

## 基于卷积神经网络的晶圆缺陷检测与分类算法

祁 鑫, 史 峥

(浙江大学 超大规模集成电路设计研究所, 杭州 310027)

**摘 要:** 针对晶圆检验时扫描电镜图像的缺陷检测和缺陷分类问题, 利用 ZFNet 卷积神经网络对晶圆缺陷进行分类, 并在此基础上, 设计基于块的卷积神经网络缺陷检测算法。为提高准确率和加快速度, 通过改进 Faster RCNN 分类器, 提出另一种检测算法。实验结果表明, 2 种检测算法都能通过学习已标记位置和类型的缺陷数据, 从扫描电镜图像中准确检测并分类多种类型缺陷。

**关键词:** 晶圆检验; 缺陷检测; 缺陷分类; 卷积神经网络; patch-based CNN 分类器; Faster RCNN 分类器

**中文引用格式:** 祁 鑫, 史 峥. 基于卷积神经网络的晶圆缺陷检测与分类算法[J]. 计算机工程, 2018, 44(8): 218-223.

**英文引用格式:** FANG Xin, SHI Zheng. Wafer defect detection and classification algorithms based on convolutional neural network[J]. Computer Engineering, 2018, 44(8): 218-223.

## Wafer Defect Detection and Classification Algorithms Based on Convolutional Neural Network

FANG Xin, SHI Zheng

(Institute of VLSI Design, Zhejiang University, Hangzhou 310027, China)

**[Abstract]** For defect detection and defect classification problems of Scanning Electron Microscope (SEM) images during wafer inspection, this paper applies a Convolutional Neural Network (CNN) called ZFNet to classify wafer defects. On this basis, a patch-based CNN defect detection algorithm is proposed. For better accuracy and higher speed, another detection algorithm is proposed by modifying Faster RCNN classifier. Experimental results show that, by learning from the defects data marked with locations and types, the two detection algorithms can both detect and classify defects of multiple types on SEM images.

**[Key words]** wafer inspection; defect detection; defect classification; Convolutional Neural Network (CNN); patch-based CNN classifier; Faster RCNN classifier

**DOI:** 10.19678/j.issn.1000-3428.0047107

### 0 概述

现代半导体制造过程中大量使用扫描电镜 (Scanning Electron Microscope, SEM) 对晶圆进行扫描从而成像, 然后通过查找并分析扫描图像上异常的图形来查找晶圆上可能造成电路无法正常工作的缺陷。晶圆上的缺陷类型繁多, 为了提高芯片良率, 研发部门要对大量分类后的缺陷作系统性分析, 挖掘特定类型缺陷的成因, 为进一步改进提供方向。由于系统性分析的基础是大量分类好的缺陷数据, 因此如何从大量 SEM 图像中检测出缺陷并且分类是半导体晶圆缺陷检测和自动缺陷分类 (Automatic Defect Classification, ADC) 研究领域的热点<sup>[1]</sup>。

晶圆检验通常分为缺陷检测和缺陷分类两步。传统缺陷检测算法是通过将 SEM 图像和参考图像

进行对比, 取差异较大的区域作为缺陷<sup>[2]</sup>, 其关键在于如何得到准确的参考图像。传统的缺陷分类算法是基于缺陷区域提取特定特征, 再由此设计分类器进行分类<sup>[3]</sup>, 其关键在于提取的特征是否能有效表达特定问题中不同缺陷类型的差异。传统缺陷检测和缺陷分类算法的适应性较差, 通常需要针对特定问题重新设计。

近年来, 卷积神经网络 (Convolutional Neural Network, CNN) 被成功地用于解决不同领域的图像分类和目标识别的问题, 例如将基于 AlexNet 改进的 ZFNet 应用于图像分类<sup>[4]</sup>, 应用 patch-based CNN 进行图像分割<sup>[5]</sup>, 应用 Faster RCNN 进行目标探测<sup>[6]</sup>, 将 DNN (Deep Neural Network) 应用于图像识别<sup>[7]</sup>, 以及开源的深度学习框架 Caffe<sup>[8]</sup>。

