

00A0

使用混合 CNN-Transformer 架构的胸部 X 光片中胸部疾病的计算机辅助诊断

Sonit Singh

the date of receipt and acceptance should be inserted later

Abstract 医学成像已被用于诊断各种疾病，使其成为有效患者护理的最强大资源之一。由于广泛可用、成本低、辐射少，胸部 X 线检查是诊断各种胸部疾病的最受追捧的放射学检查之一。由于医学成像技术的进步和患者负荷的增加，当前的放射学工作流程面临着各种挑战，包括积压增加、工作时间和诊断错误增加。自动化的计算机辅助诊断系统可以通过提供可操作的见解来解释胸部 X 射线以增强放射科医生的能力，该系统有可能为放射科医生提供第二意见，突出显示图像中的相关区域，从而加快临床工作流程，减少诊断错误，并改善患者护理。在这项研究中，我们应用了一种新颖的架构，使用转换器增强了具有多头自注意力机制的 DenseNet121 卷积神经网络 (CNN)，即 SA-DenseNet121，可以在胸部 X 光片中识别多种胸部疾病。我们在四个最大的胸部 X 射线数据集上进行了实验，即 ChestX-ray14、CheXpert、MIMIC-CXR-JPG 和 IU-CXR。受试者工作特征下面积 (AUC-ROC) 的实验结果表明，通过自我注意力增强 CNN 在通过胸部 X 射线诊断不同的胸部疾病方面具有潜力。所提出的方法有可能支持阅读工作流程，提高效率并减少诊断错误。

Keywords Medical imaging · thoracic diseases · computer-aided diagnosis · chest X-ray · multi-label classification · convolutional neural network · deep learning

1 介绍

随着人工智能 (AI) 技术的兴起，医疗保健部门正在迅速采用以改善临床工作流程以及改善医疗保健专业人

员参与日常任务的实践 [?]。促成这一点的主要因素包括健康记录的数字化、大规模医学数据集的发布、学习算法的进步以及计算能力的提高。医学成像约占医疗保健总数据的 90%。在各种影像学检查中，胸部 X 线成像是目前应用最广泛的放射学检查之一，用于筛查和诊断各种肺部相关疾病，包括气胸、心脏扩大和肺炎。胸部 X 光检查是最受欢迎的胸部影像学检查之一，因为它价格实惠、周转速度快、辐射少，并且在世界各地的医疗保健系统中更广泛地可用。每年大约有 20 亿次胸部 X 光检查，用于各种疾病的筛查、诊断和管理 [?]。根据世界卫生组织的估计，全球三分之二的人口无法获得放射诊断 [?,?]。在世界各地的偏远地区，即使有可用的成像设备，也缺乏放射科医生来解释这些图像 [?]。在极少数情况下，这可能导致患者延迟诊断甚至死亡。随着全球人口的增加，与不断增加的患者扫描数量相比，进入劳动力市场的放射科医生数量相当少。由于工作量的增加，许多放射科医生每天要阅读 100 多份 X 光检查 [?]。鉴于解读胸部 X 光片是一项具有挑战性且耗时的任务，即使是经验丰富的放射科医生也可能由于疾病视觉特征的细微差异而出现主观评估错误。因此，开发计算机辅助诊断和筛查工具至关重要，这些工具可以在胸片上高效准确地检测疾病。这些 CAD 工具通过提供“第二意见”来提供可操作的见解，支持加快临床工作流程，通过突出显示图像中的相关区域来增强放射科医生的信心，并帮助确定阅读列表的优先级，从而帮助放射科医生首先阅读关键病例。

一些研究人员研究了胸部疾病的识别和定位。这些研究大多依赖于卷积神经网络和视觉注意机制。最近，自然语言处理社区已经从循环模型加注意力机制转向仅基于注意力的模型，例如转换器。Transformer 网络在各种 NLP 任务（包括机器翻译、语音识别和语言建模）上优于递归神经网络 (RNN) 和时间卷积网络 (TCN)。变压器网络的关键模块是多头注意力 (MHA)。MHA 块利用多个磁头，每个磁头都采用注意力机制来捕获全局和局部特征。在这项工作中，我们研究了用于胸部疾病诊断的多头自注意力卷积网络。这主要基于以

下几点: (1) 多头注意力网络可以同时捕捉全局和局部特征, 这对胸部疾病的准确识别具有重要意义; (2) 基于自我注意力的模型被证明训练速度更快, 并且可以利用 GPU 并行化; (3) 大多数 NLP 研究都受益于基于 Transformer 的模型。

在这项工作中, 我们开发了计算机辅助诊断系统, 可以自动检测胸部 X 光片中存在的胸部疾病。具体来说, 我们开发了一个基于多头自注意力卷积网络的多标签分类框架, 用于预测四个最大的公开胸部 X 射线数据集上常见胸部疾病的存在, 即 ChestX-ray14、CheXpert、MIMIC-CXR-JPG 和 IU-CXR。图 ?? 显示了来自四个数据集的心脏扩大阳性的胸部 X 光样本。我们提出的常见胸部疾病识别¹模型的框图如图 ?? 所示。

2 相关工作

胸部疾病是指胸部疾病的集合, 包括结构异常、传染病及其并发症 [?]。弗莱施纳学会是一个国际多学科的胸部疾病医学学会, 提供常见胸部疾病清单。我们的目标是在这项研究中研究的四个大规模胸部 X 射线数据集遵循 Fleischner Society 的词汇表, 用于从自由文本放射学报告中获取结构化标签。大多数常见的胸部疾病包括肺不张、心脏扩大、积液、浸润、肿块、结节、肺炎、气胸、实变、水肿、肺气肿、纤维化、胸膜增厚、疝气、心脏纵隔肥大、肺病变、肺混浊和胸膜其他。除了这些异常之外, 还有 Fracture、Support devices 和 No found 的标签。

2.1 胸部 X 线数据集

为了激励医学成像界的研究, 已经发布了各种数据集。近日, 大规模胸部 X 光数据集发布, 应用深度学习解决各种疾病分类任务成为可能。印第安纳大学胸部 X 射线采集 (IU-CXR) 数据集 [?] 包括 7470 张胸部 X 射线及其随附的 3955 份放射学报告。[?] 发布的 ChestX-ray14 数据集包含来自 30805 名独特患者的 112120 张正面胸部 X 光片。每张 X 线照片都标有 14 种常见胸部疾病中的一种或多种类型。在斯坦福医院收集的 CheXpert 数据集 [?] 由来自 65240 名患者的 224316 张胸部 X 光片组成。MIMIC-CXR-JPG 数据集 [?] 由 377110 张胸部 X 光片和使用自然语言处理工具从相关放射学报告中提取的结构化标签组成。随着这些大规模数据集的出现, 研究已经开始应用深度学习模型从胸部 X 射线自动检测胸部疾病。

2.2 胸部疾病检测

早期的计算机辅助检测系统基于经典的机器学习方法。[?] 提出的 SVM 分类器在纹理和形状特征上进行了训练, 以诊断肺部疾病。已经开发了各种专门的算法来检

测特定的胸部疾病, 如肺结节 [?]、肺炎 [?]、心脏扩大 [?,?]、气胸 [?] 和肺癌 [?]。然而, 从胸部 X 光片中准确检测多种疾病的存在仍然是一项具有挑战性的任务。[?] 提供了首批带有疾病标签的大规模公开胸部 X 射线数据集之一。[?] 疾病诊断问题表述为使用特定类别的图像特征转换的多标签分类。[?] 提出了一种深度生成分类器, 通过胸部 X 射线自动诊断胸部疾病, 使模型对噪声具有鲁棒性并减少过拟合。[?] 提出了一个统一的弱监督深度学习框架, 该框架配备了挤压和激发块, 以共同对胸部 X 射线进行胸部疾病分类和定位。为了探索这 14 种疾病之间的相关性, [?] 使用 LSTM 反复解码 DenseNet 的特征向量, 并在每一步产生一个疾病预测。[?] 探索了损失函数来从头开始训练 CNN, 并提出了一个用于多标签分类的增强级联 CNN。[?] 使用预先训练的 ResNet 来提取特征, 并将它们划分为斑块, 这些斑块通过完全连接的网络传递以获得疾病概率图。

