

# Journal of System Simulation

---

Volume 32 | Issue 6

Article 22

---

6-25-2020

## Classification of Chest X-ray Disease Based on Convolutional Neural Network

Huang Xin

*Department of Computer Science and Technology, College of Electronics and Information Engineering,  
Tongji University, Shanghai 201804, China;*

Fang Yu

*Department of Computer Science and Technology, College of Electronics and Information Engineering,  
Tongji University, Shanghai 201804, China;*

Mengdan Gu

*Department of Computer Science and Technology, College of Electronics and Information Engineering,  
Tongji University, Shanghai 201804, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Classification of Chest X-ray Disease Based on Convolutional Neural Network

## Abstract

**Abstract:** The artificial intelligence technology can effectively assist the chest X-ray diagnosis. On the basis of the analysis of Chinese reports of chest X-rays, a labeling method of the thoracic disease classification for the chest abnormal parts is proposed and a dataset of the thoracic disease classification labels is complied. The thoracic disease classification is evaluated through four kinds of convolutional neural networks, AlexNet, VGGNet, ResNet and DenseNet and through three kinds of training methods, direct training, ImageNet pre-training and Chest X-14 pre-training. The result shows that the more complicated convolutional neural network with the more parameters, the better performance in obtaining the key information from the chest X-ray images can be. The model pre-trained by Chest X-14, a large dataset of chest X-ray, has the better result than the other pre-training methods.

## Keywords

Chest X-Rays, Convolutional Neural Network, Thoracic Disease, Reports

## Recommended Citation

Huang Xin, Fang Yu, Gu Mengdan. Classification of Chest X-ray Disease Based on Convolutional Neural Network[J]. Journal of System Simulation, 2020, 32(6): 1188-1194.

# 基于卷积神经网络的 X 线胸片疾病分类研究

黄欣, 方钰, 顾梦丹

(同济大学电子信息工程学院计算机科学与技术系, 上海 201804)

**摘要:** 利用人工智能技术可以有效的辅助胸片的诊断。通过对中文 X 线胸片检查报告文本挖掘, 提出一种以基于异常部位的疾病分类标注方法, 并整理出一个基于中文 X 线胸片检查报告的疾病分类标注数据集。使用 AlexNet, VGGNet, ResNet 及 DenseNet 4 种不同的卷积神经网络, 以及直接训练, ImageNet 预训练和 ChestX-14 预训练 3 种不同预训练方式对胸部疾病分类评估。结果显示更为复杂以及参数更多的卷积神经网络模型, 在 X 线胸片图像关键信息的获取方面有着更大的优势, 同时采用大型 X 线胸片数据集 ChestX-14 预训练的模型效果要明显优于其他预训练。

**关键词:** X 线胸片; 卷积神经网络; 胸部疾病; 检查报告

中图分类号: TP391 文献标识码: A 文章编号: 1004-731X (2020) 06-1188-07

DOI: 10.16182/j.issn1004731x.joss.18-0712

## Classification of Chest X-ray Disease Based on Convolutional Neural Network

Huang Xin, Fang Yu, Gu Mengdan

(Department of Computer Science and Technology, College of Electronics and Information Engineering, Tongji University, Shanghai 201804, China)

**Abstract:** The artificial intelligence technology can effectively assist the chest X-ray diagnosis. On the basis of the analysis of Chinese reports of chest X-rays, a labeling method of the thoracic disease classification for the chest abnormal parts is proposed and a dataset of the thoracic disease classification labels is complied. The thoracic disease classification is evaluated through four kinds of convolutional neural networks, AlexNet, VGGNet, ResNet and DenseNet and through three kinds of training methods, direct training, ImageNet pre-training and Chest X-14 pre-training. The result shows that the more complicated convolutional neural network with the more parameters, the better performance in obtaining the key information from the chest X-ray images can be. The model pre-trained by Chest X-14, a large dataset of chest X-ray, has the better result than the other pre-training methods.