**基金项目:** 国家自然科学基金 (61474098, 61674129)。

**作者简介:** 祁 鑫 (1994—), 男, 硕士, 主研方向为晶圆缺陷检测、深度学习; 史 峥, 副教授、博士。

**收稿日期:** 2017-05-08 **修回日期:** 2017-08-23 **E-mail:** 153614495@qq.com

因为具有强大的特征学习能力, 所以 CNN 针对不同问题都能对应学习合适的特征, 具有非常强的适应能力, 如遥感图像<sup>[9]</sup>、人脸图像<sup>[10]</sup>、行人检测<sup>[11]</sup>等。国内也提出很多将 CNN 应用到传统图像识别和检测的工程问题, 例如钢材表面缺陷检测<sup>[12]</sup>、木材缺陷检测<sup>[13]</sup>、水果缺陷检测<sup>[14]</sup>以及手势识别<sup>[15]</sup>, 都得了不错的效果。

本文应用深度学习领域的 CNN 图像分类算法 ZFNet 进行 SEM 图像缺陷分类, 同时基于 ZFNet 缺陷分类器实现一种 patch-based CNN 缺陷检测算法, 该算法能够从 SEM 图像中检测出缺陷的位置和类型。为进一步提高检测效率, 本文根据缺陷检测问题的特殊性, 通过改动 Faster RCNN 中的 RPN 网络结构实现另一种缺陷检测算法。

## 1 ZFNet 缺陷分类器

### 1.1 晶圆缺陷数据

芯片制造的工艺流程及其复杂, 而在不同阶段都要进行晶圆检验, 所以, SEM 图像上的晶圆缺陷类型繁多, 而缺陷类型都需要工程师结合实际情况来定义。根据某晶圆厂提供的数据, 本文模拟生成了一批尺寸为 500 × 500 像素, 包含 9 种不同类型缺陷的 SEM 图像, 并且给出缺陷的具体位置和类型。晶圆缺陷类型依次为 open、short、brighter、darker、impurity、hump1、bite1、hump2、hite2, 其中图像为彩色是因为将 SEM 图像和对应版图各自作为一个通

道进行合并, 从而使图像包含更多信息便于检测与分类。

由于缺陷区域在原尺寸的 SEM 图像只占小部分, 无法将其直接送入 CNN 进行分类, 因此对原尺寸图像进行随机剪裁产生图像, 其中包含缺陷的图像标记为对应缺陷类型, 而不包含缺陷的图像标记为无缺陷, 使用这样数据训练出来的 CNN 分类器能够同时判断是否有缺陷与缺陷具体类型。实际算法是首先使用多种尺寸比例的滑动窗口对原尺寸图像进行滑动剪裁(本文取面积分别为 32<sup>2</sup>、64<sup>2</sup>、128<sup>2</sup>, 长宽比分别为 2:1、1:1、1:2 的 9 种滑动框, 滑动步幅为 16), 然后分别计算该框与缺陷区域的 *overlap*, 采用交并比 (Intersection over Union, IoU) 作为评价函数, 从中随机挑选 *overlap* > 0.4 的 20 张图作为正例, *overlap* < 0.001 的 200 张图作为负例, 再通过水平、垂直翻转和对比度随机变化等方法对数据集进行扩张, 最终得到约 9 × 10<sup>4</sup> 组数据。随机挑选其中 70% 作为训练集, 30% 作为测试集。

### 1.2 ZFNet 结构

基于 AlexNet 微调的 ZFNet 是 2013 ILSVRC 的冠军<sup>[5]</sup>, 具有较快的分类速度和强大的学习适应能力, 是目前图像分类较为常用的一种卷积神经网络。如图 1 所示, 该网络总共 5 层卷积层、2 层全连接层、1 层 softmax 分类层, 其中前两层卷积层连接有局部响应归一化层 (Local Response Normalization, LRN)。