除了手工制作的特征外, [?] 还应用了四个卷积神经网络对 ChestX-ray14 数据集中的图像上的胸部疾病进行分类。[?] 提出了 CheXNet, 它以胸部 X 光片为输入, 输出肺炎的概率以及定位图像中最能指示肺炎区域的热图。[?] 引入了 CheXNet, 这是一个基于 DenseNet 的模型, 在 ChestX-ray14 数据集上进行了训练, 该模型在超过 14 种疾病类别上取得了最先进的性能, 并使用 F1 指标超过了放射科医生在肺炎方面的表现。[?] 提出了提取图像和文本表示的 TieNet 模型。[?] 使用卷积网络从胸部 X 光片中提取特征, 然后使用多标签分类算法对提取的特征进行分类。[?] 提出了卷积块注意力模块 (CBAM) 和 shuffleNetV2 的组合来诊断胸部疾病。[?] 开发了一个文本-图像嵌入网络 TieNet, 其基础是不仅 X 射线图像, 而且文本报告都是有用的。

2.3 胸部疾病检测中的注意力模型

鉴于各种胸部疾病在视觉特征上的细微差异, 胸部 X 光多标签分类确实是一个具有挑战性的问题。视觉注意力机制允许模型自适应地聚焦于图像的相关区域, 从而提供模型可解释性的见解, 并提高模型的有效性。[?] 提出了类激活映射 (CAM) 方法, 使深度卷积神经网络能够执行对象定位。[?] 提出了梯度加权类激活映射 (Grad-CAM), 它将特征图与梯度信号相结合, 以产生可视化的解释。[?] 提出了卷积块注意力模块 (CBAM) 的修改版本, 因为与标准注意力机制相比, CBAM 具有轻量级结构。虽然该模型速度很快, 因为采用了轻量级的 CNN 模型, 但这是以牺牲模型有效性为代价的。[?] 提出了一个注意力正则化 DNN 模型, Thorax-Net, 它由分类分支和注意力分支组成。Grad-CAM 方法嵌入到堆叠卷积运算中以执行注意力。[?] 使用 CAM 方法生成热图, 用于解释 CheXNet 预测。[?] 还在注意力分支中使用了 Grad-CAM 方法, 通过分析学习的特征图, 利用了类标签与病理异常相关区域之间的相关性。

¹ 我们将交替使用术语识别和分类。

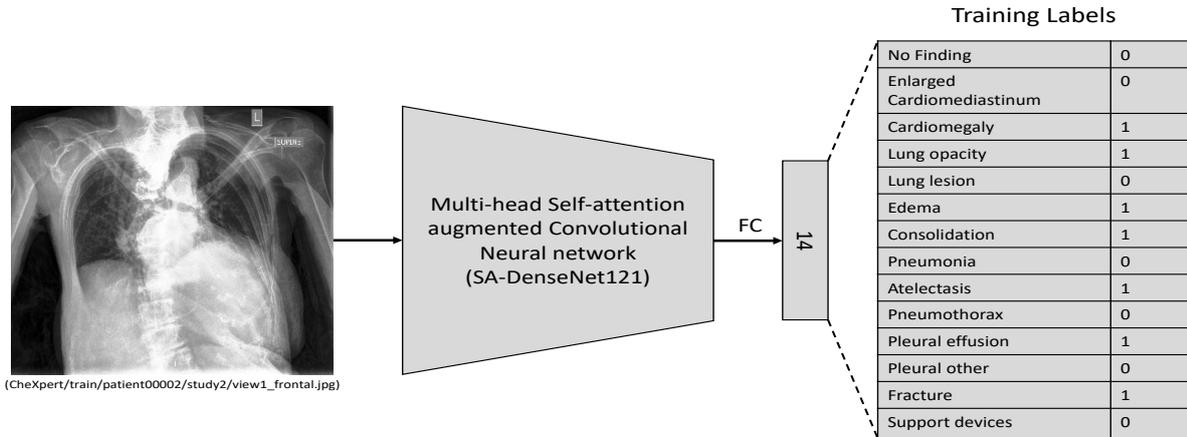


Fig. 1 基于多头自注意力的胸部疾病识别卷积网络框图.

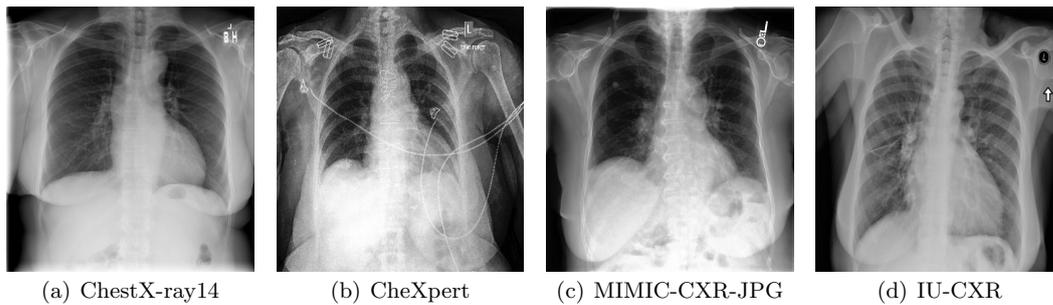


Fig. 2 从四个数据集中的每一个数据集中随机抽样具有心脏扩大的胸部 X 射线: ChestX-ray14、CheXpert、MIMIC-CXR-JPG 和 IU-CXR。

3 方法论

本节介绍我们在胸部 X 光检查中诊断胸部疾病的方法。它提供了选择 DenseNet 作为我们的骨干网络背后的基本原理，以及使用 DenseNet 模型增强自我注意力的必要性。我们还提供各种技术，包括迁移学习、数据增强、NLP 数据标记器以及处理由 NLP 标记器生成的不确定标签。

3.1 卷积神经网络

深度学习 [?] 是机器学习的一个子领域，近年来取得了显著的成功。使之成为可能的各种因素包括学习算法的改进、大规模数据集的发布以及计算能力的提高。深度学习已成为计算机视觉、自然语言处理、语音识别、医学成像和健康信息学等各个领域的标准工具。在计算机视觉领域，分析图像和视频，卷积神经网络 (CNN) 已被证明在提供最先进的结果方面非常强大，甚至在各种基于图像的分类和识别问题上超越了人类的表现。

CNN 将原始数据 (例如图像) 作为输入，并执行一系列卷积和非线性操作，以分层方式学习有关图像的丰富信息，以弥合高级表示和低级特征之间的差距。在训练阶段，CNN 通过前向传递和反向传播程序优化某些损失函数来调整其滤波值 (权重)，以便将输入正确映射到地面实况标签。值得注意的是，CNN 最近被证明在自然图像分类、皮肤癌分类、糖尿病视网膜病变检测等视觉任务中的表现与人类相当或超过人类 [?]。从数据的固有特征中自动提取有用特征的最高级能力使 CNN 成为解决复杂医疗问题的首选。迄今为止，嵌入深度学习算法的 CAD 系统通过有效地生成一系列高质量的诊断解决方案，同时突出可疑特征，有效地为医学疾病检测工作 [?]。

第一个卷积神经网络，即 LeNet-5 [?]，由 3 个卷积层、2 个子采样层和 2 个全连接层组成，应用于文档识别。与其他方法相比，CNN 具有优势，因为它们具有感受野、共享权重和子采样的位移、缩放和失真不变性。然而，正是在 AlexNet 模型中，深度学习的热度在不同领域上升。从那时起，各种 CNN 模型被

提出, 包括 VGG-16、VGG-19、Inception、ResNet 和 DenseNet。在医学成像界广泛使用的最重要的 CNN 模型之一是 DenseNet-121。典型的 DenseNet 模型由多个密集连接的卷积层组成, 这些卷积层改善了信息流和梯度在网络中的流动, 使其更好地收敛并克服了梯度消失的问题。DenseNet 模型使用前一层的输出与当前层的输出的串联。使用所有先前层的特征图作为当前层的输入有助于实现特征重用功能, 尽管具有更大更深的网络, 但有助于减少训练参数的数量。此外, 访问前几层的特征有助于模型在训练期间从数据中学习。鉴于胸部疾病位于医学图像中的小区域, 总体数据显示出相似的全局特征, 局部差异很小。使用 DenseNet-121 作为骨干网络可以帮助识别小的疾病区域, 因为它能够结合局部和全局特征。图 ?? 显示了 DenseNet-121 模型的结构, 该模型由 4 个连续的密集块组成, 由 3 个过渡层连接。DenseNet-121 模型对各种医学成像任务进行了显著改进, 包括分类、检测和分割。