**Keywords:** Chest X-Rays; Convolutional Neural Network; Thoracic Disease; Reports

## 引言

X 线胸片(Chest X-ray, CXR)是一种经济且易于使用的医学成像技术, 多用于胸廓、胸腔、肺组



收稿日期: 2018-10-25 修回日期: 2019-03-11;  
基金项目: 上海市科委项目(16511102800);  
作者简介: 黄欣(1984-), 男, 江西, 博士生, 研究方向为图像处理; 方钰(1977-), 女, 上海, 博士, 教授, 研究方向为机器学习; 顾梦丹(1994-), 女, 广西, 硕士生, 研究方向为图像处理。

织、纵隔、心脏等疾病的早期筛查。一个专业的放射科医生使用 X 线胸片图像可诊断肺炎, 气胸, 心力衰竭等病症。在我国, 一家大型三甲医院每年仅从门诊患者就获得超过 40 000 个 X 线胸片。此外, X 线胸片在我国是常规的体检项目。数据显示, 2013 年我国体检人数有超过 3 亿, 而这个数字还在增加<sup>[1]</sup>。

另一个事实是, 我国的放射科医生工作强度

大, 落后地区医生诊断水平偏低的现象一直存在, 放射科医生的培养周期长, 数量存在缺口, 在未来 10 年内, 状况并不会明显改善。与此同时, 因为疲劳或经验不足产生的误判也屡见不鲜, 且误判多发生在基层以及偏远地区。根据报道显示, 约有 20%~50% 的肺结节在胸部 X 线检查中漏诊或误诊<sup>[2]</sup>。即便是专业的优秀放射科医生, 也会出现 3%~6% 的严重的临床错误<sup>[3]</sup>。所以, X 线胸片自动疾病分类的研究对于辅助放射科医生的诊断有着很强的现实意义。

随着深度学习技术的不断成熟, 卷积神经网络在目标检测等方面有了质的飞跃<sup>[4]</sup>, 与此同时, 诸多大型医学图像数据集的公开, 更是促进了研究者对医学图像研究的热情。在 X 线胸片领域, 同样如此, Chest X-Ray14<sup>[5]</sup>以及 Open-i<sup>[6]</sup>都是很好的研究对象。但是就目前而言, 几乎所有的 X 线胸片数据集都是国外数据集, 虽然胸部疾病分类有一定的共性, 但人种之间差异引起的疾病差异亦是我们不可忽视的问题。这一点从中外放射科医生在描述 X 线胸片的文本中可以得到印证。我国的放射科医生更注重 X 线胸片的表征描述, 国外的放射科医生则更习惯于指出可能患的疾病。另一个不同是我国的放射科医生更习惯按照“胸廓”、“两肺”、“主动脉”、“心影”及“膈面隔角”的部位模板进行描述。国内相关的高质量标注数据集的缺失, 导致深度学习与 X 线胸片疾病分类的研究一直局限在国外的数据集, 无法真正的为我国影像科医生的辅助诊断提供帮助, 而同时存放在国内医院 PACS 系统的海量的 X 线胸片却因为没有标注而无法发挥其真实的研究价值, 基于此现状, 本文尝试使用提取 X 线胸片的中文检查报告的关键信息, 对 X 线胸片进行标注, 然后使用不同的卷积神经网络以及不同的预训练方式对 X 线胸片疾病分类的效果进行评估, 据我们目前所知, 这项研究工作是开创性的。

## 1 相关工作

通过计算机手段辅助胸部疾病诊断的研究一

直备受关注<sup>[7]</sup>, 但在很长一段时间内, 多采用在边缘检测、纹理特征、构建形状模型和模式识别等传统方法进行研究。随着包含超过 10 万张 CXRs 的 ChestX-Ray 14 数据集的公开, 使用深度学习方法对胸部疾病分类进行研究成为了当前的研究热点, 且取得了相当不错的诊断效果。