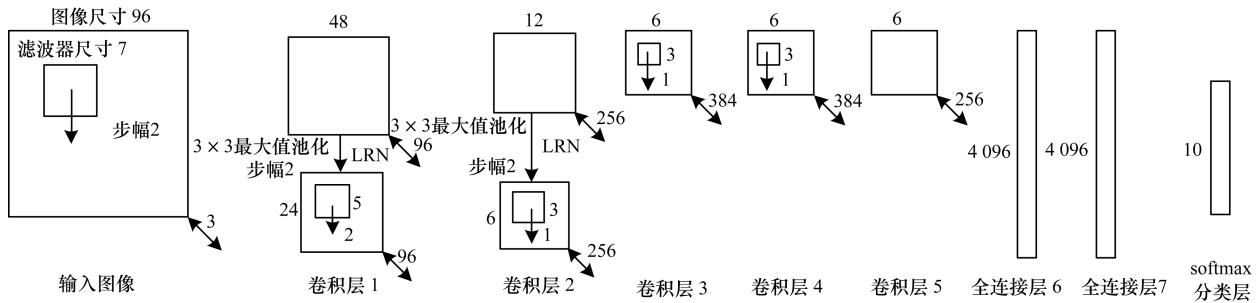


图 1 ZFNet 结构示意图

此外, 该网络采用 ReLU 激活函数替代 Tanh 以加速收敛, 在全连接层采用 dropout 技术减小过拟合。本文 ZFNet 将输入图像尺寸统一调整为 96 × 96 像素, 删去了全连接层 5 的次采样层, 将 softmax 分类层的输出数改为 10 (无缺陷加上 9 类缺陷)。本文 ZFNet 基于 Caffe 架构可以较容易的实现<sup>[8]</sup>, 并采用 SGD (Stochastic Gradient Descent) 算法进行迭代训练, 学习率 *lr* = 0.0001。

### 1.3 测试结果

采用训练好的 ZFNet 分类模型对测试集分类, 得到结果如表 1 所示。

表 1 ZFNet 分类器测试结果

类型	正确数	错误数
有缺陷 (正类)	2 519	12
无缺陷 (负类)	25 330	139

因为测试数据中无缺陷图像占比超过 90%, 所以准确率无法用来衡量算法有效性, 故采用精确率 *P* 和召回率 *R* 的调和平均值 *F*<sub>1</sub> 来综合衡量分类结果, 计算得:

$$P = 2\ 519 / (2\ 519 + 12) = 99.5\%$$

$$R = 2\ 519 / (2\ 519 + 139) = 94.8\%$$

$$F_1 = 2 / (1/P + 1/R) = 97.1\%$$

通过结果可以看出, 将 ZFNet 应用于 SEM 图像

缺陷分类是有效的,而且其还能同时判断图像中是否有缺陷,因此,借助 ZFNet 和有效的剪裁方法就能够同时实现缺陷检测与分类的功能。下面介绍按此思路设计的 patch-based ZFNet 检测器,其不同于传统的晶圆缺陷检测器只能找出缺陷的位置,而是同时检测缺陷并且分类。

## 2 patch-based ZFNet 检测器

### 2.1 检测算法

patch-based CNN 通过用滑动窗口对原图剪裁再送入 CNN 来判断该位置类型,最终将原尺寸图像分割成不同类型的子图<sup>[5]</sup>。如图2所示,参




图2 patch-based ZFNet 检测算法示意图

在训练 patch-based ZFNet 检测器时,数据集是  $500 \times 500$  像素原始尺寸的图像,且包含标记好的缺陷区域和类型。本文通过一系列数据扩张操作,得到1 576 组数据,随机选取 60% 作为训练集,40% 作为测试集。

算法中需要优化的参数有滑动窗口尺寸  $d_{\text{patch-size}}$ 、滑动步幅  $d_{\text{stride}}$ 、概率阈值  $P_{\text{th}}$ 、面积阈值  $S_{\text{th}}$ ,由于无法求出各参数与检测结果的明确关系式,因此采用遍历法优化参数。因为检测到的缺陷尽量正确和尽量检测到所有缺陷是矛盾的,所以将精确率和召回率的调和平均值  $F_1$  作为优化目标,也可根据实际需要调整两者权重满足不同侧重。

### 2.2 测试结果

用训练好的 patch-based ZFNet 检测模型对测试集检测,CPU 计算模式下每张图约耗时 37 s。如果检测到的缺陷与标准答案的  $\text{overlap} > 0.1$  且类型相同,则判为正确,否则判为错误,得到结果如表2所示。

表2 patch-based ZFNet 检测器测试结果

类型	正确数	错误数
有缺陷(正类)	346	108
无缺陷(负类)	132	89

照该算法,本文在已经训练好的 ZFNet 分类器基础上,用  $48 \times 48$  像素的滑动框将  $500 \times 500$  像素的原尺寸图像分割成多块 patch 图像(步幅为 16),依次送入 ZFNet,通过 softmax 层分别计算出各个 patch 属于各类型的概率,忽略掉没有缺陷的概率,按 patch 的顺序排列可以组成 9 张不同类型缺陷的概率分布图。接下来对概率图取阈值进行二值化,再过滤掉面积较小的连通区域,最后用最小矩形分别框覆盖剩下连通区域,即可确定检测到的缺陷的位置和类型。从图2中可以发现,只有 open 概率分布图中有明显一块较亮的区域,即为检测到的 open 缺陷。