3.2 多头自注意力

卷积网络一直是许多计算机视觉应用的首选范式。卷积层的设计强加了: 1) 通过有限感受野的局部性, 以及; 2) 通过权重分摊进行平移等方差。在设计对图像进行操作的模型时, 这两个属性都被证明是关键的归纳偏差。然而, 卷积核的局部特性使其无法捕获图像中的全局上下文, 这通常是更好地识别图像中对象所必需的。Self-attention [?] 是捕获远程相互作用的最新进展, 但主要应用于序列建模和生成建模任务。在阅读任何文本时, 人类不会在任何地方都给予同样的关注。同样, 在识别图像时, 人类会更加关注某些区域。因此, 有必要对不同的功能给予不同的重视。最近的研究 [?, ?] 证明, 基于 Transformer 的架构可以击败最先进的卷积网络。在 [?] 中, 作者研究了自注意力层如何学习卷积滤波器。他们发现, 具有足够数量的头的多头自注意力层至少可以与任何卷积层一样富有表现力。自我关注背后的关键思想是产生从隐藏单位计算出的值的加权平均值。与池化或卷积算子不同, 加权平均运算中使用的权重是通过隐藏单元之间的相似性函数动态生成的。因此, 输入信号之间的相互作用取决于信号本身, 而不是像卷积那样由它们的相对位置预先确定。特别是, 这允许自我关注在不增加参数数量的情况下捕获远程相互作用。在 [?] 中, 作者开发了一种新颖的二维相对自注意力机制, 该机制在注入相对位置信息的同时保持平移等方差, 使其非常适合图像。所提出的自注意力机制被证明在完全取代卷积方面具有竞争力, 然而在对照实验中, 作者发现, 当他们将自注意力机制与卷积相结合时, 可以获得最好的结果。因此, 作者建议通过将强制局部性的卷积特征图连接到能够建模更长距离依赖关系的自注意力图来增强具有自注意力机制的卷积。

CNN 和自注意力层之间的主要区别在于, 像素的新值取决于图像的每个其他像素。与卷积层相反, 卷积层的感受野是 $K \times K$ 邻域网格, 而自我注意的感受野始终是完整的图像。自注意力层由键/查询大小 D_k 、头

部大小 D_h 、 N_h 个头数和输出维度 D_{out} 定义。该图层由一个键矩阵 $\mathbf{W}_{key}^{(h)}$ 、一个查询矩阵 $\mathbf{W}_{qry}^{(h)}$ 和一个值矩阵 $\mathbf{W}_{val}^{(h)}$ 来参数化, h 以及一个投影矩阵 \mathbf{W}_{out} 用于将所有头组装在一起。缩放点积是最常用的注意力函数之一。

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T/\sqrt{d_k})V \quad (1)$$

其中 Q 、 K 和 V 分别是查询、键和值的矩阵, d_k 表示键的维度。如果 Q 、 K 和 V 相等, 则该函数称为自注意力。与 CNN 中的过滤器类似, 单个注意力不足以学习多个特征的权重。为了使模型能够从不同的表示子空间中学习信息, 提出了 MHSA 机制。图 ?? 显示了变压器架构和多头注意力块。

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W^o \quad (2)$$

$$\text{Head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (3)$$

其中 W^o 、 W_i^Q 、 W_i^K 和 W_i^V 是参数矩阵。

将 CNN 与 MHSA 相结合的优点是可以同时获得两种方法的优点, 并大大减少参数的数量。

3.3 数据增强

深度卷积神经网络在许多计算机视觉任务中表现出卓越的性能。然而, 深度神经网络需要大规模注释的数据集来训练它们。深度神经网络通常在小规模数据集上表现出过拟合, 其中网络在训练数据上可以完美地学习, 但在测试集上不能很好地泛化。包括医学图像分析在内的各种应用领域都没有大规模的注释数据集, 因为它耗时、昂贵, 并且需要专家对医学数据集进行注释。数据增强是在模型训练期间合成生成样本的过程, 有助于防止模型过拟合。数据增强技术在图像中产生变化, 从而帮助模型变得更加鲁棒, 以便在测试图像上很好地泛化, 并提高模型的性能。事实证明, 数据增强在数据集中存在类不平衡的问题中很有用。在这项研究中, 我们使用了不同的增强技术, 包括水平翻转、旋转、缩放、随机裁剪、使用均值和标准差进行归一化。我们没有使用垂直翻转, 因为处理后的图像不是放射科医生在医学扫描中经常看到的。

3.4 迁移学习

迁移学习, 它利用预先训练的模型, 有助于将第一个模型学到的知识转移到第二个模型。迁移学习在提供更好的模型方面起着关键作用, 因为医学数据集的规模较小。为了在我们的实验中使用迁移学习, 我们用预训练的权重初始化了我们的 CNN 模型, 这些权重是在大规模模态图像数据集 (即 ImageNet) 上训练的。

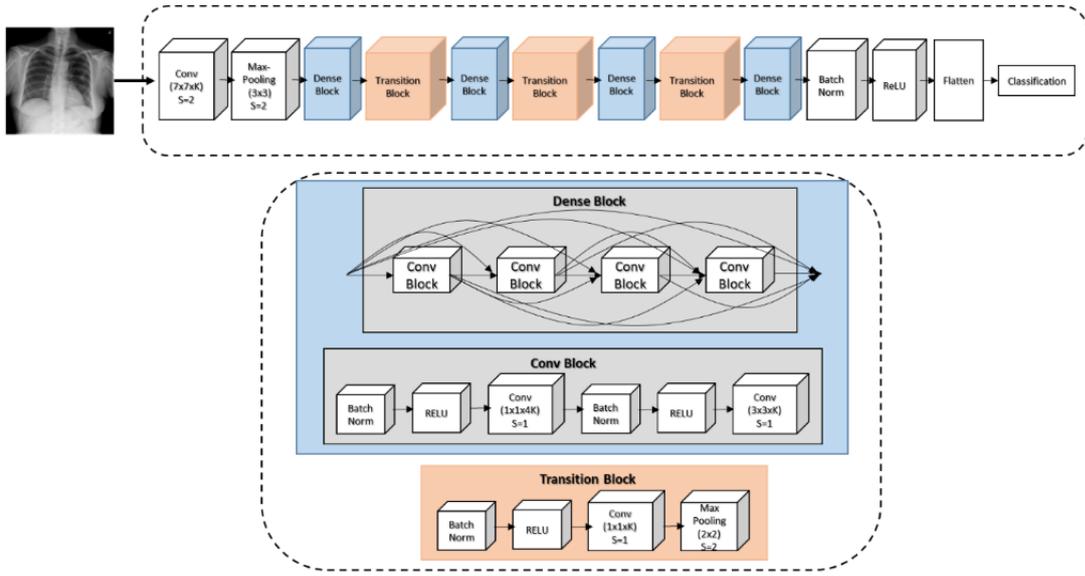


Fig. 3 DenseNet-121 模型架构 [?] .

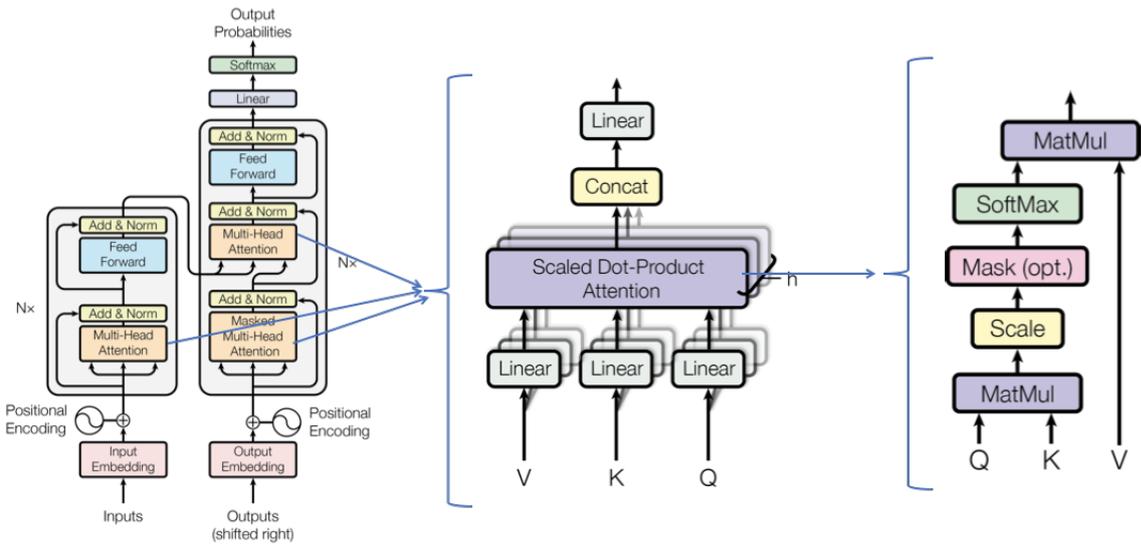


Fig. 4 Transformer 架构、多头注意力块、缩放点积注意力 [?] .