其中 Wang 在整理发布 ChestX-Ray 14 数据集的同时, 分别评估了 AlexNet<sup>[8]</sup>, GoogleNet<sup>[9]</sup>, VGGNet-16<sup>[10]</sup>以及 ResNet-50<sup>[11]</sup>4 个经典 CNN 模型对胸部疾病分类的效果; 而更为著名的研究则是 Rajpurkar<sup>[12]</sup>提出的 CheXNet 模型, 该模型由修改 DenseNet-121<sup>[13]</sup>的全连接层和损失函数所得, 在胸部疾病分类同样取得了不错的效果, 尤其在肺炎的诊断中准确率达到 88.87%, 超过目前人类的诊断水准; Yao 等<sup>[14]</sup>则选择了另一种深度学习模型 LSTM<sup>[15]</sup>对胸部疾病分类的效果, 结果表明 LSTM 在该任务上表现同样出色。

最新的研究则不仅仅停留在模型的选择上, Kumar 等<sup>[16]</sup>从损失函数出发, 研究最适合胸片疾病分类的损失函数, 并提出一种增强的级联网络用于胸部疾病分类; Guan 等<sup>[17]</sup>则根据 ChestX-Ray 14 病例区域分布特征, 提出了一种全新的 AG-CNN 网络, 该网络由全局分支和局部分支组成, 实验证明, 在针对“Hernia”等在边缘分布的疾病分类中, 取得更好的成绩。Baltruschat<sup>[18]</sup>则充分考虑到非图像特征对疾病分类的影响, 在模型中加入角度及性别等特征, 效果显著。相关的研究不仅仅停留在 ChestX-Ray 14 上, 另一个公开数据集 Open-i 因其含有更丰富的患者信息, 同样受到了研究者的关注, Shin 等<sup>[19]</sup>在该数据集上, 设计了一种级联的网络可以为 CXRs 进行标注, 为 CXRs 的检索提供了思路。wang 最新的成果则是同时在 Open-i 和 ChestX-Ray 14 数据集上, 探索直接根据 CXRs 图像生成对应检查报告的工作, 并设计了相关模型 TieNet<sup>[20]</sup>, 这项工作具有相当的前瞻性。根据不同数据集特点进行融合的工作是弥补单独数据集信息缺失的很好的方法, Gundel 等<sup>[21]</sup>的研究在 PLCO

数据集与 ChestX-ray14 之间展开, 利用 PLCO 数据集对于肺部疾病的详细位置标记, 进一步提升肺部疾病的诊断效果; Islam 等<sup>[22]</sup>将 Open-i, JSRT 数据集以及 shenzhen 数据集三者进行结合, 比较不同 CNN 分类的效果。

最新的研究成果都显示了良好的效果, 但不可否认的是由于数据集本身信息的缺失以及标注的差异, 在胸部疾病分类这项研究工作中, 仍然有很长的路要走。

## 2 数据相关

### 2.1 基于检查报告的 CXR 标注

本文使用的数据来自同济大学同济附属医院, 共 1 877 张 X 线胸片以及对应检查报告。检查报告包含了丰富的诊断信息, 这是我们标注的依据。通过对检查报告的分析, 我们发现检查报告中的描述围绕着“胸廓”、“两肺”、“主动脉”、“心影”及“膈面隔角”5 个部位展开。

完全无异常的健康 X 线胸片的描述为: “两侧胸廓对称。两肺纹理稍增多, 未见明显异常实变影。心影外形及大小如常。两膈面光整, 两肋隔角锐利。”而存在异常的 X 线胸片描述各异。对于发现异常的部位, “胸廓”的描述较为单一, 多为“两侧胸廓不对称”或“两侧胸廓不对称”; “两肺”疾病的描述种类很多, 诸如“左下肺野见少许斑片模糊影”, “右上肺可见小结节状致密影”等, 总体来说可以总结为肺部+表征; “主动脉”的描述多集中是否突出及钙化, 如“主动脉结突出并见钙化灶”; “心影”的描述在于大小是否如常, 异常描述多为“心影饱满”; 对于“膈面隔角”异常描述集中在膈面是否光整及是否有隆起, 而隔角则多为是否锐利。

根据部位是否存在异常作为本研究标注的原则, 对于存在异常的标注, 本研究并不区分异常严重程度以及不同异常的表征。具体来说, 对于“左下肺野见少许模糊影”和“左下肺野见致密影”两种描述, “少许模糊影”和“致密影”都被标注为两肺异常。同理当出现“右膈面模糊”和“右膈面隆

