像和所述扩增样本图像。

在示例性实施例中，对所述初始样本图像进行瑕疵合成处理，生成扩增样本图像，包括：提取所述初始样本图像中的初始样本瑕疵；将所述初始样本瑕疵与扩增背景图像合成，生成所述扩增样本图像；和/或，通过深度学习生成模型学习所述初始样本图像，生成所述扩增样本图像。

数据集质量会影响模型的准确性和鲁棒性。例如还是以检测口罩布图像中的瑕疵

为例，为了训练一个高效准确的模型，需要大量高质量的具有瑕疵的口罩布图像以形成数据集。如果数据集中的图像质量低或样本量不足，模型的准确性和鲁棒性可能会受到影响。

实际情况中，存在瑕疵的口罩布图像数量比不存在瑕疵的口罩布图像的数量要少，即训练数据集中的正负样本数量不平衡。本公开通过实施一种多阶段数据增强策略解决数据集质量问题。首先，采集大量原始的口罩布图像，并通过专家标注生成初始训练数据（包括初始样本图像）。接着，利用图像处理技术如随机裁剪、旋转、缩放和光照变化模拟，以及合成瑕疵生成方法等中的一种或多种扩充数据集，以获得扩增样本图像。

本公开实施例中，可以通过采用随机裁剪、旋转、缩放、光照变化模拟（例如亮度调整）、瑕疵合成、添加高斯噪声、随机遮挡等中的任意一项或多项的数据增强方式来增加存在瑕疵的口罩布图像。光照变化模拟是随机调整原始的存在瑕疵的口罩布图像的饱和度、亮度、对比度等中的一种或者多种，可以模拟拍摄图像容易受到光照和天气变化的影响；随机遮挡是将存在瑕疵的口罩布图像的随机区域用黑色遮挡，可以模拟在拍摄时容易被其它物品遮挡的情况；高斯噪声是在原始的存在瑕疵的口罩布图像中添加概率密度函数服从高斯分布的噪声，可以更好地模拟未知的真实噪声。

相关技术中的模型难以在检测速度和准确性之间达到较好的平衡。这可能导致在实际应用中对小微瑕疵点的检测性能不令人满意，因为小微瑕疵点需要处理高分辨率图像，从而加剧算力负担，降低检测速度。本公开实施例通过数据增强将多张初始样本图像随机缩放裁剪进行拼接，大量增加了训练数据集中的小微瑕疵点，提高了小微瑕疵点检测的效果。

本公开实施例还可以通过引入了 AIGC（stable diffusion）根据真实的瑕疵样本生成新的瑕疵样本，增加数据多样性。可以采用如下两种合成瑕疵方法中的任意一种或者两种：第一种是将瑕疵前景提取出来，替换其他布料的背景。第二种是通过 stable diffusion 学习真瑕疵图像，然后生成假的瑕疵图像。将 AIGC 引入瑕疵样本生成领域，可以根据真实的瑕疵样本生成新的瑕疵样本，可以丰富数据集，帮助训练更准确的模型。生成的瑕疵样本可以用于模拟各种可能的瑕疵情况，从而在实际应用中更全面地测试瑕疵检测系统的性能。

在示例性实施例中，获得目标训练数据集，包括：获取候选样本图像及所述候选样本图像中的候选样本瑕疵的标注类别和标注位置；通过所述特征提取模块获得所述候选样本图像的输出特征；基于各个候选样本图像的输出特征，获得各个候选样本图像之间的特征距离；选择标注类别相同的候选样本图像中特征距离大于第一距离阈值的候选样本图像，和/或，标注类别不同的候选样本图像中特征距离小于第二距离阈值的候选样本图像，作为所述目标训练数据集中的目标样本图像。

本公开实施例中可以使用欧几里得距离来作为特征距离，但本公开并不限于此。

本公开实施例还可以应用一种自适应的样本选择机制，优先选择那些对模型性能提升最有效的样本进行训练。例如，在训练过程中，提取多个样本的骨干网络输出的特征，以捕捉到不同样本之间的相似性和差异性。然后计算各个样本的特征距离。

例如，可以通过如下公式计算第 i 个样本 (x_i) 和第 j 个样本 (x_j) 之间的特征距离 d_{ij} ：

$$d_{ij} = \sqrt{\sum_{k=1}^D (F_k(x_i) - F_k(x_j))^2} \quad (5)$$

$F_k(x_i)$ 是样本 x_i 在第 k 维的特征值， $F_k(x_j)$ 是样本 x_j 在第 k 维的特征值， D 是样本的特征的维度， D 为大于或等于 1 的正整数， k 为大于或等于 1 且小于或等于 D 的正整数。 i 和 j 均为大于或等于 1 的正整数，且 i 不等于 j 。

计算样本的特征距离有助于理解样本在特征空间中的分布。例如，可以选择同类型样本（同种类型瑕疵对应的图像，就是 label（标签）相同的不同样本，例如均被标注为“胶纸”的样本）中距离最远的，不同类型样本（不同种类型瑕疵对应的图像，例如一个样本被标注为“污渍”，另一个样本被标注为“折痕”）中距离最近的样本参与反向传播，相当于使用最容易出错（最难判断）的样本来优化模型的权重，以提高模型的准确性和鲁棒性。

本公开实施例中，自适应的样本选择机制的样本选择标准是先统计特征距离，然后根据特征距离的统计值划分第一距离阈值和第二距离阈值，例如选择第一距离阈值（也称类内距离）大于 0.3，第二距离阈值（也称类间距离）小于 0.2。自适应的样本选择机制这个训练策略是在常规训练后新增的，用于解决 hard sample（困难样本）问题进行的二次训练。经过二次训练后，令类内样本特征分布更加集中，类间样本特征分布更加离散，从而增强分类准确性。

基于特征距离的计算结果，选择同类型样本中距离最远的样本，意味着这些样本在特征空间中的差异最大，即使它们属于同一类别，模型也很难将它们正确区分。通过让模型学习这些难以区分的样本，可以促使模型更加关注类别内部的细节差异，从而提高模型的准确性。同时，选择不同类型样本中距离最近的样本，意味着这些样本在特征空间中的相似度较高，但实际上它们属于不同的类别。这些样本是模型最容易出错的样本，因为它们具有相似的特征但标签不同。通过让模型学习这些样本，可以强化模型对不同类别之间的区分能力，从而提高模型的鲁棒性。使用这种策略进行反向传播，相当于使用最容易出错（最难判断）的样本来优化模型的权重。这样，模型在训练过程中会更加关注这些具有挑战性的样本，从而提高其在面对复杂和多变的环境时的泛化能力和鲁棒性。

在示例性实施例中，在所述深度学习瑕疵检测模型的训练过程中：提取所述深度学习瑕疵检测模型中的每个卷积层的权重张量；获得所述权重张量中每个通道的欧几里得范数；对每个卷积层根据其通道的欧几里得范数进行排序，根据剪枝阈值或剪枝比例，对相应的通道进行剪枝。

通道剪枝是一种有效的模型压缩和加速技术，特别适用于轻量化模型设计的需求。在模型中进行通道剪枝，可以显著减少模型的参数数量和计算复杂度，同时保持模型的性能。

本公开实施例，基于 L2-norm（欧几里得范数）度量卷积通道对网络输出的贡献，并根据贡献程度进行通道剪枝。首先，基于 L2-norm 度量卷积通道的贡献：L2-norm（欧几里得范数）可以用来评估卷积通道的重要性或贡献程度。对于模型中的每个卷积层，可以计算每个卷积通道权重的 L2-norm 值。这个值反映了该通道在网络中的影响力和贡献。具体的，对于模型中的每个卷积层，提取其权重张量（weight tensor）。计算权重张量中每个通道的 L2-norm 值。例如对权重张量进行平方、求和和开方等操作。将计算得到的 L2-norm 值保存下来，用于后续的通道剪枝决策。然后，根据贡献程度进行通道剪枝：根据上一步计算得到的 L2-norm 值，可以评估每个卷积通道的重要性，并根据一定的策略进行通道剪枝。通道剪枝的目标是移除那些对网络输出贡献较小的通道，从而减少模型的参数数量和计算复杂度。具体的，设定一个剪枝阈值或剪枝比例。剪枝阈值或剪枝比例可以根据具体需求和实验来确定。对于每个卷积层，根据其通道的 L2-norm 值进行排序。根据设定的剪枝阈值或剪枝比例，选择贡献较小的通道进行剪枝。例如，将对应通道的权重设置为零或直接从模型中移除这些通道。在剪枝后，对模型进行重新训练和微调，以恢复或保持其性能。欧几里得范数反映了该通道对输出的响应权重，优先裁剪响应权重较低的通道。

在一些实施例中，针对检测速度与准确性的平衡，对深度学习瑕疵检测模型进行轻量化设计，通过通道剪枝降低特征通道数量，使用深度可分离卷积替换原始卷积层，减少模型的参数和计算量，实现更快的检测，同时保持高准确性。

在示例性实施例中，所述目标样本图像包括具有不同材料、纹理、颜色、印花图案的口罩图像（或口罩布图像）。

为了增加模型的泛化能力，本公开实施例设计了一个混合数据集，以口罩布图像为例，该混合数据集中包含了多种类型的口罩样本，例如具有采用不同的口罩材料、颜色、纹理和印花图案等的口罩图像。

对于某些特定类型的口罩材料，例如带有印花图案的口罩布，由于其图案的类型可能是千变万化的，训练样本不可能包含所有图案的口罩样本图像，导致模型可能无法实现高检测准确性。本公开实施例中可以利用迁移学习和领域自适应技术，包括：特征空间对齐，fine-tuning（微调），度量学习等中的一种或多种，使模型能够适应新的材料、颜色、纹理、印花图案等类型。