3.5 CheXpert-开源放射学报告贴标器

CheXpert 标记器 [?] 将输入的句子解析为依赖结构，并运行一系列表面和句法规则，以提取胸部放射学报告中 14 临床观察的存在状态。与多位放射科医生在大规模放射学报告数据集上的预言机注释相比，它被评估为具有超过 95% 的总体 F1。图 ?? 显示了放射学报告样本及其不同观察结果的输出。

14 个观测值中的每一个可能有 4 个标签。对于每个观测值，CheXpert 标记器会解析报告并输出 0、1、u 或 blank。如果案文中没有提到观察，则将其保留 blank。如果提及观察表明存在异常，则输出为 1，表示阳性。如果提到观察表明没有异常，则输出为 0，表

示阴性。对于不确定的情况，贴标器输出为 u，表示不确定的情况。

3.6 通过 CheXpert 贴标机处理不确定的标签

CheXpert 贴标机是一个基于规则的系统，为放射学报告中 14 医学观察中的每个标记提供四个标签。这四个标签 blank 未提及，0 表示负面，1 表示积极，-1 表示不确定。[?] 已经提出了各种政策来处理这些不确定的标签。为了在数据集上应用多标签分类算法，可以忽略不确定的标签 (U-Ignore)、映射到负标签 (U-Zeros) 或映射到正标签 (U-Ones)。如果我们应用 U-Ignore 策略

Sample radiology report	Labeler output	Observation
1. Unremarkable cardiomeastinal silhouette. 2. diffuse reticular pattern, which can be seen with a atypical infection or chronic fibrotic change. no focal consolidation. 3. no pleural effusion or pneumothorax. 4. mild degenerative changes in the lumbar spine and old right rib fractures.	No Finding	
	Enlarged Cardiom.	0
	Cardiomegaly	
	Lung Opacity	1
	Lung Lesion	
	Edema	
	Consolidation	0
	Pneumonia	u
	Atelectasis	
	Pneumothorax	0
	Pleural Effusion	0
	Pleural Other	
	Fracture	1
	Support Devices	

Fig. 5 CheXpert 贴标机在样本放射学报告上输出各种观察结果。

(删除所有具有不确定观测值的行)，我们将无法利用整个数据集，从而为我们提供一个减少的数据集。U-Zeros 映射肯定会误导模型训练，因为不确定的情况被视为负情况。为了正确处理不确定的情况，以便放射科医生可以拥有他们的专家外观，将它们映射到 U-One 是合乎逻辑的。有了这个动机，我们将所有不确定的标签映射到 1，在我们的研究中将它们视为积极的标签。

4 实验装置

在本节中，我们将胸部疾病识别表述为多标签分类问题。我们简要概述了四个最大的胸部 X 射线数据集，即 IU-CXR、ChestX-ray14、CheXpert 和 MIMIC-CXR，以及它们在训练、验证和测试方面的标签和分布。然后，我们提供数据分析。最后，我们提供了评估措施来报告模型的性能。

4.1 问题定义

鉴于每个胸部 X 光片都可能存在一个或多个病理（或标签），该任务可以表述为多标签图像分类问题。在多标签设置中， $D = \{(x^{(i)}, y^{(i)}; i = 1 \text{ to } N)\}$ 包含 N 胸部 X 射线的训练数据集，其中每个输入图像 $x^{(i)}$ 都与标签 $y^{(i)} \in \{0, 1\}^{14}$ 相关联，其中 0 和 1 分别对应于阴性和阳性观察结果。在训练期间，目标是训练一个模型，该模型由权重 θ 参数化，该模型 $x^{(i)}$ 映射到预测 $\hat{y}^{(i)}$ ，以便二元交叉熵损失函数在训练集 D 上最小化。在多标签分类问题中，由于我们需要每个标签的概率，因此我们使用下面定义的 sigmoid 激活函数。

$$\hat{y}^k = \frac{1}{1 + \exp(-z_k)}, k = 1, \dots, 14, \quad (4)$$

其中 z_k 是 CNN 最后一层的对数，它输出每个 14 标签的概率。损失函数由下式给出

$$l(\theta) = \sum_{i=1}^N \sum_{k=1}^{14} \log y_k^{(i)} + (1 - y_k^{(i)}) \log(1 - \hat{y}_k^{(i)}) \quad (5)$$

将二元交叉熵（BCE）损失函数最小化，以获得最佳的分类性能。

$$BCE(y, \hat{y}) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (6)$$

其中 N 是类的数量（即 $N = 14$ ）， y_i 是基本真值， \hat{y}_i 是预测概率。

4.2 数据

为了检查我们提出的胸部 X 光片诊断胸部疾病的方法的有效性，我们在 4 具有胸部 X 光片及其标签的大规模数据集上进行了实验。所有数据集都使用基于规则的自然语言处理（NLP）标记器从原始放射学报告中提取 14 常见提及。这些数据集之间的主要区别在于包含不确定性标签和疾病类别。CheXpert 标记器提取了用 u 表示的疾病的不确定发现，而 ChestX 射线 14 则省略了这些提及。这四个数据集有 7 共同的疾病标签：肺不张、心脏扩大、积液、肺炎、气胸、实变和水肿。所有这些数据集都经过去标识化处理，以满足 1996 年美国健康保险流通与责任法案（HIPAA）安全港要求。受保护的健康信息（PHI）将从所有这些数据集中删除。为了提供患者特定信息，使用随机生成的标识符对不同的报告和患者进行分组。

4.2.1 胸部 X 光片 14

ChestX-ray14 是美国国立卫生研究院（National Institute of Health）公开发布的大规模数据集。它包含来自 30,805 独特患者的 112,120 胸部 X 光片。每张图像都标有一个或多个病理，使其成为一个多标签分类问题。与每个胸部 X 光片相关的病理学标签通过应用自然语言处理工具挖掘放射学报告进行注释。数据集中的图像采用 .png 格式，并在不保留纵横比的情况下调整为 1024×1024 。如果胸部 X 光片中没有病理，则标记为“未发现”。疾病标签的准确度预计在 90% 以上。我们将提供的标签作为这项工作中训练和评估的基本事实。