起”两个病理学不同的病征的时候, 本研究也只标注为“膈面隔角”存在异常。最后共获得完全未发现异常的 X 线胸片共 1 217 张, 患病异常 X 线胸片数量为 660 张。其中“胸廓”及“膈面隔角”部位出现异常的数量较少, 而“两肺”及“心影”出现异常数量则偏多。在表 1 中, 总数代表该部位异常的 X 线胸片数量, 重叠代表同时出现多个部位异常的数量, 重叠率为 2 者的比例。

表 1 X 线胸片异常统计  
Tab. 1 Chest X-ray abnormal statistics

异常部位	总数	重叠	重叠率/%
正常	1217	0	0
胸廓	35	33	94.3
两肺	744	440	59.1
主动脉	792	494	62.4
心影	220	201	91.4
膈面隔角	51	21	41.2

在对 X 线胸片图片的标注过程中, 本研究采用 5 维向量  $L=[l_1, l_2, \dots, l_C]$  标注, 其中  $l_C \in \{0, 1\}$ ,  $C=5$ 。 $l_C$  表示是否存在病症, 1 表示存在, 0 表示不存在。如上数据处理示例如图 1 所示。



图 1 X 线胸片标注示例  
Fig. 1 Chest X-ray labeling example

### 2.2 数据预处理

数据预处理分为 4 步: 首先将医院获得的 Dicom 格式的原始 X 线胸片通过无损的方式转换为 PNG 的图片格式, 并将所有图片的尺寸统一调整为 256×256。其次, 对数据进行平衡扩充, 根据表 1 的统计结果对“胸廓”和“膈面隔角”X 线胸片图

片进行复制扩充, 使其占总量比例达到至少 20%。之后对数据进行增强处理, 根据图像的区域分布, 在不影响可能出现异常的部位的情况下, 对图片进行的裁剪以及偏移不大于 $\pm 15$  度的旋转, 得到 X 线胸片图片共为 8 632 张。最后按 80%, 10%, 10% 的比例将所有数据划分为训练, 验证, 测试 3 部分, 并保证验证集以及测试集异常数据的分布均衡。

上述工作后, 共获得训练集 X 线胸片图像数量为 6 912 张, 验证集 X 线胸片数量为 860 张及测试集 X 线胸片数量为 860 张。

### 3 模型

为了充分考虑了模型本身的泛化性, 尽量让对比结果变得更具参考价值。所以本文选用 AlexNet、VGGNet、ResNet 及 DenseNet 四种卷积神经网络对 X 线胸片进行异常分类, 这 4 种模型都曾在不同的数据集及应用场景下得到了很好的验证。除了 AlexNet 网络, 其余 3 个模型都有深度或广度的不同版本, 根据 2.2 节处理后的数据集大小, 分别选取经典 AlexNet、VggNet-16、ResNet-34 及 DenseNet-121 作为最终训练网络模型。为了更好的评估异常分类效果, 我们分别同时对比直接训练, ImageNet 预训练和 ChestX-14 预训练等不同预训练方式对最终结果的影响。

为了适应本研究的数据集训练, 本文统一对 4 种卷积神经网络做了 3 点修改: (1) 把原始模型的输出修改为二进制标签的向量  $c$ , 表明 5 种异常是否存在; (2) 将所有卷积神经网络全连接层替换成 5 维向量, 并使用 sigmoid 函数进行分类; (3) 修改模型的损失函数为未加权交叉熵。修改后的损失函数如公式(1)所示:

$$L(X, y) = \sum_{c=1}^5 [-y_c \log p(Y_c = 1 | X) - (1 - y_c) \log p(Y_c = 0 | X)] \quad (1)$$

式中:  $p(Y_c=1|X)$  为包含  $c$  部位疾病的预测概率; 而  $p(Y_c=0|X)$  为包含  $c$  部位不包含疾病的预测概率。图 2 以 DenseNet 为例展示了模型的详细训练过程。