由表2中的数据可以计算得到:

$$P = 346 / (346 + 108) = 76.2\%$$

$$R = 346 / (346 + 89) = 79.5\%$$

$$F_1 = 2 / (1/P + 1/R) = 77.8\%$$

其中,正确缺陷的平均  $\text{overlap} = 0.41$ 。

从检测结果来看,该算法基本实现了对 SEM 图像上晶圆缺陷的检测和分类,但是  $F_1$  值较低,缺陷检测位置不准确,检测耗时较长,分析其原因如下:

1) 在检测出错的数据中,缺陷较大的类型易判断错,缺陷较小的容易被漏掉,说明只使用一种尺寸的滑动框很难适应尺寸变化范围较大的缺陷。

2) 滑动框步幅减小则算法耗时平方倍增加,而步幅过长造成缺陷概率分布图分辨率较差,从而检测到缺陷位置准确度较差。

3) 相邻滑动框都有大量重叠,所以,每个区域都被多次重复送入 ZFNet 计算卷积,导致算法耗时较长。

在与上述检测算法相似的图像目标检测领域,近来出现的 Faster RCNN 能够克服以上缺点,取得较好的效果,因此,下文将在 Faster RCNN 的基础上,提出另一种算法,更好地实现晶圆缺陷的检测与分类。

### 3 Faster RCNN 分类器

#### 3.1 Faster RCNN 结构

相比于 patch-based ZFNet 检测算法, Faster RCNN 主要从以下 3 个方面进行了针对性的改进:

1) 针对重复计算卷积的缺点, Faster RCNN 采用先统一计算特征图, 再按 ROI (Region of Interest) 进行映射截取的办法<sup>[6]</sup>。如图 3 所示, 先通过卷积网络对输入图像计算得到其特征图, 因为在输入图像上的 ROI 都能映射到特征图上, 所以从输入图像上按 ROI 割取图像进行卷积运算可以替代为直接从特征图上按 ROI 映射后的范围割取, 从而避免多次重复计算卷积。由于 ROI 的大小形状不一, 而全连接层的神经元连接数是固定的, 因此对割取得到的子特征图, 通过 ROIpool 层次采样到统一尺寸以连接到全连接层。




图 3 ROI 映射示意图

2) 针对滑动窗口尺寸单一的缺点, Faster RCNN 增加了滑动窗口的尺寸类型, 并且增加由一个全卷积网络组成的区域推荐网络 (Region Proposal Network, RPN) 来预判断是否有缺陷<sup>[6]</sup>。本文采用面积分别为  $32^2$ 、 $64^2$ 、 $128^2$ , 长宽比分别为 2:1、1:1、1:2 共 9 种尺寸的滑动窗口, 依次计算其中有缺陷的概率, 再从中筛选出一定数量最有可能有缺陷的区

域, 进行非极大值抑制 (Non-Maximum Suppression, NMS), 最后得到一定数量的候选区域。

3) 针对缺陷检测位置准确度差的缺点, Faster RCNN 在全连接层后连接一个边界回归层 (Boundary Regression) 用来修正缺陷位置<sup>[6]</sup>, 该回归层与 Softmax 分类层并列。

针对本文的缺陷检测问题, 直接套用标准 Faster RCNN 并不能解决问题。因为判断晶圆的缺陷类型通常需要结合缺陷区域周围的图形信息, 而 RPN 在预判断是否有缺陷时还进行了边界回归。虽然能更准确地给出缺陷的位置, 但送入检测网络的特征几乎不包含缺陷周围图形信息, 导致缺陷分类不准。因此, 本文对标准 Faster RCNN 做如下修改:

1) 将 RPN 改为只判断滑动窗口内是否有缺陷, 而不进行边界回归, 也就是只计算所有滑动窗口有缺陷的概率, 选取可能性最大的 1 000 个, 做非极大值抑制, 再选出可能性最大的 100 个进行检测。

2) 将 RPN 卷积层的尺寸加大为  $7 \times 7$ , 加大感受野, 从而在判断滑动框内是否有缺陷时能参考更多的周围信息。

3) 将原尺寸为  $500 \times 500$  像素的图像调整为  $1\,024 \times 1\,024$  像素, 使得滑动窗口尺寸能够适应缺陷大小的变化范围, 也可以根据实际情况来具体调整。