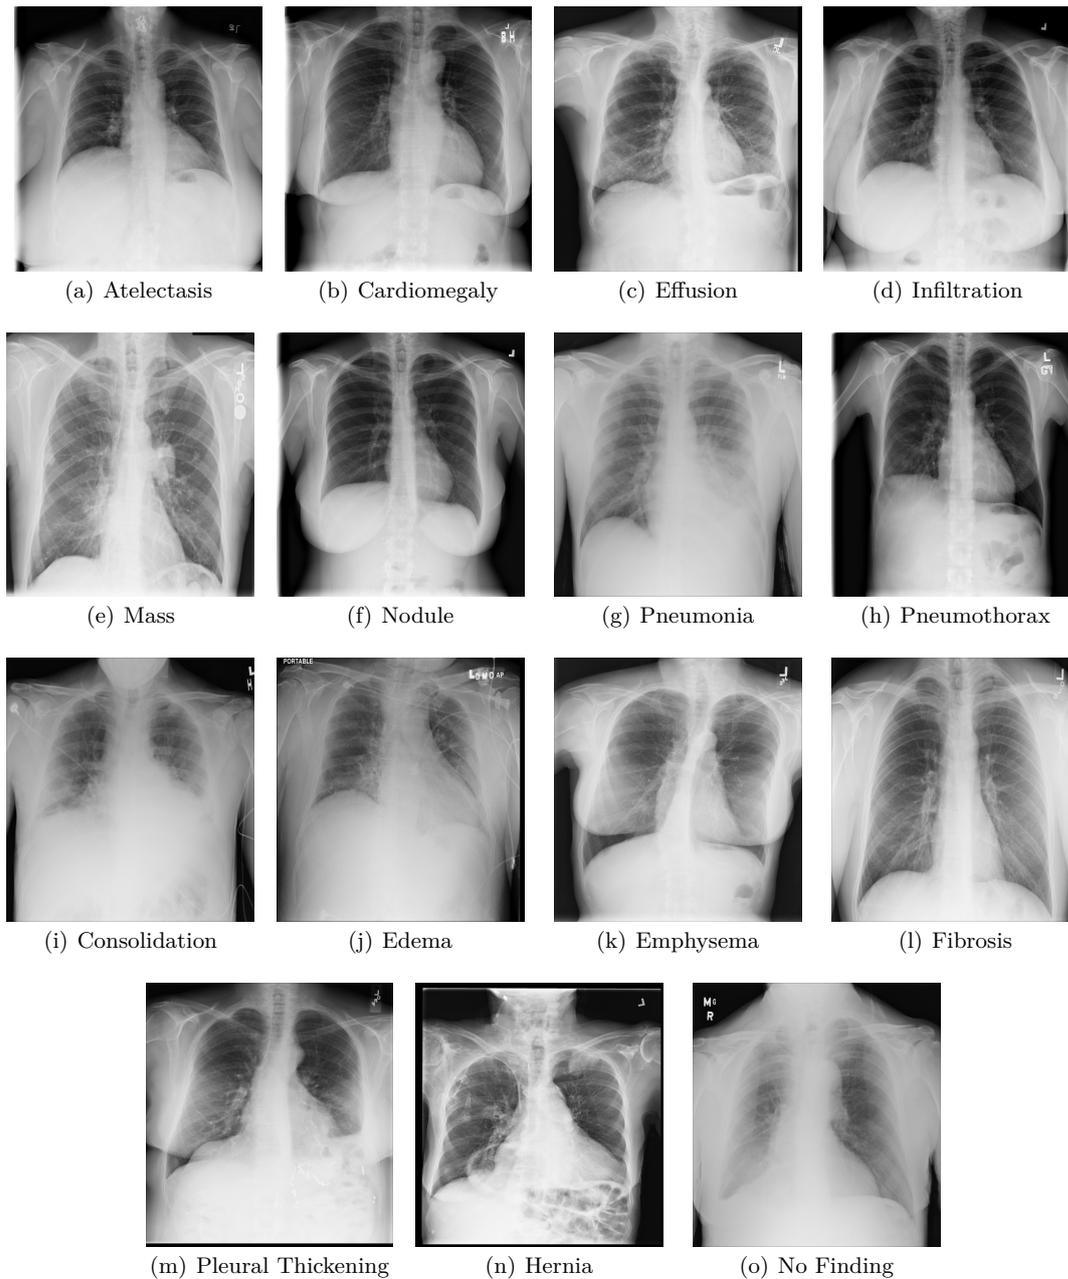


Fig. 6 ChestX-ray14 数据集中每个 14 观测值和“未发现”的样本图像。

数据集分为训练、验证和测试，分别占总数据集的 70%、20% 和 10%。数据集的拆分方式是为了确保训练和测试数据中没有患者重叠。每张图像可能有一个或多个标签，用于肺不张、心脏扩大、积液、浸润、肿块、结节、肺炎、气胸、实变、水肿、肺气肿、纤维化、胸膜增厚和疝气。

继 [?] 的原始工作之后，引入了该数据集，有几项著名的研究使用了相同的数据集。不幸的是，这些研究中的每一项都进行了自己的拆分，因此很难建立一致的基准。近日，官方的训练和测试拆分由 [?] 提供。这些标准的训练和测试拆分是公开的，拆分是按患者而不是

按图像完成的，因此同一患者的图像不会同时出现在训练和测试中，因为它会泄露信息并可能提供虚假结果。表 ?? 根据官方拆分显示了训练、验证和测试拆分中每种病理学的图像数量。提供这种官方的数据拆分，包括训练 (70%)、验证 (10%) 和测试 (20%)，以将结果与现有工作进行比较。在 111120 张胸部 X 光片中，51708 张包含一种或多种病理。其余 60412 张图像被视为正常。数据集中总共有 15 个不同的标签 (14 个常见的病理关键字加上“未发现”)。

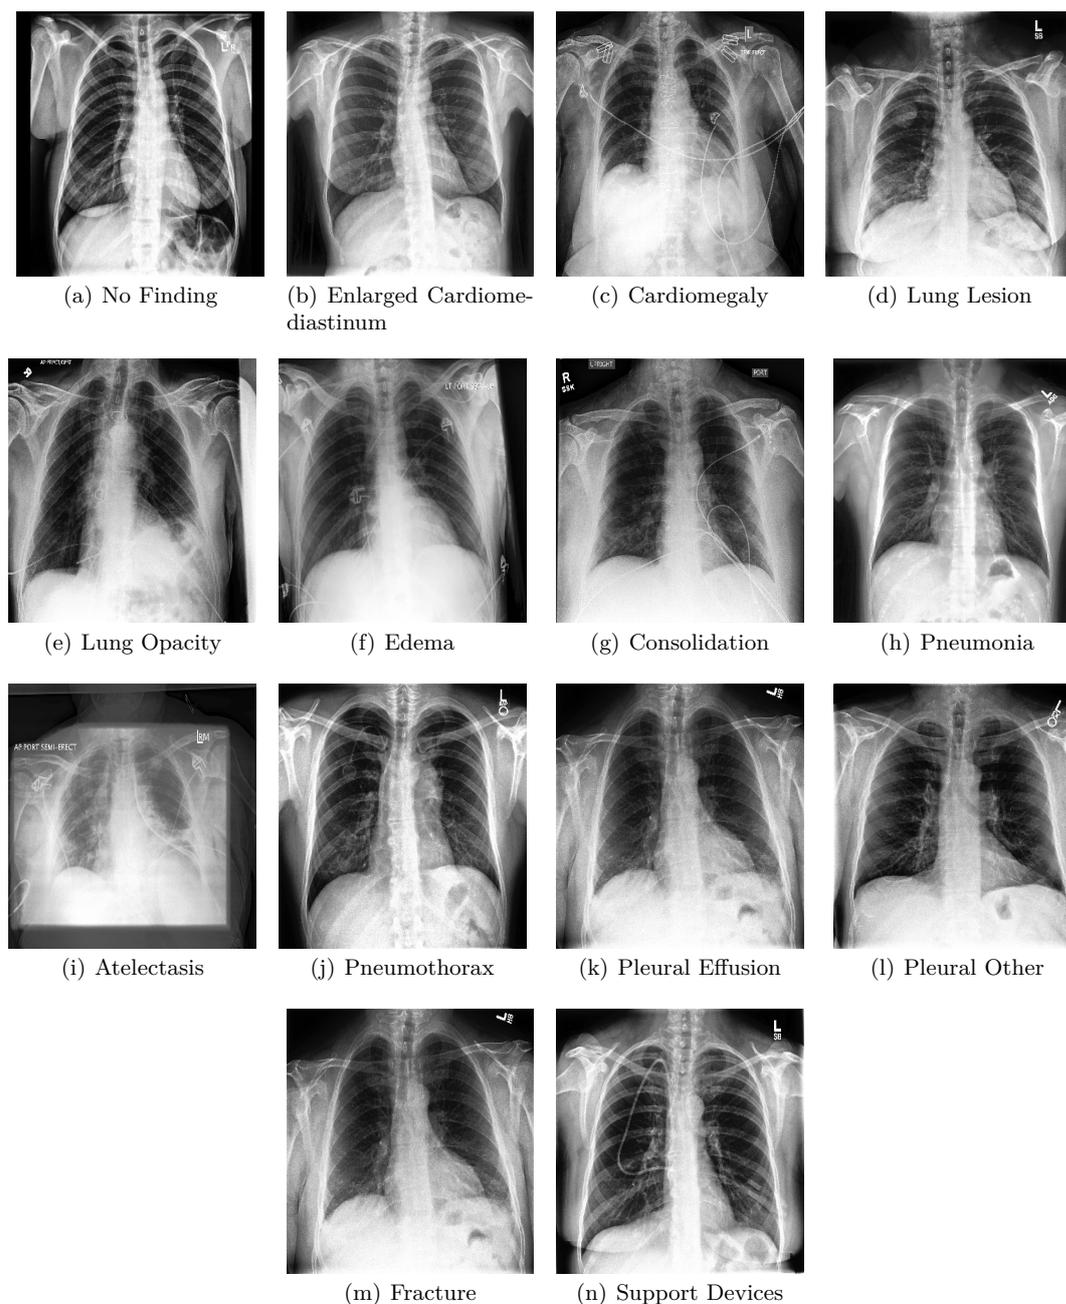


Fig. 7 CheXpert 数据集中每个 14 观测值的示例图像。

4.2.2 切克斯特

CheXpert 数据集 [?] 是一个用于胸片解释的大型公共数据集，由 65,240 患者的 224,316 胸部 X 光片组成，这些 X 光片是根据 2002 年 10 月至 2017 年 7 月期间斯坦福医院在住院和门诊中心的胸部 X 光检查及其相关放射学报告整理的。每张胸部 X 线检查都有相关的放射学报告。应用基于规则的自动 NLP 标记器来提取 14 胸部疾病的存在，包括阳性、阴性或不确定。根据 Fleischner Society 推荐的胸部疾病术语表 [?]，仅 14