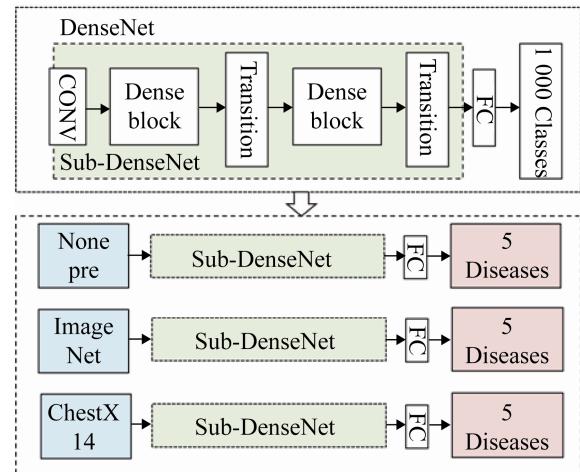


图 2 采用 DenseNet 模型的训练过程  
Fig. 2 Training process using DenseNet model

在训练的过程中, 本文针对 AlexNet 和 VGGNet 随机裁剪为 227\*227 作为输入, 而 ResNet 和 DenseNet 则随机裁剪为 224\*224 作为输入; 同时选择 Adam 作为训练的优化器, BatchSize 值设置为 16, 初始学习率为 0.001。每轮训练后对其在验证集上进行验证并衰减 50%, 所有模型统一训练 500 轮。训练计算采用的是 GPU 是 NVIDIA 发布的 Tesla K40 系列。

### 4 评估

采用 AUC 值对分类效果进行评估, 表 2 对比展示了不同实验的结果。在不同预训练方式的分类结果对比中, 采用“直接训练”方式的 AUC 均值最低, “ImageNet 预训练”次之, 而“ChestX-14 预训练”的效果最佳, 比“直接训练”高出 3.7%, 说明采用其他大型 X 线胸片数据进行预训练, 可有效的提高小型 X 线胸片数据集的疾病分类效果。在不同卷积神经网络模型分类效果的对比中, 我们发现除了“膈面隔角”的 AUC 最大值由 AlexNet 获得之外, 其余 4 个部位的 AUC 最大值都来自 ResNet 和 DenseNet。就 AUC 均值而言, ResNet 和 DenseNet 的值也要明显高于 AlexNet。可见在不同的卷积神经模型中, 更为复杂以及参数更多的模型, 在图片关键信息的获取方面有着更大的优势。

表 2 不同模型测试 AUC 值

Tab. 2 Different models test AUC values

CNN	胸廓	两肺	主动脉	心影	膈面	均值
直接训练						
AlexNet	0.733	0.698	0.812	0.791	0.788	0.764
VggNet	0.748	0.739	0.832	0.821	0.812	0.790
ResNet	0.781	0.763	0.842	0.803	0.813	0.800
DenseNet	0.745	0.795	0.839	0.844	0.822	0.809
均值	0.752	0.749	0.831	0.815	0.809	0.791
ImageNet 预训练						
AlexNet	0.772	0.715	0.895	0.847	<b>0.849</b>	0.816
VggNet	0.801	0.776	0.909	0.813	0.804	0.820
ResNet	0.741	0.813	0.845	0.865	0.831	0.816
DenseNet	0.746	0.765	0.842	0.859	0.826	0.808
均值	0.765	0.767	0.872	0.821	0.828	0.815
ChestX-14 预训练						
AlexNet	0.784	0.731	0.887	0.811	0.837	0.810
VggNet	0.799	0.762	0.912	0.824	0.817	0.822
ResNet	0.751	0.777	<b>0.920</b>	<b>0.875</b>	0.846	<b>0.834</b>
DenseNet	<b>0.804</b>	<b>0.826</b>	0.898	0.867	0.826	0.844
均值	0.784	0.774	0.904	0.844	0.832	<b>0.828</b>