在一些实施例中，模型定期在新收集的数据上进行再训练，以维持其泛化性能。

在示例性实施例中，获得待处理图像，包括：从图像采集组件中的图像拍摄设备获得所述待处理图像，所述图像采集组件用于获取处于生产过程中的待检测对象的所述待处理图像。其中，所述方法还包括：获得所述待检测对象的当前生产速度和所述

深度学习瑕疵检测模型对所述待处理图像的当前处理速度；根据所述当前生产速度和所述当前处理速度调整用于所述深度学习瑕疵检测模型处理所述待处理图像的并行线程或并行进程数量。

本公开实施例中引入实时检测反馈机制，根据当前生产线速度（或当前生产速度）改变模型推理并行线程数量来动态调整模型推理时间（即模型的当前处理速度），确

例如，模型经过剪枝后使用 TensorRT 进行部署，经过封装的 TensorRT 架构支持多进程，多线程并发。同时考虑到硬件长时间高负载会影响寿命，所以设计了动态调整的机制。本公开实施例中，可以使用线程池来管理推理任务的并发执行。线程池可以确保线程资源的有效利用，避免频繁创建和销毁线程带来的开销。设计一个任务调度器，负责将推理任务分配给空闲的线程。可以使用负载均衡策略，确保各个线程的负载相对均衡，避免某些线程过载而其他线程空闲的情况。

TensorRT 原生支持多线程推理，通过 IExecutionContext 的 execute_async_v2 即可实现。除此之外，本公开实施例还利用多核 CPU（Central Processing Unit，中央处理器）的优势，将 TensorRT 引擎序列化到磁盘，然后在多个进程中加载这个序列化的引擎，令每个进程都可以独立地执行推理任务，将 CPU 和 GPU（Graphics Processing Unit，图形处理器）的资源发挥到极致。

本公开实施例可以使用传感器或其他监控设备实时获取当前生产速度；监控模型当前的推理速度，即处理每张图像所需的时间作为其当前处理速度。根据当前生产速度和模型的当前处理速度的对比，调整模型的推理并行线程数量。如果当前生产速度加快，需要增加并行线程数量以加快推理速度；反之，如果当前生产速度减慢，可以减少并行线程数量以节省资源。通过结合实时检测反馈机制、动态调整模型推理并行线程数量以及 TensorRT 的高效部署，可以确保生产线上的瑕疵检测任务既准确又高效。

在示例性实施例中，获得待处理图像，包括：从图像采集组件中的图像拍摄设备获得所述待处理图像；若所述待处理图像的灰度值和灰度分布不满足预设条件，则发送控制信号调整所述图像拍摄设备的曝光参数；从调整曝光参数后的所述图像拍摄设备获得新的待处理图像，直到获得满足所述预设条件的所述待处理图像。

为了提高模型对环境因素的鲁棒性，本公开实施例设计了自动曝光模块。在每次系统开启时，通过图像拍摄设备例如相机采集当前环境下的图像，分析其灰度分布情况，如果该图像的灰度值和灰度分布不满足预设条件，则调整曝光参数，再次采集图像进行分析，不断循环，直到采集到的图像的灰度值和灰度分布满足要求，才作为输入模型的待处理图像。该自动曝光模块可以实时监测光照条件，实时计算相机最新的曝光参数，抑制外界光线的影响。

例如，期望的预设条件是直方图均衡，灰度均值在 130 到 140 之间，灰度方差越

小越好。根据相机采集的图像的灰度直方图，灰度均值，灰度方差进行判断，是否达到预设条件，不满足则根据目标差值决定是增加曝光还是减少曝光。

在示例性实施例中，本公开实施例提供的方法还包括：若所述瑕疵的类别不确定性和/或位置不确定性大于不确定阈值，则发送针对所述瑕疵的提示信息。

5 例如，在线操作期间，整个系统是端到端的。它以获取的口罩布图像为输入，模型首先删除不相关的背景，获得待处理图像。然后，它执行特征提取，最后输出瑕疵的类别检测结果、位置检测结果和类别不确定性和位置不确定性。系统可以确定类别不确定性和/或位置不确定性大于不确定性阈值（其值可以根据实际需求进行设置）的瑕疵具有高不确定性的瑕疵，此时可以触发提示信息，以提示用户该瑕疵的预测具有
10 高不确定性，进一步的，可由用户来确定如何对该瑕疵进行处理，例如是否由人工来进行瑕疵的位置和类别的标注。即本公开实施例还可以利用模型预测的类别不确定性和/或位置不确定性来协助用户识别最具信息量的数据以进行标记，从而提高注释过程的效率。

在示例性实施例中，本公开实施例提供的方法还包括：统计所述待处理图像中检测
15 出的各个瑕疵的像素数量信息；根据各个瑕疵的像素数量信息确定各个瑕疵的瑕疵等级；根据各个瑕疵的瑕疵等级，执行相应的处理。

本公开实施例提供的瑕疵检测系统中，包括算法层和数据服务层/数据服务组件。算法层中部署有上述深度学习瑕疵检测模型，以用于对待处理图像进行处理，获得瑕疵数据，例如该待处理图像是否存在瑕疵，如果存在瑕疵，则包含该瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性等瑕疵信息。数据服务层负责分析和处理算法层提供的瑕疵数据，以确定瑕疵的严重程度。例如，通过统计瑕疵的像素数量信息（例如瑕疵的长边包含的像素个数），将瑕疵分为四个等级：第一等级为
20 轻微瑕疵，如长边像素小于 20 的瑕疵；第二等级为一般瑕疵，如长边像素大于或等于 20 且小于 60 的瑕疵；第三等级为较严重瑕疵，如长边像素大于或等于 60 且小于
25 100 的瑕疵；而第四等级则为严重瑕疵，如长边像素大于 100 的瑕疵。基于此分级系统，数据服务层可以为不同等级的瑕疵制定并执行相应的处理策略，例如检测到严重瑕疵时，直接触发报警器，提示用户（例如工人）马上处理。轻微瑕疵可以不触发报警器，只在交互界面进行提示，由用户自行决定是否处理。以确保瑕疵检测和处理的
30 高效性和可靠性。

在示例性实施例中，根据各个瑕疵的瑕疵等级，执行相应的处理，包括：在所述待处理图像中，将处于不同瑕疵等级的瑕疵分别用具有不同粗细程度的边框标识。

本公开实施例中，数据服务层利用瑕疵区域边框的粗细来辅助判定瑕疵的分类等级，边框越粗表示瑕疵等级越高，边框越细表示瑕疵等级越低。例如数据服务层先统计每个瑕疵的像素数量信息，然后根据瑕疵像素数量信息将瑕疵分为四个等级，然后
35 将第一等级的瑕疵在该待处理图像中采用最细的边框标识，将第四等级的瑕疵在该待

处理图像中采用最粗的边框标识，然后将标识好的瑕疵图像提供给用户，在交互界面显示，方便用户马上能够辨别出瑕疵严重程度，从而快速决策是否需要停机处理。这种视觉标识使得在后续的人工检查过程中，操作员能够迅速且直观地了解瑕疵的严重程度。

5 在示例性实施例中，本公开实施例提供的方法还包括：保存所述待处理图像以及所述待处理图像中检测出的瑕疵的类别检测结果、位置检测结果、类别不确定性、位置不确定性、瑕疵等级、瑕疵区域图像、瑕疵区域的图像特征、检出时间和检出序号；接收并根据输入的瑕疵区域的图像特征、检出时间和检出序号中的一项或多项，检索相应的瑕疵信息。

10 本公开实施例提供的瑕疵检测系统还可以包括瑕疵记录模块，当检测到瑕疵时，该瑕疵记录模块会自动记录瑕疵的等级（即瑕疵等级）、确切位置（即位置检测结果）以及瑕点（即瑕疵或瑕疵点）的详细区域图像。为了进一步提升效率，数据服务层还可以提供了瑕点信息检索功能，瑕疵/瑕疵区域的图像特征（例如可以是特征提取模块提取的特征），检出时间，检出序号都会保存在数据库中，可以通过上述三个数据进行检索。通过这一功能，可以快速检索和回顾历史瑕疵记录，支持质量根据生产过程的持续改进。

当该瑕疵检测方法及系统应用于检测无纺口罩布的瑕疵检测时，也可称之为无纺
口罩布瑕疵检测方法及系统。当该瑕疵检测方法及系统应用于卫生及个人护理产品材
料的瑕疵检测时，也可以称之为卫生及个人护理产品材料智能缺陷检测方法及系统。

20 本公开实施例还提供了一种瑕疵检测系统，包括：图像采集组件，用于获取处于生产过程中的待检测对象的所述待处理图像；瑕疵检测装置，与所述图像采集组件连接，用于从所述图像采集组件获得所述待处理图像。

其中，所述瑕疵检测装置包括：图像处理模块，用于通过深度学习瑕疵检测模型
中的特征提取模块处理所述待处理图像，所述特征提取模块包括中间特征层，所述中
25 间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处理所述待处理图像后提
取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取模块处理后获得经
过随机丢弃处理后的多个特征；通过所述深度学习瑕疵检测模型中的检测头对经过随
机丢弃处理后的多个特征进行处理，获得所述待处理图像中的瑕疵的多个类别预测结
果、多个位置预测结果；根据所述瑕疵的多个类别预测结果和多个位置预测结果，获
30 得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位
置不确定性。