观察的标签以结构化标签的形式从放射学报告中提取。每张图像都标有 14 个发现：无发现、心脏纵隔肥大、心脏扩大、肺混浊、肺病变、水肿、实变、肺炎、肺不张、气胸、胸腔积液、胸腔其他、骨折和支持装置。整个数据集分为一组 223,414 研究、一组 234 研究验证集和一组 500 研究的检验集。

每份报告都标记为存在 14 个观测值，为正面、负面或不确定。我们根据报告中的患病率和临床相关性决定了 14 项观察结果，并在适用时符合 Fleischner 协会推荐的词汇表。然后，我们开发了一个基于规则的自动

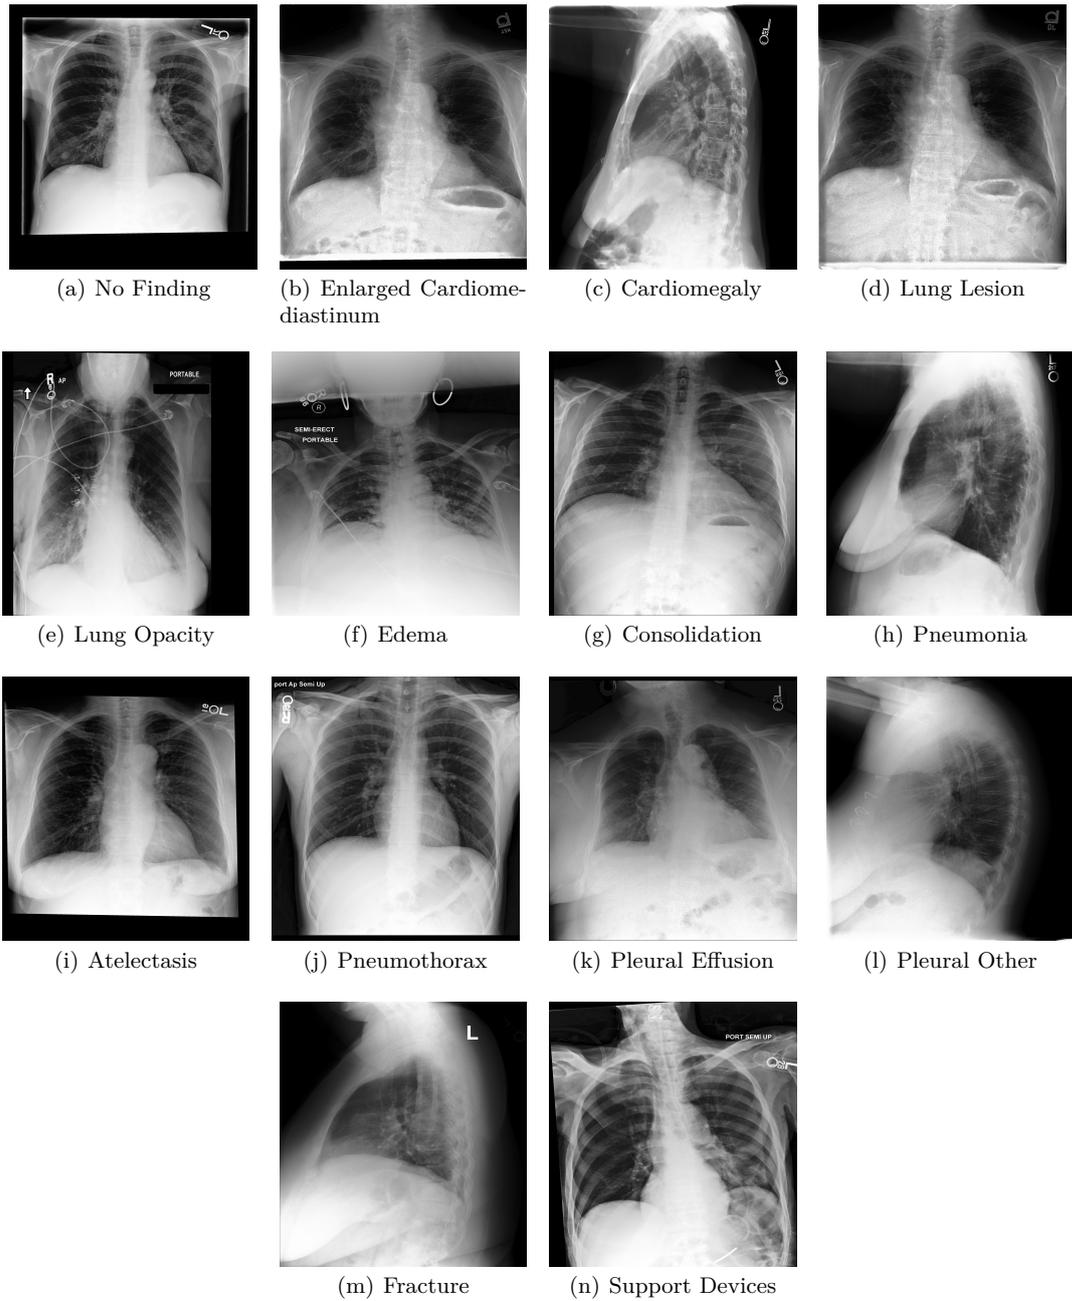


Fig. 8 MIMIC-CXR-JPG 数据集中每个 14 观测值的示例图像。

标记器，从自由文本放射学报告中提取观察结果，用作图像的结构化标签。标记器分为三个不同的阶段：提及提取、提及分类和提及聚合。在提及提取阶段，标记器从放射学报告的“印象”部分的观察列表中提取提及，该列表总结了放射学研究中的主要发现。在提及分类阶段，提及的观测值分为负面、不确定或正面。在提及聚合阶段，我们使用每次提及观测值的分类来得出 14 个观测值的最终标签（空白表示未提及，0 表示负面，-1 表示不确定，1 表示正面）。表 ?? 显示了正、不确定和

负属性的每个观测值的图像数量。表 ?? 显示了训练、验证和测试拆分中每种病理的图像分布。

4.2.3 模仿-CXR-JPG

MIMIC-CXR-JPG 数据集 v2.0.0 [?] 是一个大型公开数据集，由 377,110 胸部 X 光图像和来自 63,478 患者的 227,827 报告组成。该数据集完全来源于 MIMIC-CXR 数据集 [?]，具有 DICOM 格式的胸部 X 光片以及随附的文本放射学报告。MIMIC-CXR-JPG 中图像的结构化标签是使用 CheXpert 从自由文本放射学报告

Table 1 胸部 X 射线在 Chest X-ray14 数据集中训练、验证和测试拆分中的分布

Pathology	Training	Validation	Testing	Total
Atelectasis	6,168	2,112	3,255	11535
Cardiomegaly	1,273	434	1,065	2772
Effusion	6,537	2,122	4,648	2516
Infiltration	10,244	3,538	6,088	19871
Mass	3,012	1,022	1,712	5746
Nodule	3,501	1,207	615	6323
Pneumonia	655	221	477	1353
Pneumothorax	1,939	698	2,661	5298
Consolidation	2,114	738	1,815	4667
Edema	1,027	361	925	2303
Emphysema	1,075	348	1,093	2516
Fibrosis	963	288	435	1686
Pleural Thickening	1,693	549	1,143	3385
Hernia	105	36	86	227
No Finding				60412
Totals	78,468	11,219	22,433	112,120

Table 2 CheXpert 数据集中 14 个观测值的阳性、不确定和阴性研究分布

Pathology	Positive	Uncertain	Negative	Total
No Finding	16,627	0	171,014	187,641
Enlarged Cardiomedastinum	9,020	10,148	168,473	187,641
Cardiomegaly	23,002	6,597	158,042	187,641
Lung Lesion	6,856	1,071	179,714	187,641
Lung Opacity	92,669	4,341	90,631	187,641
Edema	48,905	11,571	127,165	187,641
Consolidation	12,730	23,976	150,935	187,641
Pneumonia	4,576	15,658	167,407	187,641
Atelectasis	29,333	29,377	128,931	187,641
Pneumothorax	17,313	2,663	167,665	187,641
Pleural Effusion	75,696	9,419	102,526	187,641
Pleural Other	2,441	1,771	183,429	187,641
Fracture	7,270	484	179,887	187,641
Support Devices	105,831	898	80,912	187,641
Totals	452,269	117,974	2,056,731	2,626,974