修改后的缺陷检测算法流程如图 4 所示。首先利用卷积网络将输入图像转换成多种特征图, 然后 RPN 根据特征图从滑动窗口中选出最有可能存在缺陷的 ROI, ROI Pooling 层根据 ROI 从特征图中抽取对应特征组成特征向量, 检测网络 (Detection Network, DN) 根据特征向量判断缺陷类型, 并进行边界回归, 最后通过 NMS 和概率阈值对候选缺陷进行过滤即可得到最终缺陷。

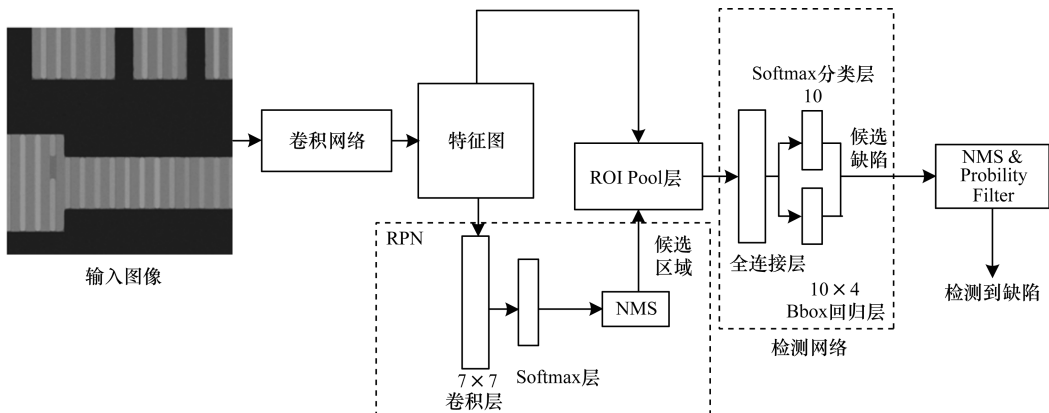


图 4 Faster RCNN 检测算法示意图

### 3.2 模型训练

图 4 中的检测算法也是基于 Caffe 架构实现,因为卷积网络提取的特征类型对相似普遍有效,故其卷积网络的参数是直接迁移上文 ZFNet 分类器的卷积层参数。但是 RPN 和 DN 的参数则需要通过 SGD 方法进行训练,标准 Faster RCNN 提供了分开和联合 2 种训练方式<sup>[6]</sup>。为了节约时间,本文采用联合训练方式,并结合缺陷检测问题的实际情况调整超参数。

在训练 RPN 时,对每张输入图像,因为要计算的滑动窗口数量庞大(9 种尺寸的滑动窗口,滑动步幅 16),所以从中随机抽取 256 个作为训练集,其中正例  $overlap > 0.35$ ,负例  $overlap < 0.001$ ,且正例占比不超过 20%。分类器采用 Softmax 损失函数。

在训练 DN 时,设置 RPN 提供 1 000 个 ROI,从中随机选取 256 个作为训练集,其中正例  $overlap > 0.3$ ,负例  $overlap < 0.001$ ,且正例占比不超过 5%。另外设置学习率  $lr = 0.000 05$ 。分类器采用 Softmax 损失函数,而边界回归采用 SmoothL1Loss 函数。

与 patch-based 检测算法对比,在通过遍历法优化 NMS 和概率阈值  $P_{th}$  时,同样以精确率和召回率的调和平均值  $F_1$  作为优化目标,并且使用相同的训练集和测试集。

### 3.3 测试结果

用训练后的 Faster RCNN 检测模型对测试集检测,CPU 计算模式下每张图约耗时 2 s,采用相同判定标准,得到的检测结果如表 3 所示(其中负类总数与表 2 中总数不同是因为同一张图中可能检测到多个缺陷)。

表 3 Faster RCNN 检测器测试结果

数量	正确数	错误数
有缺陷(正类)	418	36
无缺陷(负类)	157	29

由表 3 的数据计算可得:

$$P = 418 / (418 + 36) = 92.1\%$$

$$R = 418 / (418 + 29) = 93.5\%$$

$$F_1 = 2 / (1/P + 1/R) = 92.8\%$$

其中,正确缺陷的平均  $overlap = 0.78$ 。

从结果来看,该算法各方面都优于 patch-based 检测算法, $F_1$  和  $overlap$  值更高说明检测检测缺陷类型正确且位置准确,而且速度也大大提高(检测一张图像耗时从 37 s 缩小到 2 s)。图 5 为检测缺陷结果