在示例性实施例中，所述图像采集组件包括：图像拍摄设备，所述图像拍摄设备
包括面阵相机。其中，所述面阵相机用于采集原始待处理图像，并对所述原始待处理
图像进行像素合并处理，以生成所述待处理图像。

35 面阵相机是指用于获取待检测对象表面图像的相机，可以采用不同类型的传感器，

例如可以为 CCD (Charge-Coupled Device, 电荷耦合器件) 或阵列相机 (array camera) 或 CMOS 面阵相机, 由固定排布的像素阵列组成, 每个像素单元都能够同时捕捉图像, 从而可以一次性地采集整个图像。面阵相机可以提供更高的分辨率和灵敏度, 特别是在较低的光照条件下。

5 在一些实施例中, 可以通过 binning (像素合并) 来优化基础相机算法, 以融合面阵相机例如 CCD 相机的多个真实像素, 从而实现具有非常短曝光时间的清晰图像, 是一种有效的高速图像捕获方法。像素合并处理时将图像中的像素合并为“超级像素”或“虚拟像素”, 例如, 将 2×2 或 3×3 等个像素融合为一个虚拟像素来增强图像, 使相机能够在非常低的曝光时间下拍摄而不会曝光不足, 从而避免因曝光时间过长而产生模糊和拖尾。

10 在 CCD 相机中, 像素合并过程在硬件或“芯片上”进行。合并后的超级像素具有更高的信号强度, 这有助于在非常短的曝光时间内获得更清晰的图像。由于曝光时间缩短, 相机可以更快地连续捕捉图像, 从而实现高速图像捕获。

15 例如, 面阵相机通过 binning 技术实现像素融合, 从而在硬件层提高图像初始亮度, 保证相机能够在较小的曝光时间内拍摄高速运动的口罩布料, 避免出现运动模糊的图像。

在示例性实施例中, 所述图像采集组件还包括: 条形光源, 位于所述图像拍摄设备的一侧, 以预定角度斜向照射在生产线上移动的所述待检测对象上。

20 条形光源是一种特殊的光源, 其形状窄而长, 通常采用 LED 或 CCFL 作为光源。条形光源的亮度比普通光源更为均匀, 这使得它非常适合用于照明或显示, 能够在一定的空间范围内提供更为均匀的光照。条形光源可以根据具体的使用场景进行定制, 包括调整其长度、亮度以及颜色等参数, 以满足不同的照明需求, 实现最佳的照明效果。条形光源具有较高的耐用性和长寿命, 可以在较长时间内保持稳定的光输出。条形光源不仅可以调节亮度和颜色, 还可以通过改变光束的形状及方向, 满足多种场景应用需求。

25 条形光源采用 LED 技术, 具有高效节能的特点, 比传统的荧光灯或白炽灯更为节能。同时, 它也具有更好的环保性能, 有助于减少能源消耗和环境污染。

需要说明的是, 本公开实施例的瑕疵检测系统中, 也可以在相机中自带光源。在另一些实施例中, 也可以采用其它光源, 例如面光源、环形光源等。

在示例性实施例中, 所述预定角度为 45 度。

30 例如, 条形光源位于相机的一侧, 以 45 度角斜向照射在生产流水线上移动的口罩布料。这种特定的照明角度可以最大化瑕点的可视对比度, 使其在相机捕捉的图像中更为明显。首先, 斜向照射的方式能够产生阴影和反射效果, 这些效果有助于凸显口罩布料表面的不平整或瑕疵部分。当光线以一定角度照射在布料上时, 瑕疵部分可能会因为形状、质地或深度的不同, 而产生不同的反射或吸收效果。这样, 相机在捕捉图像时就能更容易地区分出瑕疵与正常部分的差异。45 度角既能保证光线能够充分

覆盖到布料的表面，又能避免光线过于直接或过于斜射而导致阴影过重或过浅。适当的阴影和反射效果有助于增强瑕点的对比度，使其在图像中更加突出。条形光源的窄长形状使得光线能够集中在一个较窄的区域内，从而提高了光照的均匀性和一致性。这对于检测流水线上移动的口罩布料尤为重要，因为布料的移动可能会导致光照条件的变化。条形光源的稳定性和一致性有助于确保相机捕捉到的图像质量稳定可靠。通过合理设置条形光源的位置和角度，可以最大化瑕点的可视对比度，提高相机捕捉图像的质量和准确性，从而实现对口罩布料瑕疵的有效检测。

需要说明的是，上述 45 度不要求严格精确，可以具有一定的误差范围，例如大于±3 度均可以。

在示例性实施例中，所述系统包括工控机组件，所述工控机组件包括工控机，所述瑕疵检测装置部署在所述工控机上。

在示例性实施例中，所述工控机上还部署有数据服务组件。所述数据服务组件用于对所述生产过程中检测到的瑕疵信息进行记录和统计。

在一些实施例中，数据服务组件通过 MySQL 管理所有瑕点数据（瑕疵信息，例如图像中是否存在瑕疵，瑕疵的类别、位置、类别不确定性和位置不确定性、瑕疵等级等与瑕疵相关的任意数据）。

在另一些实施例中，数据服务组件可以将检测到的瑕疵信息实时上传到云端服务器。这样可以进行数据的集中管理，同时也方便进行远程监控、分析和优化生产流程。

在示例性实施例中，本公开实施例提供的系统还包括：报警组件，与所述瑕疵检测装置连接，用于在所述瑕疵检测装置检测到瑕疵时，接收所述瑕疵检测装置发送的触发信号，并根据所述触发信号发送报警信息。例如，该报警组件可以包括报警器，但本公开并不限于此。

在示例性实施例中，本公开实施例提供的系统还包括：显示器，与所述瑕疵检测装置连接，用于显示所述瑕疵检测装置检测出的瑕疵信息。

下面结合图 13 至图 15 对本公开实施例提供的系统进行举例说明，但本公开并不限于此。

如图 13 所示，瑕疵检测系统 120 可以包括图像采集组件 121 和瑕疵检测装置 122。例如该瑕疵检测装置 122 可以设置在高性能工控机组件中。该瑕疵检测装置 122 中可以包括图像处理模块 1221。图像采集组件 121 包括图像拍摄设备 1211（例如面阵相机）和光源 1212（例如，条形光源）。图像拍摄设备 1211 与工控机组件连接。工控机组件包括工控机。

可选的，瑕疵检测系统 120 还可以包括报警组件 123，报警组件 123 可以与工控机组件连接。

例如，高速面阵相机与高性能工控机相连接，将采集到的图像实时回传到工控机上。报警组件 123 与高性能工控机相连接，当工控机检测到布面图像/口罩布图像存在

瑕点/瑕疵时，发送触发信号给报警器，报警器发出声光信号作为报警信息，提示工人处理对应瑕疵口罩。其中，算法识别组件/算法层和数据服务组件均在高性能工控机上运行。

图 14 显示了口罩生产的缺陷检测系统的示例性场景。如图 14 所示，瑕疵检测系统 120 的硬件可以包括图像采集组件/系统（包括高速相机 1211' 和条形光源 1212'，负责采集图像信息，例如待处理图像）、高性能工控机（Industrial Control Computer, IPC, 工业控制计算机的简写，负责处理采集到的图像信息，并生成检测结果，例如包括类别检测结果和位置检测结果以及类别不确定性和位置不确定性）122'，可选的，还可以包括报警器。高性能工控机 122' 与高速相机 1211' 之间具有相机链路（Camera Link 接口）124。高性能工控机 122' 可以与条形光源 1212' 通过 RS232 进行连接。高速相机 1211' 和条形光源 1212' 位于口罩材料的切割机 125 之前的位置。这里假设口罩材料为无纺布。口罩材料或口罩布沿着口罩无纺布运动方向在导布辊 126 上朝向切割机 125 运动。条形光源 1212' 朝向导布辊 126 上的口罩布发射的光线与该口罩布之间的角度 例如可以为 45 度。

参考图 14，相机 1211'（例如摄像头）采集到的口罩布图像/材料图像由 IPC 进行处理，以进行缺陷/瑕疵识别。如果在图像中识别出缺陷，则 IPC 通过报警器发送声光信号，通知装配线上的工人拒收缺陷产品。

从图 14 可以看出，高速相机 1211' 和光源（例如条形光源 1212'）安装在口罩材料切割机 125 之前的位置。由于检测环境中的空间非常有限，并且在生产线上移动口罩材料的速度非常快，因此相机需要在短时间内（例如，至少每秒 25 帧）捕获图像。然而，当相机以如此高的速度拍摄图像时，由于曝光时间的限制，图像会变得模糊和失真。因此，本公开实施例使用 binning 将 2*2 个像素融合为一个虚拟像素（virtual pixel）来增强图像，使相机能够在非常低的曝光时间下拍摄，而不会出现曝光不足，从而避免了因长时间曝光导致的模糊和拖影。

本公开实施例提出的检测系统克服了相关技术中对机械结构过分依赖，对视觉识别方法描述不足的局限。该系统利用先进的图像捕捉设备、结合深度学习算法的智能识别技术，以及高效的数据服务支持，实现对高速运动口罩布料中瑕疵的实时、准确检测。

如图 15 所示，本公开实施例提供的瑕疵检测系统（也可称之为智能缺陷检测系统）包括硬件、算法层/组件（也可以称之为检测算法层）和数据服务层/组件。系统的硬件组成包括工控机、高速摄像头（高速相机）、光源以及报警器，它们共同工作以捕捉图像，并在检测到瑕疵时发出警告。算法层包括预处理、通道剪枝、深度可分离卷积和贝叶斯优化等技术，有效提高了检测速度和准确性。数据服务组件包括图像和数据存储、瑕点数据分析、瑕点数据报告和自动化瑕点标注。检测算法是检测系统的核心部分，而硬件和数据服务使缺陷检测系统更快、更准确、更便于使用。