Table 3 CheXpert 数据集中训练、验证和测试拆分中胸部 X 射线的分布

Pathology	Training	Validation	Testing	Total
No Finding	22,334	38	47	22,419
Enlarged Cardiomedastinum	23,146	109	55	23,310
Cardiomegaly	35,005	68	82	35,155
Lung Lesion	10,655	1	19	10,675
Lung Opacity	110,925	126	254	111,305
Edema	65,070	45	160	65,275
Consolidation	42,422	33	103	42,558
Pneumonia	24,756	8	53	24,817
Atelectasis	66,955	80	160	67,195
Pneumothorax	22,547	8	46	22,601
Pleural Effusion	97,581	67	234	97,882
Pleural Other	6,160	1	16	6,177
Fracture	9,656	0	26	9,682
Support Devices	116,813	107	267	117,187
Totals	222,914	234	500	223,648

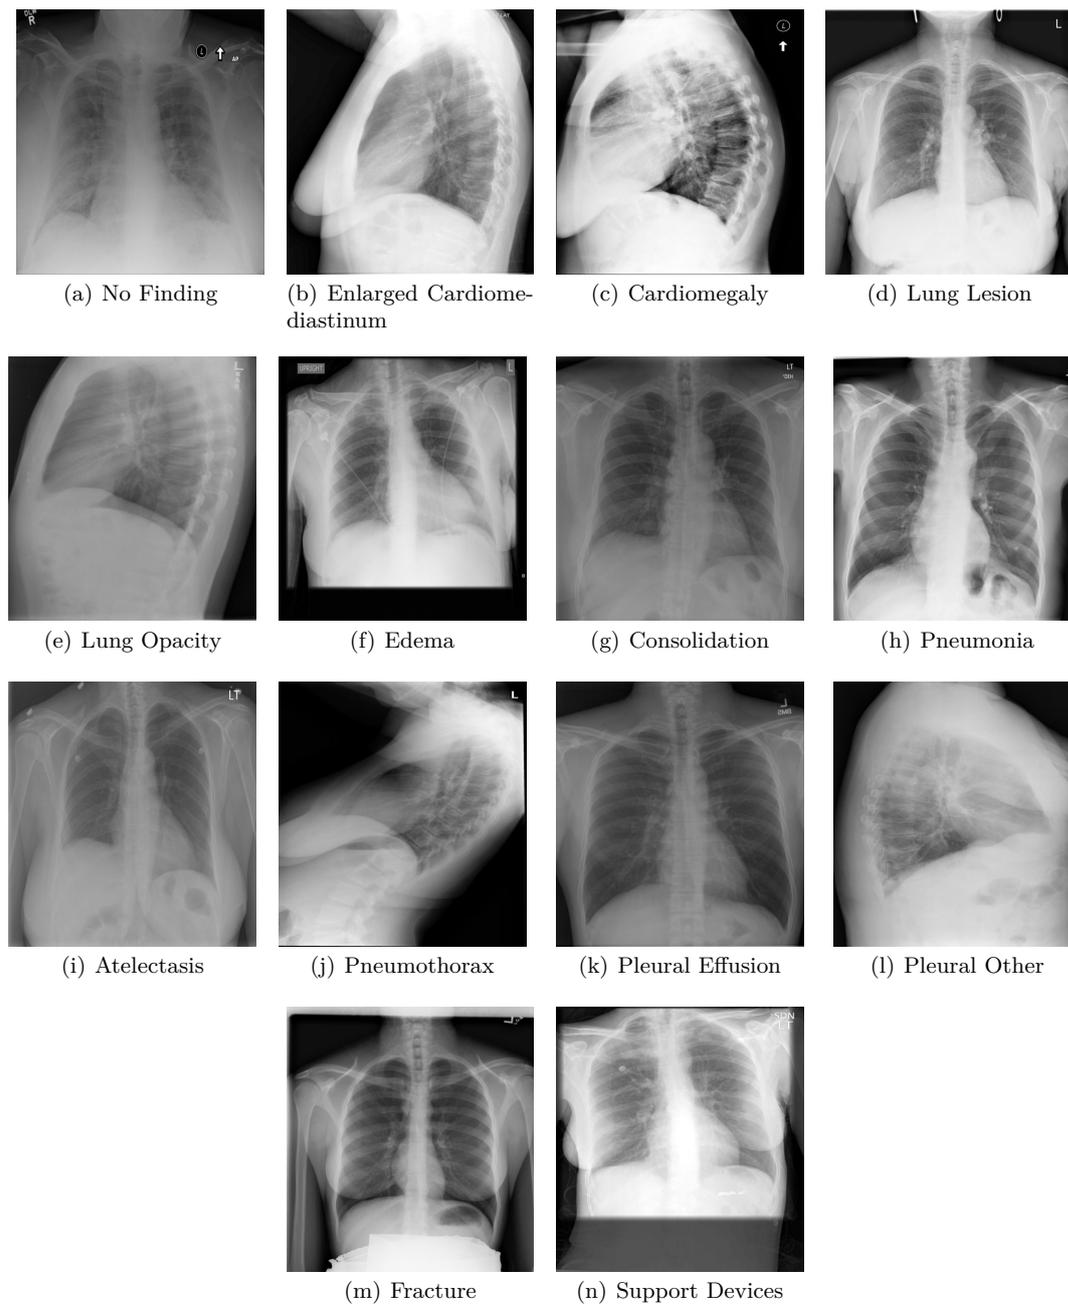


Fig. 9 IU-CXR 数据集中每个 14 观测值的样本图像。

中标记的。CheXpert 是一个基于 NegBio 的开源规则工具，分为三个阶段：提取、分类和聚合。CheXpert 的输出被保存到一个 CSV 文件中，每个研究一行，每个发现一列。每个图像都标记为“正面”、“负面”和“不确定”（空白表示未提及，0 表示负面，-1 表示不确定，1 表示正面）。

4.2.4 IU-CXR 扫描

印第安纳大学胸部 X 射线采集 (IU-CXR) 是印第安纳大学收集的公共放射学数据集，其中包含 7,470 胸部 X

射线图像和 3,955 放射学报告。每份放射学报告都与一对具有正面和侧面视图的图像相关联。报告采用 XML 格式，并包含预先解析的部分。每份放射学报告都由比较、适应症、发现和印象部分组成。“比较”部分指示当前影像学检查是否与患者以前的任何影像学检查进行比较。适应症部分列出了患者信息，例如年龄、性别和相关临床信息，包括任何现有的疾病和症状。“结果”部分指示图像中的每个区域是正常、异常还是潜在异常。印象部分总结了研究结果、患者临床病史和适应症，被

Table 4 有关 MIMIC-CXR 数据集图像的统计信息分为训练集、验证集和测试集。

	Training	Validation	Testing
Number of images	368,960	2,991	5,159
Number of studies	222,758	1,808	3,269
Number of patients	64,586	500	292

Table 5 MIMIC-CXR-JPG 数据集中训练、验证和测试拆分中胸部 X 射线的分布

Pathology	Training	Validation	Testing	Total
No Finding	141,239	1,129	984	143,352
Enlarged Cardiomeastinum	21,926	214	487	22,627
Cardiomegaly	70,768	625	1,422	72,815
Lung Lesion	12,468	123	237	12,828
Lung Opacity	80,059	596	1,684	82,339
Edema	54,100	478	1,395	55,973
Consolidation	20,521	184	473	21,178
Pneumonia	53,858	410	1,104	55,372
Atelectasis	78,593	671	1,319	80,583
Pneumothorax	15,524	124	171	15,819
Pleural Effusion	83,086	744	1,714	85,544
Pleural Other	4,679	33	145	4,857
Fracture	8,445	39	174	8,658
Support Devices	82,240	731	1,463	84,434
Totals	368,945	2,991	5,159	377,095

认为是放射学报告中最具指示性和最重要的决策部分。数据集已完全去标识化，无法提取患者特定信息。

鉴于该数据集没有可用的观察标签，我们应用 CheXpert，NLP 标记器从放射学报告中获取结构化标签。我们将检查结果和印模部分连接起来，形成放射学报告的文本，并对其应用 CheXpert 贴标机。CheXpert 贴标器以 *blank* 的形式给出输出，报告中未提及观察结果；0 为负数；1 为阳性；*u* 对每个 14 观察结果的不确定提及。我们应用 *U - Zeros* 映射将 *blank* 标签转换为 0，并应用 *U - Ones* 映射将 *u* 转换为 1。