在不同部位的异常分类对比中，相较其他 3 个部位“胸廓”及“两肺”的 AUC 值明显偏低。其中“胸廓”的 3 种不同预训练 AUC 均值分别为 0.752、0.765 和 0.784，“两肺”的 3 种不同预训练 AUC 均值分别为 0.749, 0.767 和 0.774, 这是因为我们获得的所有数据中，仅“胸廓”异常的样本数量只有 2 张，尽管在训练之前通过技术手段对图片进行扩充和增强，在总体样本偏少的情况下，给模型训练带来了难度。样本量最大“两肺”，同样出现了 AUC 值偏低的情况，原因是“两肺”异常的数量虽然较多，但是因为“两肺”在整个 X 线胸片所占的区域最大，异常出现的部位也很复杂。

在对 X 线胸片进行标注的时候，并没有区分异常出现的位置，对于“左下肺野见少许斑片模糊影”，“右上肺可见小结节状致密影”都被标记为了“两肺”部位的异常，这同样给模型的识别带来了难度。和“两肺”同样出现异常较多的“主动脉”AUC 值最高，这是因为“主动脉”部位本身所占区域小，并且异常相对单一，多为“钙化”或“结状”，所以取

得了最好的效果。

最后本文通过生成热图的方式，进一步了解以及评估模型对不同疾病分类的效果。图 3 展示了对比的示例，图 3 中第 1 排为 X 线胸片原图，第 2 排生成的热图，第 3 排为 X 线胸片对应的原始检查报告描述，蓝色部分为模型输出疑似异常的区域。对比发现，“两肺”部位的异常确实范围更广，这印证了表 2 中 AUC 值偏低的原因判断，同时当出现单个部位异常的时候，例如只有“主动脉结突出”时，模型的效果明显更好，但当出现多个部位异常同时伴有部位重叠的时候，模型的效果不如单个部位异常。

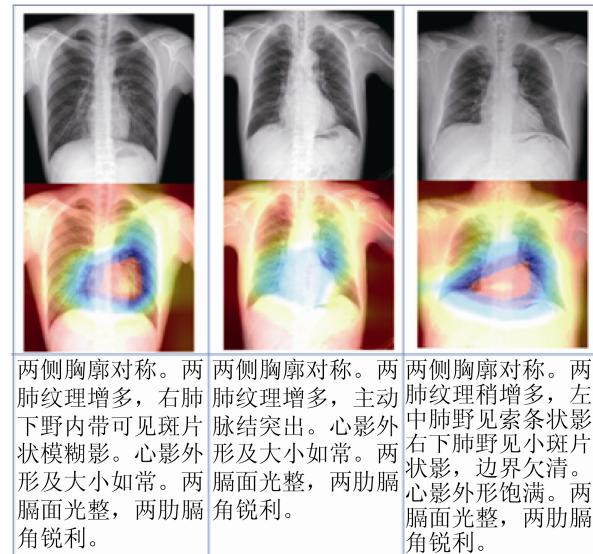


图 3 热图与检查报告对比

Fig. 3 Comparison between heat map and inspection report

## 5 结论

本文从我国放射科医生诊断 X 线胸片的实际情况出发，通过对 X 线胸片检查报告分析整理，提出了一种以“胸廓”、“两肺”、“主动脉”、“心影”及“膈面隔角”为检测目标新的 X 线胸片的疾病分类标注方法，整理出一个基于中文检查报告的 X 线胸片疾病分类标注数据集，共包含完全未发现异常的 X 线胸片共 1 217 张，患病异常 X 线胸片数量为 660 张。同时，本文对比了使用 AlexNet、

VGGNet、ResNet 及 DenseNet 4 种不同的卷积神经网络, 以及直接训练, ImageNet 预训练和 ChestX-14 预训练 3 种不同预训练方式对于异常分类的效果。对比发现采用大型 X 线胸片数据集 ChestX-14 预训练的模型效果要明显优于其他预训练。同时我们发现在不同的卷积神经模型中, 更为复杂以及参数更多的模型, 在 X 线胸片图像关键信息的获取方面有着更大的优势。

本文做的初探性研究对于我国发展人工智能的方式辅助医师进行阅片有很强的现实意义。在我们的研究中, 通过对比发现“胸廓”及“两肺”的 AUC 值整体相较其他 3 个部位明显偏低, 其原因是“胸廓”总体样本偏少的情况下, 给模型训练带来了难度。而“两肺”异常分布区域较广, 并且容易和别的部位重叠。这也给今后的研究指明了方向, 如何针对“两肺”不同区域的更细粒度的标注以及关于重叠区切割分析, 如何将借鉴其他领域的目标检测方法<sup>[23]</sup>通过迁移学习应用在 X 线胸片疾病检测问题, 是本文结束后将继续的研究的主题。