相机例如可以采用 CIS 相机（CMOS Image Sensor，互补金属氧化物半导体图像传感器）、CCD 相机等。

例如，相机和光源负责采集口罩布表面图像信息以获得口罩布图像；工控机负责处理采集的图像，识别口罩布表面的瑕点；报警器用于提示工人处理不符合质量标准的次品口罩。当相机采集的口罩布图像，由工控机处理进行瑕疵识别，如果在图像中识别出瑕疵，工控机会通过报警器发出声光信号，通知生产线上的工人剔除有瑕疵的产品。

算法层是系统智能的核心，负责瑕点定位和分类。算法层包括图像预处理、通道剪枝、深度可分离卷积处理、贝叶斯优化模块。预处理的作用是在瑕疵检测之前，对图像进行预处理，通过图像增强和滤波提高瑕点和背景的差异性，从而更好地识别瑕点；通道剪枝是基于轻量化模型设计的需求，对模型进行通道剪枝，通过 L2-norm 度量卷积通道对网络输出的贡献，根据贡献程度进行通道剪枝，以减少其模型参数，提高处理速度；深度可分离卷积处理也是一种模型轻量化手段，通过 Deepwise Conv 和 Pointwise Conv 简化卷积运算过程，深度可分离卷积对比普通卷积运算，可降低 85% 的运算参数，同时保证精度不受损失；贝叶斯优化是运用贝叶斯方法优化模型，首先在模型添加 dropout 层创造随机性模拟贝叶斯后验分布，增强瑕疵检测的准确性和可靠性。贝叶斯方法能够对预测的不确定性进行量化。在检测系统中，模型不仅能预测出结果，还能提供关于这些预测有多确信的信息。这种不确定性的量化使得系统能更智能地处理信息，如对那些模型不够确信的预测采取更谨慎的处理方式。

在该实施例中，检测算法可以预测口罩材料瑕疵的四种主要类型：贴纸（贴纸是指口罩布每卷之间的连接位置，通过胶纸贴在一起上流水线的，因此也可以称之为胶纸）、污点（污渍）、印刷问题（是指某些口罩是有图案和印花的，会存在印花错误）和口罩布料折痕。在在线运行期间，整个系统是端到端的。它以获取的图像为输入，模型首先移除不相关的背景，不相关的背景是指图像中拍到的除口罩布以外的区域。通过通道剪枝和深度可分离卷积实现高效率的图像特征提取。然后，在检测架构中融入了关于随机和认知不确定性的贝叶斯方法。随机不确定性源于训练数据本身的随机性。在口罩布瑕疵检测的背景下，这可能包括因口罩布料的自然变异、生产过程中的微小差异、或是图像采集过程中的噪声引起的不确定性。随机不确定性通常是不可减少的，因为它反映了数据本身的固有变异。认知不确定性源自于模型参数的不确定性，是关于模型对于数据的理解和推断过程中的不确定性。在口罩布瑕疵检测中，认知不确定性可能源于模型对特定类型瑕疵识别的不确定性，或是模型对新材料和新类型瑕疵的适应能力。贝叶斯方法包括：在 backbone 的中间特征层添加 dropout 层用于模拟贝叶斯的后验分布效果，来获得关于特征的不同输出，这些输出的分布提供了对预测不确定性的一个近似，其中预测结果的变异性反映了模型的不确定性；修改检测头，在模型输出包含边界框的坐标、类别和置信度的基础上新增各项参数的均值和方差表

示对预测不确定的度量；调整损失函数，新增负对数似然损失，惩罚过高的不确定性和不准确的预测。具体的，新增了检测头的负对数似然损失函数，用来计算贝叶斯概率损失。作用有二：第一惩罚过高的不确定性（因为如果模型对自己的预测很不确定，损失会增大）。第二惩罚不准确的预测（预测误差大会增加损失）。

5 本公开实施例优化口罩布料瑕疵检测系统的瑕疵类别、位置和不确定性的预测过程。改进检测头的输出为概率分布，新增贝叶斯损失，例如负对数似然损失，来增加对于不确定性结果的惩罚，从而优化反向传播。在 backbone 中间特征层增加 dropout 来模拟模型参数的不确定性，实现贝叶斯后验分布。数据不确定性是由数据噪声、标注方差、样本质量（例如光照，分辨率，对比度）决定的。通过上述改进，实现模型
10 对其预测的不确定性进行估计，从而模型提高其鲁棒性和可靠性。这些创新的实施对于提高口罩布料瑕疵检测系统的准确性和效率较为重要，特别是在高速生产环境中。通过这些技术的结合，能够实现对高速运动口罩布料的有效检测，同时提高了系统的鲁棒性和可靠性。

数据服务层是口罩布瑕疵检测系统中的信息处理和决策支持中心，负责整合算法
15 层的输出并执行后续的数据管理和决策制定。数据服务层包括瑕点和图像数据存储、瑕点数据聚合、瑕点数据传输、自动决策制定模块。图像和瑕点数据存储负责收集并保存，所有通过图像采集系统获取的原始图像数据以及算法层处理后的结果数据（包括瑕点的位置、瑕点的瑕疵类型、每个瑕点的不确定性、疵点区域的图像特征等中的一种或多种），通过高效的数据组织和索引机制，确保数据的可查询性和可访问性。
20 其中瑕点数据分析会对检测到的各类瑕疵数据进行统一整合和分析，将分散的瑕疵信息汇总成直观的报告，以便于监控和评估生产质量。瑕点数据传输，确保检测到的瑕疵信息能够快速且准确地传递到生产线的下游环节或质量控制部门，为实时响应和处理瑕疵提供支持。自动决策制定，是基于聚合分析的瑕疵数据，结合生产线的实际情况，本模块通过智能决策算法分析瑕疵点检出的分布情况和不确定性概率，生成报告，
25 帮助生产者了解目前口罩生产出现哪种瑕疵点的情况最多，严重瑕疵点出现的频率等，让生产者从更宏观的角度了解生产工艺的缺陷，以优化生产过程。

数据服务层负责存储、分析和传输检测数据，并根据瑕疵的严重程度实施相应的处理策略。此外，数据服务层还增强了人工检查的效率，通过瑕疵边框的粗细直观显示瑕点等级/瑕疵等级，并提供瑕点信息/瑕疵信息的检索功能，支持质量追踪和生产
30 流程的优化。

本公开实施例涉及一种高速生产环境下的口罩布瑕疵检测系统。该系统集成了高性能图像捕捉硬件（相机和光源）、先进的深度学习算法（包括上述实施例中提及的深度学习瑕疵检测模型）以及全面的数据服务层，以实现对高速移动口罩布料的实时瑕疵检测和分类。整体而言，本公开提供了一种既高效又可靠的解决方案，以满足快
35 速生产线上对于高质量口罩的需求。

本公开的实施例提供的口罩布瑕疵检测系统，通过设置图像采集组件和算法层以及数据服务组件，能够在不影响口罩布生产流水线速度的前提下，对经过的口罩布进行高效、准确的瑕疵检测，并在检测到瑕疵时，自动进行打标，极大地提高了生产效率和产品质量。通过人工和自动化检测的结合，本系统也确保了高水平的检测可靠性。

例如结合贝叶斯方法会给出预测出的每个瑕点一个不确定性的评分（例如参考上述公式（2）），如果某个瑕点的不确定性的评分较高，则会将该瑕点发送给人工来打标。

本公开实施例中的“高速”是指满足全局快门，最大帧率例如超过 60fps。高速例如是指，在流水线上以 500 个/min 的口罩生产速度去拍摄口罩布，图像不出现动态模糊，相机帧采样间隔不会丢失口罩布区域信息。

根据本公开的一个实施方面，提供了一种口罩布瑕疵检测系统，该系统包括：图像采集组件，包含高速面阵相机，条形光源以及相机和光源支架。高速面阵相机用于采集口罩布表面图像，光源用于突出瑕疵和背景的视觉差异；高性能工控机组件，包含一台装配了高性能 GPU 的工控机和一台显示器，工控机用于实时检测相机采集的图像中的瑕疵，显示器安装于口罩生产线尾端，方便工人确认口罩瑕疵的图像信息；报警组件，安装在口罩生产线尾端，当检测到瑕疵时，报警器触发提示工人及时处理；瑕疵识别算法组件，通过分析瑕疵特性和图像特性，对模型进行改进，优化其计算速度和精度。其中，图像特性可以包括图像中的背景的变化情况，被检测物体的表面纹理变化情况，周围环境光对图像的干扰情况等中的一种或多种。涉及图像特性的处理就是调整相机曝光、移除图像背景。

本公开实施例中，瑕疵点特性就是瑕疵的锚框分布特性，瑕疵点特征类间欧几里得距离。例如，分析瑕疵点的锚框分布特性，瑕疵点特征类间欧几里得距离。根据锚框分布特性进行聚类，生成最优先验锚框，根据瑕疵点特征类间欧几里得距离，进行排序比对，优化瑕疵点分类精度。