示例,图像中方框标注了缺陷的位置和大小,各缺陷类型的对应概率如表 4 所示。

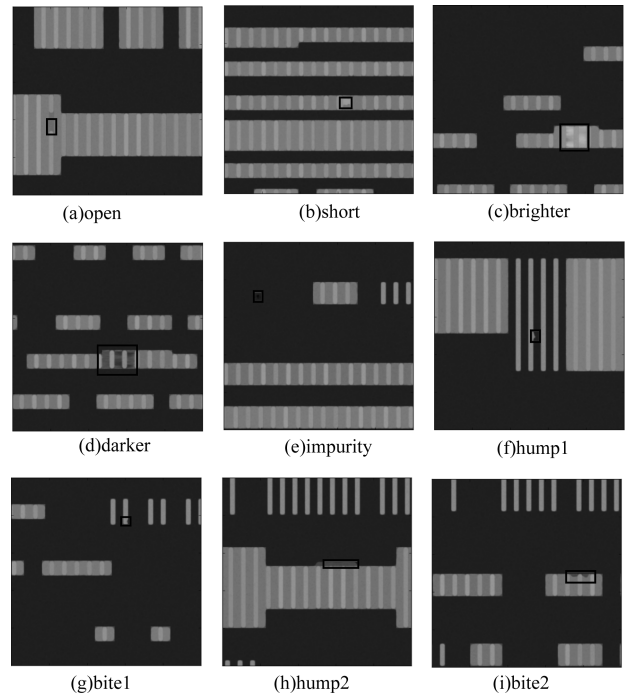


图 5 检测结果示例图

表 4 各缺陷类型的对应概率

缺陷类型	对应概率	缺陷类型	对应概率
open	1.000	hump1	1.000
short	0.998	bite1	0.999
brighter	1.000	hump2	0.998
darker	1.000	bite2	0.999
impurity	1.000		

## 4 结束语

针对晶圆 SEM 图像的缺陷分类问题,本文采用 ZFNet 卷积神经网络对 SEM 图像缺陷区域进行分类。SEM 图像数据包含 9 种缺陷类型以及非缺陷类型,共 10 种类型,测试的 F-score 值达到了 97%,可见本文提出的 ZFNet 缺陷分类算法准确,具有较强数据适应能力。

针对缺陷检测问题,本文基于 ZFNet 缺陷分类算法实现了一种较耗时的 patch-based 检测算法,然后对其重复计算卷积和剪裁不合理的缺点,改进 Faster RCNN 实现了另一种缺陷检测算法,从而快速准确地检测出 SEM 图像中缺陷的位置和类型。SEM 图像包含 9 种缺陷类型,Faster RCNN 检测算法测试结果的 F-score 为 92%,且耗时仅为 patch-based 检测算法的 5%,可见该算法快速、准确,具有较强的数据适应能力。