## 参考文献:

- [1] 中华人民共和国国家卫生健康委员会规划发展与信息化司. 2013 年我国卫生和计划生育事业发展统计公报 [EB/OL].(2014-5-30). <http://www.nhc.gov.cn/guihuaxxs/s10742/201405/886f82dafa344c3097f1d16581a1bea2.shtml>.
- [2] Chen H, Shen C, Qin J, et al. Automatic localization and identification of vertebrae in spine CT via a joint learning model with deep neural networks[C]/International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 515-522.
- [3] Bruno M A, Walker E A, Abujudeh H H. Understanding and confronting our mistakes: the epidemiology of error in radiology and strategies for error reduction[J]. Radiographics(S0271-5333), 2015, 35(6): 1668-1676.
- [4] Jiang X, Pang Y, Sun M, et al. Cascaded subpatch networks for effective CNNs[J]. IEEE Transactions on Neural Networks and Learning Systems(S2162-237X), 2018, 29(7): 2684-2694.
- [5] Wang X, Peng Y, Lu L, et al. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases[C]/Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2017: 2097-2106.
- [6] National Institutes of Health. Open-i: Open Access Biomedical Image Search Engine [EB/OL]. (2018-9-30). <https://openi.nlm.nih.gov>.
- [7] Shigehiko K, Kunio D. Computer-aided diagnosis in chest radiography[J]. Computerized Medical Imaging and Graphics(S0895-6111), 2007, 31(4/5): 212-223.
- [8] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]/Advances in neural information processing systems. New York, NY: Curran Associates., 2012: 1097-1105.
- [9] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-10) <https://arxiv.org/abs/1409.1556>.
- [10] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]/Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2015: 1-9.
- [11] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]/Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2016: 770-778.
- [12] Rajpurkar P, Irvin J, Zhu K, et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning [EB/OL]. (2017-12-25) <https://arxiv.org/abs/1711.05225>.
- [13] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]/Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2017: 4700-4708.
- [14] Yao L, Poblenz E, Dagunts D, et al. Learning to diagnose from scratch by exploiting dependencies among labels [EB/OL]. (2017-10-28) <https://arxiv.org/abs/1710.10501>.
- [15] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural computation(S0899-7667), 1997, 9(8): 1735-1780.
- [16] Kumar P, Grewal M, Srivastava M M. Boosted cascaded convnets for multilabel classification of thoracic diseases in chest radiographs[C]/International Conference Image Analysis and Recognition. Cham: Springer, 2018: 546-552.

- [17] Guan Q, Huang Y, Zhong Z, et al. Diagnose like a radiologist: Attention guided convolutional neural network for thorax disease classification [EB/OL]. (2018-01-30) <https://arxiv.org/abs/1801.09927>.
- [18] Baltruschat I M, Nickisch H, Grass M, et al. Comparison of deep learning approaches for multi-label chest X-ray classification[J]. *Scientific reports*(S2045-2322), 2019, 9(1): 1-10.
- [19] Shin H C, Roberts K, Lu L, et al. Learning to read chest x-rays: Recurrent neural cascade model for automated image annotation[C]/Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2016: 2497-2506.
- [20] Wang X, Peng Y, Lu L, et al. Tienet: Text-image embedding network for common thorax disease classification and reporting in chest x-rays[C]/Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2018: 9049-9058.
- [21] Guendel S, Grbic S, Georgescu B, et al. Learning to recognize abnormalities in chest x-rays with location-aware dense networks[C]/Iberoamerican Congress on Pattern Recognition. Cham: Springer, 2018: 757-765.
- [22] Islam M T, Aowal M A, Minhaz A T, et al. Abnormality detection and localization in chest x-rays using deep convolutional neural networks [EB/OL]. (2017-05-27) <https://arxiv.org/abs/1705.09850>.