本公开实施例中，分析瑕疵点特征/瑕疵特性的两种方式：

一种是生成最优先验锚框：例如通过 k-means 对标注的瑕疵锚框进行聚类，找出最优的先验锚框，从而分析瑕疵的长宽比例分布情况。

另一种是 hard sample 挖掘和优化：首先根据锚框的分布，找出不同比例的瑕疵点，例如对于长宽比 1:1 的瑕疵点，对于瑕疵点 A，计算 A 和长宽比 1:1 的其他类瑕疵点的欧几里得距离。然后找出距离最近的不同类瑕疵点标记为 N (Negative)，找出距离最远的同类瑕疵点标记为 P (Positive)。那么这 3 个瑕疵点样本就构成了一个 hard sample triplet (三元组)。通过构筑多个不同长宽比例瑕疵的这种 hard sample triplets 最终构建一个 hard sample dataset (数据集)。然后针对 hard sample dataset 将模型进行深度训练，使模型对这种 hard sample 更加拟合，从而达到更好的检测效果。即挑选最难分辨的瑕疵点，进行针对性优化。

条形光源的优点是功率大，光照强度高。因为相机要拍摄高度运动物体，曝光时

间不能太长，所以需要足够强的光源来提供亮度。选择的条形光源的照明宽度和长度足够覆盖相机拍摄面积。

数据服务组件，对所有流水线上检测的瑕点进行记录和统计，实时更新到数据库，进行数据分析，帮助工人分析瑕疵成因，从而优化工艺。

5 本公开的目的在于提供一种口罩布瑕疵检测系统，该系统旨在至少在一定程度上解决现有技术在口罩布瑕疵检测中所遇到的诸如检测精度不足等问题。本系统通过引入先进的图像采集和处理技术，显著提高了瑕疵识别的准确性和效率，从而改善了相关技术领域的工艺流程。

10 本公开实施例提供了一整套在线高速疵点检测系统，其是一种针对具体业务场景（处于生产流水线上高速运动的口罩布）的系统性改进和创新，对模型进行整体轻量化，并在模型中引入贝叶斯估计，通过 AIGC 技术增强训练样本，通过量化学习解决 hard sample 问题使模型能够更好的收敛，通过 binning 提高图像采集质量，设计相机自动曝光算法，以及设计人机交互逻辑优化疵点决策过程。

15 在示例性实施例中，本公开实施例还提供了一种瑕疵检测系统，包括：图像拍摄设备，用于采集处于生产过程中的待检测对象的所述待处理图像；处理器和用于存储计算机程序的存储器；当所述处理器执行所述计算机程序时，实现上述任意实施例中所述方法中的步骤。

在示例性实施例中，所述存储器包括用于存储瑕疵检测程序（实现上述算法层的功能）的存储器和用于存储服务数据程序（实现上述数据服务层的功能）的存储器。

20 在以上描述中，智能缺陷检测系统和方法等被列为优选示例。本领域的技术人员将明白，在不脱离本发明的范围和精神的情况下，可以进行修改，包括添加和/或替换。可以省略具体细节，以免混淆本发明；然而，本公开的目的是使本领域的技术人员能够实践本文的教导，而无需进行过多的实验。

25 图 16 是本公开一示例性实施例的瑕疵检测装置的结构示意图。如图 16 所示，本公开实施例提供的瑕疵检测装置 1500 包括图像获得模块 1510 和图像处理模块 1520。

图像获得模块 1510 可以用于获得待处理图像。

30 图像处理模块 1520 可以用于通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像，所述特征提取模块包括中间特征层，所述中间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征。

图像处理模块可以还用于通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理，获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果。

35 图像处理模块可以还用于根据所述瑕疵的多个类别预测结果和多个位置预测结

果，获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

其中，图像处理模块 1520 还用于：根据所述第一瑕疵的多个第一类别预测结果和多个第一位置预测结果，获得所述第一瑕疵的第一类别检测结果、第一位置检测结果、第一类别不确定性和第一位置不确定性；根据所述第二瑕疵的多个第二类别预测结果和多个第二位置预测结果，获得所述第二瑕疵的第二类别检测结果、第二位置检测结果、第二类别不确定性和第二位置不确定性。

在示例性实施例中，图像获得模块 1510 还用于：从图像采集组件中的图像拍摄设备获得所述待处理图像，所述图像采集组件用于获取处于生产过程中的待检测对象的所述待处理图像。

其中，瑕疵检测装置 1500 还可以包括：速度获得模块，可以用于获得所述待检测对象的当前生产速度和所述深度学习瑕疵检测模型对所述待处理图像的当前处理速度。图像处理模块 1520 还可以用于根据所述当前生产速度和所述当前处理速度调整用于所述深度学习瑕疵检测模型处理所述待处理图像的并行线程或并行进程数量。

在示例性实施例中，图像获得模块 1510 还用于：从图像采集组件中的图像拍摄设备获得所述待处理图像；若所述待处理图像的灰度值和灰度分布不满足预设条件，则发送控制信号调整所述图像拍摄设备的曝光参数；从调整曝光参数后的所述图像拍摄设备获得新的待处理图像，直到获得满足所述预设条件的所述待处理图像。

在示例性实施例中，瑕疵检测装置 1500 还可以包括：发送模块，用于若所述瑕疵的类别不确定性和/或位置不确定性大于不确定阈值，则发送针对所述瑕疵的提示信息。

在示例性实施例中，瑕疵检测装置 1500 还可以包括：数据处理模块，用于统计所述待处理图像中检测出的各个瑕疵的像素数量信息；根据各个瑕疵的像素数量信息确定各个瑕疵的瑕疵等级；根据各个瑕疵的瑕疵等级，执行相应的处理。

在示例性实施例中，数据处理模块还可以用于：在所述待处理图像中，将处于不同瑕疵等级的瑕疵分别用具有不同粗细程度的边框标识。

在示例性实施例中，瑕疵检测装置 1500 还可以包括：数据处理模块，可以用于保存所述待处理图像以及所述待处理图像中检测出的瑕疵的类别检测结果、位置检测结果、类别不确定性、位置不确定性、瑕疵等级、瑕疵区域图像、瑕疵区域的图像特征、检出时间和检出序号；接收并根据输入的瑕疵区域的图像特征、检出时间和检出序号中的一项或多项，检索相应的瑕疵信息。

在示例性实施例中，瑕疵检测装置 1500 还可以包括：模型训练模块，可以用于获得目标训练数据集，所述目标训练数据集中包括目标样本图像及所述目标样本图像中的目标样本瑕疵的标注类别和标注位置；将所述目标样本图像输入至所述深度学习瑕疵检测模型，获得所述目标样本瑕疵的多个类别预测结果和多个位置预测结果；根

据所述目标样本瑕疵的多个类别预测结果和多个位置预测结果获得所述目标样本瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性；根据所述目标样本瑕疵的标注类别及类别检测结果、标注位置及位置检测结果、以及类别不确定性和位置不确定性构建损失函数以训练所述深度学习瑕疵检测模型。

5 在示例性实施例中，模型训练模块还可以用于：获取初始样本图像及所述初始样本图像中的初始样本瑕疵的标注类别和标注位置；对所述初始样本图像进行随机裁剪、旋转、缩放、光照变化模拟、瑕疵合成中的任意一项或多项处理，生成扩增样本图像及所述扩展增益图像中的扩展样本瑕疵的标注类别和标注位置。其中，所述目标样本图像包括所述初始样本图像和所述扩增样本图像。

10 在示例性实施例中，模型训练模块还可以用于：提取所述初始样本图像中的初始样本瑕疵；将所述初始样本瑕疵与扩增背景图像合成，生成所述扩增样本图像；和/或，通过深度学习生成模型学习所述初始样本图像，生成所述扩增样本图像。

15 在示例性实施例中，模型训练模块还可以用于：获取候选样本图像及所述候选样本图像中的候选样本瑕疵的标注类别和标注位置；通过所述特征提取模块获得所述候选样本图像的输出特征；基于各个候选样本图像的输出特征，获得各个候选样本图像之间的特征距离；选择标注类别相同的候选样本图像中特征距离大于第一距离阈值的候选样本图像，和/或，标注类别不同的候选样本图像中特征距离小于第二距离阈值的候选样本图像，作为所述目标训练数据集中的目标样本图像。

20 在示例性实施例中，模型训练模块还可以用于在所述深度学习瑕疵检测模型的训练过程中：提取所述深度学习瑕疵检测模型中的每个卷积层的权重张量；获得所述权重张量中每个通道的欧几里得范数；对每个卷积层根据其通道的欧几里得范数进行排序，根据剪枝阈值或剪枝比例，对相应的通道进行剪枝。

图 16 实施例的其它内容可参考上述其它实施例。

25 图 17 示意性示出了根据本公开的一实施例的电子设备 1600 的示意性结构图。图 17 所示的电子设备 1600 包括处理器 1610，处理器 1610 可以从存储器中调用并运行计算机程序，以实现本公开实施例中的方法。

可选地，如图 17 所示，电子设备 1600 还可以包括存储器 1620。其中，处理器 1610 可以从存储器 1620 中调用并运行计算机程序，以实现本公开实施例中的方法。

30 其中，存储器 1620 可以是独立于处理器 1610 的一个单独的器件，也可以集成在处理器 1610 中。

可选地，如图 17 所示，电子设备 1600 还可以包括收发器 1630，处理器 1610 可以控制该收发器 1630 与其他设备进行通信，具体地，可以向其他设备发送信息或数据，或接收其他设备发送的信息或数据。

35 可选地，处理器 1610、存储器 1620 以及收发器 1630 之间可以通过通信总线 1640 实现相互之间的双向通信。

应理解，本公开实施例的处理器可能是一种集成电路芯片，具有信号的处理能力。在实现过程中，上述方法实施例的各步骤可以通过处理器中的硬件的集成逻辑电路或者软件形式的指令完成。