## 参考文献

- [1] HO B, INOKUCHI M. SEM ADC ( auto defect classification); how it improves the cost of ownership without risk of yield loss [C]//Proceedings of ASMC'07. Washington D. C., USA; IEEE Press, 2007; 293-298.
- [2] SHANKAR N G, ZHONG Z W. Defect detection on semiconductor wafer surfaces [J]. Microelectronic Engineering, 2005, 77(3/4): 337-346.
- [3] KOO H I, CHO N I. New automatic defect classification algorithm based on a classification-after-segmentation framework [J]. Journal of Electronic Imaging, 2010, 19(2): 334-343.
- [4] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C]//Proceedings of ECCV'14. Berlin, Germany; Springer, 2014; 818-833.
- [5] MAGGIORI E, TARABALKA Y, CHARPIAT G, et al. Fully convolutional neural networks for remote sensing image classification [C]//Proceedings of 2016 IEEE International Geoscience and Remote Sensing Symposium. Washington D. C., USA; IEEE Press, 2016; 5071-5074.
- [6] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(6): 1137-1149.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]//Proceedings of International Conference on Neural Information Processing Systems. [S. l.]: Curran Associates Inc., 2012; 1097-1105.
- [8] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding [C]//Proceedings of the 22nd ACM International Conference on Multimedia. New York, USA; ACM Press, 2014; 675-678.
- [9] LIU, Y, ZHONG Y, FEI F, et al. Scene semantic classification based on random-scale stretched convolutional neural network for high-spatial resolution remote sensing imagery [C]//Proceedings of IEEE International Geoscience and Remote Sensing Symposium. Washington D. C., USA; IEEE Press, 2016; 763-766.
- [10] LAWRENCE S, GILES C L, TSOI A C, et al. Face recognition; a convolutional neural-network approach [J]. IEEE Transactions on Neural Networks, 1997, 8(1): 98-113.
- [11] CHEN X, WEI P, KE W, et al. Pedestrian detection with deep convolutional neural network [C]//Proceedings of ACCV'14 Workshops. Berlin, Germany; Springer, 2014; 354-365.
- [12] SOUKUP D, HUBER-MÖRK R. Convolutional neural networks for steel surface defect detection from photometric stereo images [M]//GEORGE B, RICHARD B. Advances in Visual Computing. Berlin, Germany; Springer, 2014; 668-677.
- [13] 徐姗姗, 刘应安, 徐昇. 基于卷积神经网络的木材缺陷识别 [J]. 山东大学学报(工学版), 2013, 43(2): 23-28.
- [14] 刘云, 杨建滨, 王传旭. 基于卷积神经网络的苹果缺陷检测算法 [J]. 电子测量技术, 2017, 40(3): 108-112.
- [15] 江帆, 刘辉, 王彬, 等. 基于 CNN-GRNN 模型的图像识别 [J]. 计算机工程, 2017, 43(4): 257-262.
- 编辑 金胡考
- 
- (上接第 217 页)
- [8] MARLIN B M, ZEMEL R S, ROWEIS S, et al. Collaborative filtering and the missing at random assumption [C]//Proceedings of the 23rd Conference on Uncertainty in Artificial Intelligence. [S. l.]: AUAI Press, 2007; 267-275.
- [9] STECK H. Training and testing of recommender systems on data missing not at random [C]//Proceedings of the 16th ACM International Conference on Knowledge Discovery and Data Mining. New York, USA; ACM Press, 2010; 713-722.
- [10] 王智圣, 李琪, 汪静, 等. 基于隐式用户反馈数据流的实时个性化推荐 [J]. 计算机学报, 2016, 39(1): 52-64.
- [11] 王鹏, 景丽萍. 改进的单类协同过滤推荐方法 [J]. 计算机科学与探索, 2014, 8(10): 1231-1238.
- [12] DEVOOGHT R, KOURTELLIS N, MANTRACH A. Dynamic matrix factorization with priors on unknown values [C]//Proceedings of the 21st ACM International Conference on Knowledge Discovery and Data Mining. New York, USA; ACM Press, 2015; 189-198.
- [13] HE X, ZHANG H, KAN M Y, et al. Fast matrix factorization for online recommendation with implicit feedback [C]//Proceedings of the 39th ACM International Conference on Research and Development in Information Retrieval. New York, USA; ACM Press, 2016; 549-558.
- [14] KOREN Y. Collaborative filtering with temporal dynamics [J]. Communications of the ACM, 2010, 53(4): 89-97.
- [15] CHUA F C T, OENTARYO R J, LIM E P. Modeling temporal adoptions using dynamic matrix factorization [C]//Proceedings of the 13th International Conference on Data Mining. Washington D. C., USA; IEEE Press, 2013; 91-100.
- [16] DIAZ-AVAILES E, DRUMOND L, SCHMIDT-THIEME L, et al. Real-time top-n recommendation in social streams [C]//Proceedings of the 6th ACM Conference on Recommender Systems. New York, USA; ACM Press, 2012; 59-66.
- [17] VOLKOV S M, YU G W. Effective latent models for binary feedback in recommender systems [C]//Proceedings of the 38th ACM International Conference on Research and Development in Information Retrieval. New York, USA; ACM Press, 2015; 313-322.
- [18] OH J, PARK S, YU H, et al. Novel recommendation based on personal popularity tendency [C]//Proceedings of the 11th International Conference on Data Mining. Washington D. C., USA; IEEE Press, 2011; 507-516.
- [19] LAI S, LIU Y, GU H, et al. Hybrid recommendation models for binary user preference prediction problem [EB/OL]. [2017-06-25]. <http://www.nlpr.ia.ac.cn/2011papers/gjhy/gh134.pdf>.
- 编辑 吴云芳