上述的处理器可以是通用处理器、数字信号处理器(Digital Signal Processor, DSP)、
5 专用集成电路(Application Specific Integrated Circuit, ASIC)、现成可编程门阵列(Field Programmable Gate Array, FPGA)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。可以实现或者执行本公开实施例中的公开的各方法、步骤及逻辑框图。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等。结合本公开实施例所公开的方法的步骤可以直接体现为硬件译码处理器执行完成，
10 或者用译码处理器中的硬件及软件模块组合执行完成。软件模块可以位于随机存储器、闪存、只读存储器，可编程只读存储器或者电可擦写可编程存储器、寄存器等本领域成熟的存储介质中。该存储介质位于存储器，处理器读取存储器中的信息，结合其硬件完成上述方法的步骤。

可以理解，本公开实施例中的存储器可以是易失性存储器或非易失性存储器，或
15 可包括易失性和非易失性存储器两者。其中，非易失性存储器可以是只读存储器(Read-Only Memory, ROM)、可编程只读存储器(Programmable ROM, PROM)、可擦除可编程只读存储器(Erasable PROM, EPROM)、电可擦除可编程只读存储器(Electrically EPROM, EEPROM)或闪存。易失性存储器可以是随机存取存储器(Random Access Memory, RAM)，其用作外部高速缓存。通过示例性但不是限制性说明，许多形式的RAM可用，例如静态随机存取存储器(Static RAM, SRAM)、
20 动态随机存取存储器(Dynamic RAM, DRAM)、同步动态随机存取存储器(Synchronous DRAM, SDRAM)、双倍数据速率同步动态随机存取存储器(Double Data Rate SDRAM, DDR SDRAM)、增强型同步动态随机存取存储器(Enhanced SDRAM, ESDRAM)、同步连接动态随机存取存储器(SynchlinkDRAM, SLDRAM)和直接内存总线随机存取存储器(Direct Rambus RAM, DR RAM)。应注意，本文描述的系统和方法的存储器旨在包括但不限于这些和任意其它适合类型的存储器。应理解，上述存储器为示例性但不是限制性说明。

本公开实施例还提供了一种计算机可读存储介质，用于存储计算机程序。该计算机程序使得计算机执行本公开实施例的各个方法中的相应流程，为了简洁，在此不再赘述。
30 本公开实施例还提供了一种计算机程序产品，包括计算机程序指令。该计算机程序指令使得计算机执行本公开实施例的各个方法中的相应流程，为了简洁，在此不再赘述。本公开实施例还提供了一种计算机程序。当该计算机程序在计算机上运行时，使得计算机执行本公开实施例的各个方法中的相应流程，为了简洁，在此不再赘述。

本领域普通技术人员可以意识到，结合本文中所公开的实施例描述的各示例的单元及算法步骤，能够以电子硬件、或者计算机软件和电子硬件的结合来实现。这些功
35

能究竟以硬件还是软件方式来执行，取决于技术方案的特定应用和设计约束条件。专业技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能，但是这种实现不应认为超出本公开的范围。

- 5 所属领域的技术人员可以清楚地了解到，为描述的方便和简洁，上述描述的系统、装置和单元的具体工作过程，可以参考前述方法实施例中的对应过程，在此不再赘述。在本公开所提供的几个实施例中，应该理解到，所揭露的系统、装置和方法，可以通过其它的方式实现。例如，以上所描述的装置实施例仅仅是示意性的，例如，所述单元的划分，仅仅为一种逻辑功能划分，实际实现时可以有另外的划分方式，例如多个单元或组件可以结合或者可以集成到另一个系统，或一些特征可以忽略，或不执行。

10

工业实用性

本公开适用于人工智能技术领域，用以解决相关技术中瑕疵预测不准确且无法输出类别不确定性和位置不确定性的问题，达到快速有效的预测瑕疵的类别和位置、并评估预测结果的类别不确定性和位置不确定性的效果。

权利要求

1.一种瑕疵检测方法，包括：

获得待处理图像；

5 通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像，所述特征提取模块包括中间特征层，所述中间特征层中包括丢弃层，所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃，以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征；

通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理，获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果；

10 根据所述瑕疵的多个类别预测结果和多个位置预测结果，获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

2.如权利要求1所述的方法，其中，所述中间特征层包括第一跨阶段卷积块，所述丢弃层包括第一丢弃层；

15 其中，所述第一跨阶段卷积块包括第一跨阶段输入层、第一卷积层、第一中间层、第二卷积层、第一融合层、第三卷积层和所述第一丢弃层；

所述第一卷积层用于将所述第一跨阶段输入层输入的第一跨阶段输入特征图进行卷积处理，向所述第一中间层输入第一卷积特征图；

所述第一中间层用于对所述第一卷积特征图进行处理，向所述第一融合层输入第一待融合特征图；

20 所述第二卷积层用于对所述第一跨阶段输入特征图进行卷积处理，向所述第一融合层输入第二待融合特征图；

所述第一融合层用于对所述第一待融合特征图和所述第二待融合特征图进行融合处理，向所述第三卷积层输入第一融合特征图；

25 所述第三卷积层用于对所述第一融合特征图进行卷积处理，向所述第一丢弃层输入第二卷积特征图；

所述第一丢弃层用于对所述第二卷积特征图中的特征进行随机丢弃，获得多个第一丢弃特征图，所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征包括多个所述第一丢弃特征图。

30 3.如权利要求2所述的方法，其中，所述中间特征层还包括第二跨阶段卷积块和第三跨阶段卷积块，所述丢弃层还包括第二丢弃层和第三丢弃层；

其中，所述第二跨阶段卷积块的输入端连接所述第一跨阶段卷积块的输出端，以分别接收多个所述第一丢弃特征图，并对多个所述第一丢弃特征图进行处理，通过所述第二丢弃层向所述第三跨阶段卷积块输入多个第二丢弃特征图；

所述第三跨阶段卷积块的输入端连接所述第二跨阶段卷积块的输出端，以分别接收多

个所述第二丢弃特征图，并对多个所述第二丢弃特征图进行处理，通过所述第三丢弃层输出多个第三丢弃特征图。

4.如权利要求3所述的方法，其中，所述深度学习瑕疵检测模型还包括特征金字塔模块，所述特征金字塔模块包括第一空间金字塔池化块、第二空间金字塔池化块和第三空间金字塔池化块；

所述第一空间金字塔池化块连接所述第一跨阶段卷积块，用于接收多个所述第一丢弃特征图；

所述第二空间金字塔池化块连接所述第二跨阶段卷积块，用于接收多个所述第二丢弃特征图，并分别对多个所述第二丢弃特征图进行处理，获得多个第二空间池化特征图；

所述第三空间金字塔池化块连接所述第三跨阶段卷积块，用于接收多个所述第三丢弃特征图，并分别对多个所述第三丢弃特征图进行处理，获得多个第三空间池化特征图；

所述第一空间金字塔池化块还连接所述第二空间金字塔池化块，用于接收多个所述第二空间池化特征图，根据多个所述第一丢弃特征图和多个所述第二空间池化特征图获得多个第一空间池化特征图；

所述第二空间金字塔池化块还连接所述第三空间金字塔池化块，用于接收多个所述第三空间池化特征图，根据多个所述第二丢弃特征图和多个所述第三空间池化特征图获得多个第二空间池化特征图。

5.如权利要求4所述的方法，其中，所述检测头包括第一深度可分离卷积块、第二深度可分离卷积块和第三深度可分离卷积块；所述瑕疵包括第一瑕疵、第二瑕疵和第三瑕疵；

所述第一深度可分离卷积块与所述第一空间金字塔池化块连接，用于接收多个所述第一空间池化特征图，并分别对多个所述第一空间池化特征图进行处理，获得所述第一瑕疵的多个第一类别预测结果和多个第一位置预测结果；

所述第二深度可分离卷积块与所述第二空间金字塔池化块连接，用于接收多个所述第二空间池化特征图，并分别对多个所述第二空间池化特征图进行处理，获得所述第二瑕疵的多个第二类别预测结果和多个第二位置预测结果；

所述第三深度可分离卷积块与所述第三空间金字塔池化块连接，用于接收多个所述第三空间池化特征图，并分别对多个所述第三空间池化特征图进行处理，获得所述第三瑕疵的多个第三类别预测结果和多个第三位置预测结果；

其中，根据所述瑕疵的多个类别预测结果和多个位置预测结果，获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性，包括：

根据所述第一瑕疵的多个第一类别预测结果和多个第一位置预测结果，获得所述第一瑕疵的第一类别检测结果、第一位置检测结果、第一类别不确定性和第一位置不确定性；

根据所述第二瑕疵的多个第二类别预测结果和多个第二位置预测结果，获得所述第二瑕疵的第二类别检测结果、第二位置检测结果、第二类别不确定性和第二位置不确定性；

根据所述第三瑕疵的多个第三类别预测结果和多个第三位置预测结果，获得所述第三

瑕疵的第三类别检测结果、第三位置检测结果、第三类别不确定性和第三位置不确定性。

6.如权利要求2所述的方法，其中，所述第一中间层包括第一中间输入层、第一深度可分离卷积层和第一累加层；

5 所述第一中间输入层用于接收所述第一卷积层输出的第一卷积特征图，并将所述第一卷积特征图分别输入至所述第一深度可分离卷积层和所述第一累加层；

所述第一深度可分离卷积层用于对所述第一卷积特征图进行深度可分离卷积处理，向所述第一累加层输入第一深度分离卷积特征图；

所述第一累加层对所述第一卷积特征图和所述第一深度分离卷积特征图进行累加处理，获得所述第一待融合特征图。

10 7.如权利要求6所述的方法，其中，所述第一深度可分离卷积层包括第一深度分离输入层、第一深度卷积层、第一点卷积层和第一激活函数层；

所述第一深度分离输入层用于接收所述第一中间输入层输出的第一卷积特征图，并将所述第一卷积特征图分别输入至所述第一深度卷积层和所述第一激活函数层；

15 所述第一深度卷积层用于对所述第一卷积特征图进行深度卷积处理，并向所述第一点卷积层输入第一深度卷积特征图；

所述第一点卷积层用于对所述第一深度卷积特征图进行点卷积处理，并向所述第一激活函数层输入第一点卷积特征图；

所述第一激活函数层用于对所述第一点卷积特征图和所述第一卷积特征图进行处理，获得所述第一深度分离卷积特征图。

20 8.如权利要求1所述的方法，其中，所述特征提取模块还包括与所述中间特征层连接的注意力块；

所述注意力块用于对所述待处理图像进行处理，获得所述待处理图像的下采样特征图，并将所述下采样特征图输入至所述中间特征层。

9.如权利要求1所述的方法，其中，所述深度学习瑕疵检测模型还包括背景移除模块；

25 所述背景移除模块用于移除所述待处理图像中的背景信息，并将移除所述背景信息之后的所述待处理图像输入至所述特征提取模块。

10.如权利要求1所述的方法，其中，获得待处理图像，包括：

从图像采集组件中的图像拍摄设备获得所述待处理图像，所述图像采集组件用于获取处于生产过程中的待检测对象的所述待处理图像；

30 其中，所述方法还包括：

获得所述待检测对象的当前生产速度和所述深度学习瑕疵检测模型对所述待处理图像的当前处理速度；

根据所述当前生产速度和所述当前处理速度调整用于所述深度学习瑕疵检测模型处理所述待处理图像的并行线程或并行进程数量。

35 11.如权利要求1所述的方法，其中，获得待处理图像，包括：

从图像采集组件中的图像拍摄设备获得所述待处理图像；

若所述待处理图像的灰度值和灰度分布不满足预设条件，则发送控制信号调整所述图像拍摄设备的曝光参数；

5 从调整曝光参数后的所述图像拍摄设备获得新的待处理图像，直到获得满足所述预设条件的所述待处理图像。

12.如权利要求 1 所述的方法，其中，还包括：

若所述瑕疵的类别不确定性和/或位置不确定性大于不确定阈值，则发送针对所述瑕疵的提示信息。

13.如权利要求 1 所述的方法，其中，还包括：

10 统计所述待处理图像中检测出的各个瑕疵的像素数量信息；

根据各个瑕疵的像素数量信息确定各个瑕疵的瑕疵等级；

根据各个瑕疵的瑕疵等级，执行相应的处理。

14.如权利要求 13 所述的方法，其中，根据各个瑕疵的瑕疵等级，执行相应的处理，包括：

15 在所述待处理图像中，将处于不同瑕疵等级的瑕疵分别用具有不同粗细程度的边框标识。

15.如权利要求 1 所述的方法，其中，还包括：

保存所述待处理图像以及所述待处理图像中检测出的瑕疵的类别检测结果、位置检测结果、类别不确定性、位置不确定性、瑕疵等级、瑕疵区域图像、瑕疵区域的图像特征、
20 检出时间和检出序号；

接收并根据输入的瑕疵区域的图像特征、检出时间和检出序号中的一项或多项，检索相应的瑕疵信息。

16.如权利要求 1 所述的方法，其中，还包括：

25 获得目标训练数据集，所述目标训练数据集中包括目标样本图像及所述目标样本图像中的目标样本瑕疵的标注类别和标注位置；

将所述目标样本图像输入至所述深度学习瑕疵检测模型，获得所述目标样本瑕疵的多个类别预测结果和多个位置预测结果；

根据所述目标样本瑕疵的多个类别预测结果和多个位置预测结果获得所述目标样本瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性；

30 根据所述目标样本瑕疵的标注类别及类别检测结果、标注位置及位置检测结果、以及类别不确定性和位置不确定性构建损失函数以训练所述深度学习瑕疵检测模型。

17.如权利要求 16 所述的方法，其中，所述损失函数包括第一损失函数和第二损失函数；

35 当所述目标样本瑕疵的标注类别和类别检测结果的差异越大，标注位置和位置检测结果的差异越大时，所述第一损失函数的取值越大；

当所述目标样本瑕疵的类别不确定性和所述位置不确定性越大时,所述第二损失函数的取值越大。

18.如权利要求 17 所述的方法,其中,所述第一损失函数 L_1 如下:

$$L_1 = \sum_{i=1}^N \text{MSE}(y_i, y_i^{\text{pre}}) + \sum_{c=1}^C \text{CE}(s_c, s_c^{\text{pre}}) + \text{BCE}(o, o^{\text{pre}})$$

- 5 MSE 是表示边界框回归计算, y_i 是第 i 个目标样本瑕疵的标注位置, y_i^{pre} 是预测的第 i 个目标样本瑕疵的位置检测结果, N 是目标样本瑕疵的数量, N 为大于或等于 1 的正整数, i 为大于或等于 1 且小于或等于 N 的正整数; CE 表示多元交叉熵计算, s_c^{pre} 表示预测的类别检测结果中类别 c 的类别置信度; s_c 表示标注类别中类别 c 的类别置信度, C 表示类别数量, C 为大于或等于 1 的正整数, c 为大于或等于 1 且小于或等于 C 的正整数;
- 10 BCE 表示二元交叉熵计算, o^{pre} 表示针对目标样本瑕疵预测的目标置信度, o 表示目标样本瑕疵中标注的目标的置信度。

19.如权利要求 17 所述的方法,其中,所述第二损失函数 L_2 如下:

$$L_2 = \sum_{i=1}^N \left(\frac{1}{2\sigma_i^2} (y_i - \mu_i)^2 + \frac{1}{2} \log \sigma_i^2 \right) + \sum_{c=1}^C \left[\frac{1}{2\sigma_c^2} (s_c - \mu_c)^2 + \frac{1}{2} \log \sigma_c^2 \right]$$

- 15 μ_i 是预测的第 i 个目标样本瑕疵的位置检测结果, y_i 是第 i 个目标样本瑕疵的标注位置; σ_i^2 是预测的第 i 个目标样本瑕疵的位置不确定性; N 是目标样本瑕疵的数量, N 为大于或等于 1 的正整数, i 为大于或等于 1 且小于或等于 N 的正整数; μ_c 表示预测的类别 c 的类别检测结果; s_c 表示标注类别中类别 c 的类别置信度, σ_c^2 表示预测的类别 c 的类别不确定性, C 表示类别数量, C 为大于或等于 1 的正整数, c 为大于或等于 1 且小于或等于 C 的正整数。

- 20.如权利要求 16 所述的方法,其中,获得目标训练数据集,包括:

获取初始样本图像及所述初始样本图像中的初始样本瑕疵的标注类别和标注位置;

对所述初始样本图像进行随机裁剪、旋转、缩放、光照变化模拟、瑕疵合成中的任意一项或多项处理,生成扩增样本图像及所述扩展增益图像中的扩展样本瑕疵的标注类别和标注位置;

- 25 其中,所述目标样本图像包括所述初始样本图像和所述扩增样本图像。

21.如权利要求 20 所述的方法,其中,对所述初始样本图像进行瑕疵合成处理,生成扩增样本图像,包括:

提取所述初始样本图像中的初始样本瑕疵;将所述初始样本瑕疵与扩增背景图像合成,生成所述扩增样本图像;和/或,

- 30 通过深度学习生成模型学习所述初始样本图像,生成所述扩增样本图像。

22.如权利要求 16 所述的方法,其中,获得目标训练数据集,包括:

获取候选样本图像及所述候选样本图像中的候选样本瑕疵的标注类别和标注位置;

通过所述特征提取模块获得所述候选样本图像的输出特征;

基于各个候选样本图像的输出特征,获得各个候选样本图像之间的特征距离;

选择标注类别相同的候选样本图像中特征距离大于第一距离阈值的候选样本图像,和/或,标注类别不同的候选样本图像中特征距离小于第二距离阈值的候选样本图像,作为所述目标训练数据集中的目标样本图像。

23.如权利要求 16 所述的方法,其中,在所述深度学习瑕疵检测模型的训练过程中:

5 提取所述深度学习瑕疵检测模型中的每个卷积层的权重张量;

获得所述权重张量中每个通道的欧几里得范数;

对每个卷积层根据其通道的欧几里得范数进行排序,根据剪枝阈值或剪枝比例,对相应的通道进行剪枝。

10 24.如权利要求 16 所述的方法,其中,所述目标样本图像包括具有不同材料、纹理、颜色、印花图案的口罩图像。

25.一种瑕疵检测装置,包括:

图像获得模块,用于获得待处理图像;

15 图像处理模块,用于通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像,所述特征提取模块包括中间特征层,所述中间特征层中包括丢弃层,所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃,以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征;

所述图像处理模块还用于,通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理,获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果;

20 所述图像处理模块还用于,根据所述瑕疵的多个类别预测结果和多个位置预测结果,获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

26.一种瑕疵检测系统,包括:

图像采集组件,用于获取处于生产过程中的待检测对象的所述待处理图像;

25 瑕疵检测装置,与所述图像采集组件连接,用于从所述图像采集组件获得所述待处理图像;其中,所述瑕疵检测装置包括:

30 图像处理模块,用于通过深度学习瑕疵检测模型中的特征提取模块处理所述待处理图像,所述特征提取模块包括中间特征层,所述中间特征层中包括丢弃层,所述丢弃层用于对所述中间特征层处理所述待处理图像后提取的特征进行随机丢弃,以使得所述待处理图像经过所述特征提取模块处理后获得经过随机丢弃处理后的多个特征;通过所述深度学习瑕疵检测模型中的检测头对经过随机丢弃处理后的多个特征进行处理,获得所述待处理图像中的瑕疵的多个类别预测结果、多个位置预测结果;根据所述瑕疵的多个类别预测结果和多个位置预测结果,获得所述待处理图像中的所述瑕疵的类别检测结果、位置检测结果、类别不确定性和位置不确定性。

35 27.如权利要求 26 所述的系统,其中,所述图像采集组件包括:

图像拍摄设备，所述图像拍摄设备包括面阵相机；

其中，所述面阵相机用于采集原始待处理图像，并对所述原始待处理图像进行像素合并处理，以生成所述待处理图像。

28.如权利要求 27 所述的系统，其中，所述图像采集组件还包括：

5 条形光源，位于所述图像拍摄设备的一侧，以预定角度斜向照射在生产线上移动的所述待检测对象上。

29.如权利要求 28 所述的系统，其中，所述预定角度为 45 度。

30.如权利要求 26 所述的系统，其中，所述系统包括工控机组件，所述工控机组件包括工控机，所述瑕疵检测装置部署在所述工控机上。

10 31.如权利要求 30 所述的系统，其中，所述工控机上还部署有数据服务组件；所述数据服务组件用于对所述生产过程中检测到的瑕疵信息进行记录和统计。

32.如权利要求 26 所述的系统，其中，还包括：

报警组件，与所述瑕疵检测装置连接，用于在所述瑕疵检测装置检测到瑕疵时，接收所述瑕疵检测装置发送的触发信号，并根据所述触发信号发送报警信息。

15 33.如权利要求 26 所述的系统，其中，还包括：

显示器，与所述瑕疵检测装置连接，用于显示所述瑕疵检测装置检测出的瑕疵信息。

34.一种瑕疵检测系统，包括：

图像拍摄设备，用于采集处于生产过程中的待检测对象的所述待处理图像；

处理器和用于存储计算机程序的存储器；当所述处理器执行所述计算机程序时，实现

20 如上述权利要求 1 至 24 任一项所述方法中的步骤。

35.如权利要求 34 所述的系统，其中，所述存储器包括用于存储瑕疵检测程序的存储器和用于存储服务数据程序的存储器。

36. 一种电子设备，包括：

一个或多个处理器；

25 存储器，配置为存储一个或多个程序，当所述一个或多个程序被所述一个或多个处理器执行时，使得所述电子设备实现权利要求 1 至 24 中任一项所述的方法。

37. 一种计算机可读存储介质，所述计算机可读存储介质存储有计算机程序，当所述计算机程序在计算机上运行时，使得所述计算机执行权利要求 1 至 24 中任一项所述的方法。

30 38. 一种计算机程序产品，包括计算机程序，该计算机程序被处理器执行时实现权利要求 1 至 24 中任一项所述的方法。




图 1




图 2




图 3




图 4




图 5




图 6




图 7




图 8




图 9




图 10




图 11




图 12

瑕疵检测系统120




图 13

瑕疵检测系统120




图 14

2408938HK07




图 15




图 16




图 17

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2024/107018

A. CLASSIFICATION OF SUBJECT MATTER G06T7/00(2017.01)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) G06T7/- 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, CNTXT, ENTXT, DWPI, VEN, ENTXTC, CNKI, 万方, WANFANG, 百度学术, BAIDU SCHOLAR: 瑕疵, 缺陷, 故障, 特征提取, 丢弃层, 随机失活, 过拟合, 检测头, 类别, 分类, 位置, 不确定性, 残差, 三层残差, 单阶段, 两阶段, 特征金字塔, 空间金字塔池化, 多尺度, 特征融合, 深度可分离卷积, 深度卷积, 点卷积, 逐点卷积, 通道卷积, blemish, default, diagnosis, feature extract network, dropout, overfitting, detector, classification, location, uncertainty, resnet, three layers, SSD, faster RCNN, feature pyramid, spacail pyramid pool, multi-scale, feature fusion, depth-separable convolution, depth convolution, pointwise convolution, channel convolution		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y	CN 115082416 A (SEEKING INTELLIGENT CONTROL (SHENZHEN) TECHNOLOGY CO., LTD.) 20 September 2022 (2022-09-20) claims 1 and 9	1, 8-38
Y	CN 109492556 A (BEIJING UNIVERSITY OF CHEMICAL TECHNOLOGY) 19 March 2019 (2019-03-19) claims 1 and 3	1, 8-38
Y	庞枫骞等 (PANG, Fengqian et al.). "融合不确定性估计的端到端视频事件检测算法 (Uncertainty Estimation Fused End-to-end Video Event Detection)" 北京航空航天大学学报 (<i>Journal of Beijing University of Aeronautics and Astronautics</i>), 15 February 2023 (2023-02-15), pages 1-16 page 2, paragraph 4	1, 8-38
☒ 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 “D” document cited by the applicant in the international application “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 19 September 2024		Date of mailing of the international search report 27 September 2024
Name and mailing address of the ISA/CN China National Intellectual Property Administration (ISA/CN) China No. 6, Xitucheng Road, Jimenqiao, Haidian District, Beijing 100088		Authorized officer Telephone No.

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	CN 111002980 A (SUZHOU ZHIJIA TECHNOLOGY CO., LTD.) 14 April 2020 (2020-04-14) entire document	1-38
A	CN 110717493 A (ZHEJIANG UNIVERSITY) 21 January 2020 (2020-01-21) entire document	1-38
A	WO 2023021208 A1 (FIVE AI LTD.) 23 February 2023 (2023-02-23) entire document	1-38
A	US 2022335966 A1 (UBTECH NORTH AMERICA RESEARCH AND DEVELOPMENT CENTER CORP. et al.) 20 October 2022 (2022-10-20) entire document	1-38

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.
PCT/CN2024/107018

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)			Publication date (day/month/year)
CN	115082416	A	20 September 2022	None			
CN	109492556	A	19 March 2019	CN	109492556	B	20 September 2022
CN	111002980	A	14 April 2020	CN	111002980	B	30 April 2021
CN	110717493	A	21 January 2020	CN	110717493	B	01 April 2022
WO	2023021208	A1	23 February 2023	WO	2023021208	A4	30 March 2023
				GB	202111986	D0	06 October 2021
US	2022335966	A1	20 October 2022	US	11514927	B2	29 November 2022
				WO	2022218134	A1	20 October 2022
				CN	115605946	A	13 January 2023

A. 主题的分类

G06T7/00(2017.01)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)

G06T7/-

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,CNTEXT,ENTXT,DWPI,VEN,ENTXTC,CNKI,万方,百度学术:瑕疵,缺陷,故障,特征提取,丢弃层,随机失活,过拟合,检测头,类别,分类,位置,不确定性,残差,三层残差,单阶段,两阶段,特征金字塔,空间金字塔池化,多尺度,特征融合,深度可分离卷积,深度卷积,点卷积,逐点卷积,通道卷积,blemish,default,diagnosis,feature extract network,dropout,overfitting,detector,classification,location,uncertainty,resnet,three layers,SSD,faster RCNN,feature pyramid,spacail pyramid pool,multi-scale, feature fusion,depth-separable convolution,depth convolution,pointwise convolution,channel convolution

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
Y	CN 115082416 A (心鉴智控(深圳)科技有限公司) 2022年9月20日 (2022 - 09 - 20) 权利要求1、9	1、8-38
Y	CN 109492556 A (北京化工大学) 2019年3月19日 (2019 - 03 - 19) 权利要求1、3	1、8-38
Y	庞枫鸾等."融合不确定性估计的端到端视频事件检测算法" 北京航空航天大学学报, 2023年2月15日 (2023 - 02 - 15), 第1-16页 第2页第4段	1、8-38
A	CN 111002980 A (苏州智加科技有限公司) 2020年4月14日 (2020 - 04 - 14) 全文	1-38
A	CN 110717493 A (浙江大学) 2020年1月21日 (2020 - 01 - 21) 全文	1-38
A	WO 2023021208 A1 (FIVE AI LIMITED) 2023年2月23日 (2023 - 02 - 23) 全文	1-38

☒ 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

"D" 申请人在国际申请中引证的文件

"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

2024年9月19日

国际检索报告邮寄日期

2024年9月27日

ISA/CN的名称和邮寄地址

中国国家知识产权局
中国北京市海淀区蓟门桥西土城路6号 100088

授权官员

刘倩倩

电话号码 (+86) 028-62967881

PCT/ISA/210 表(第2页) (2022年7月)

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
A	US 2022335966 A1 (UBTECH NORTH AMERICA RESEARCH AND DEVELOPMENT CENTER CORP等) 2022年10月20日 (2022 - 10 - 20) 全文	1-38

国际检索报告
关于同族专利的信息

国际申请号
PCT/CN2024/107018

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	115082416	A	2022年9月20日	无	
CN	109492556	A	2019年3月19日	CN	109492556 B 2022年9月20日
CN	111002980	A	2020年4月14日	CN	111002980 B 2021年4月30日
CN	110717493	A	2020年1月21日	CN	110717493 B 2022年4月1日
WO	2023021208	A1	2023年2月23日	WO	2023021208 A4 2023年3月30日
				GB	202111986 D0 2021年10月6日
US	2022335966	A1	2022年10月20日	US	11514927 B2 2022年11月29日
				WO	2022218134 A1 2022年10月20日
				CN	115605946 A 2023年1月13日