4.3 数据分析

在我们开始数据建模之前，我们进行了数据分析，以更仔细地观察四个大规模胸部 X 射线数据集中每个数据集的病理分布。观测点渗透在数据集中的样本数最多。然而，疝气在整个 ChestX-ray14 数据集中只有 227 个样本。图 ?? 显示了 14 种病症中每一种患者年龄分布的箱形图。图 ?? 给出了直方图，显示了 ChestX-ray14 数据集中患者年龄的分布。图 ?? 显示了患者年龄的性别分布。这表明男性患者的数量多于女性患者。[?] 研究胸部 X 射线数据集中的性别失衡，但医学成像数据集中的性别失衡可能会产生有偏差的分类器。他们建议，拥有性别平衡的数据集以及多样性可以提高 CAD 系统的泛化能力。图 ?? 显示了 ChestX-ray14 数据集中病理共生的弦图。这表明许多病理可以同时发生，因此单次胸部 X 光检查可以与多个病理标签相关联。例如，肺不张通常与浸润和积液一起发生。我们在剩下的三个数据集中看到了类似的模式。

4.4 评估指标

多标签分类问题与标准分类问题的不同之处在于，模型输出每种病理的概率。因此，我们使用受试者工作特性下面积 (AUC) 作为衡量我们所提出的模型性能的指标。AUC 测量受试者工作特征 (ROC) 曲线下的面积，其中 *x* 轴和 *y* 轴分别是假阳性率 (FPR) 和真阳性率 (TPR)。ROC 曲线描述了真阳性和假阳性之间的相对权衡。AUC 值的范围为 0 到 1，可以解释为模型对随机选择的正实例的评分高于随机选择的负实例的概率。AUC 分数越高，意味着分类器越好。此外，由于标准准确性指标在不平衡数据集的背景下与显著困难相关，因此 AUC 评分为 14 个疾病类别中的每一个类别提供了强大的模型性能衡量标准。

5 实验结果

本节重点介绍了模型训练过程中的各种参数，并介绍了四个胸部 X 射线数据集的实验结果。

5.1 模型训练

该模型是用 Python 实现的，有 PyTorch [?] 和 Tensorflow 库 [?]。我们还使用 Pandas [?] 库来读取 csv 文件，使用 OpenCV [?] 来读取和处理图像，并使用 Scikit-learn [?] 来构建模型评估的方法，包括受试者工作特征 (AUC) 分数的下面积。

我们使用 DenseNet-121 作为主干卷积神经网络。我们使用预训练模型的权重初始化 CNN，在大规模

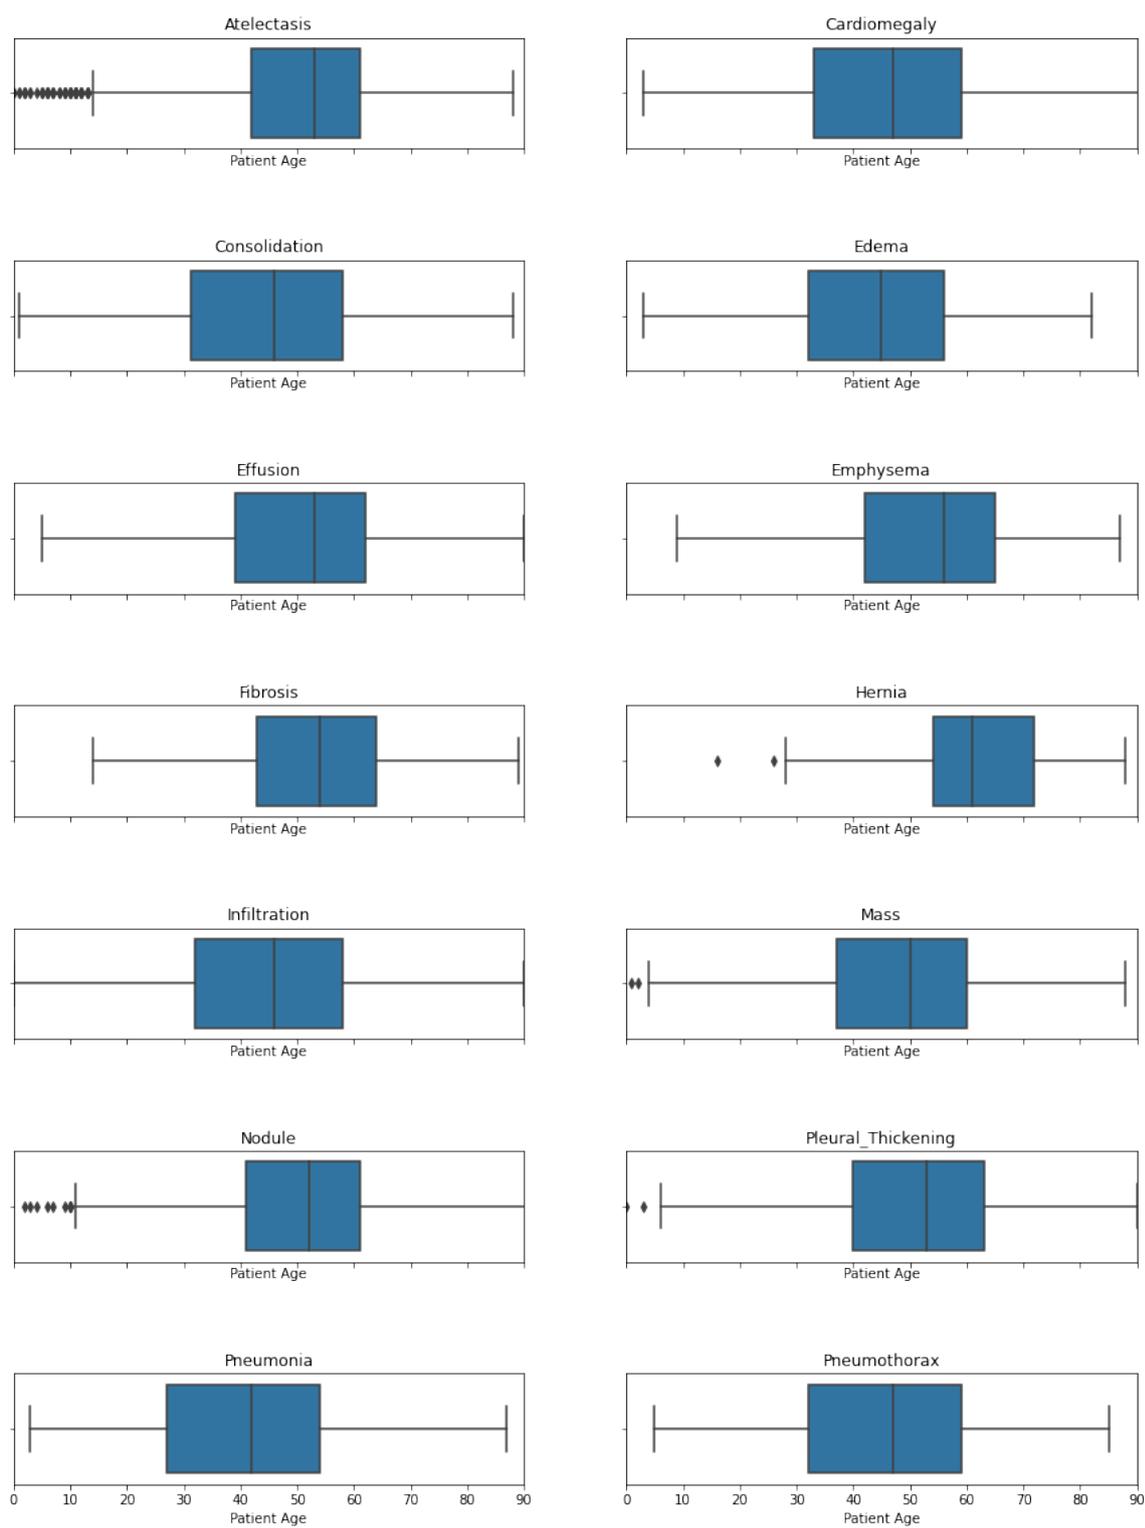


Fig. 10 用于显示 ChestX-ray14 数据集中不同病理的年龄分布的箱线图。

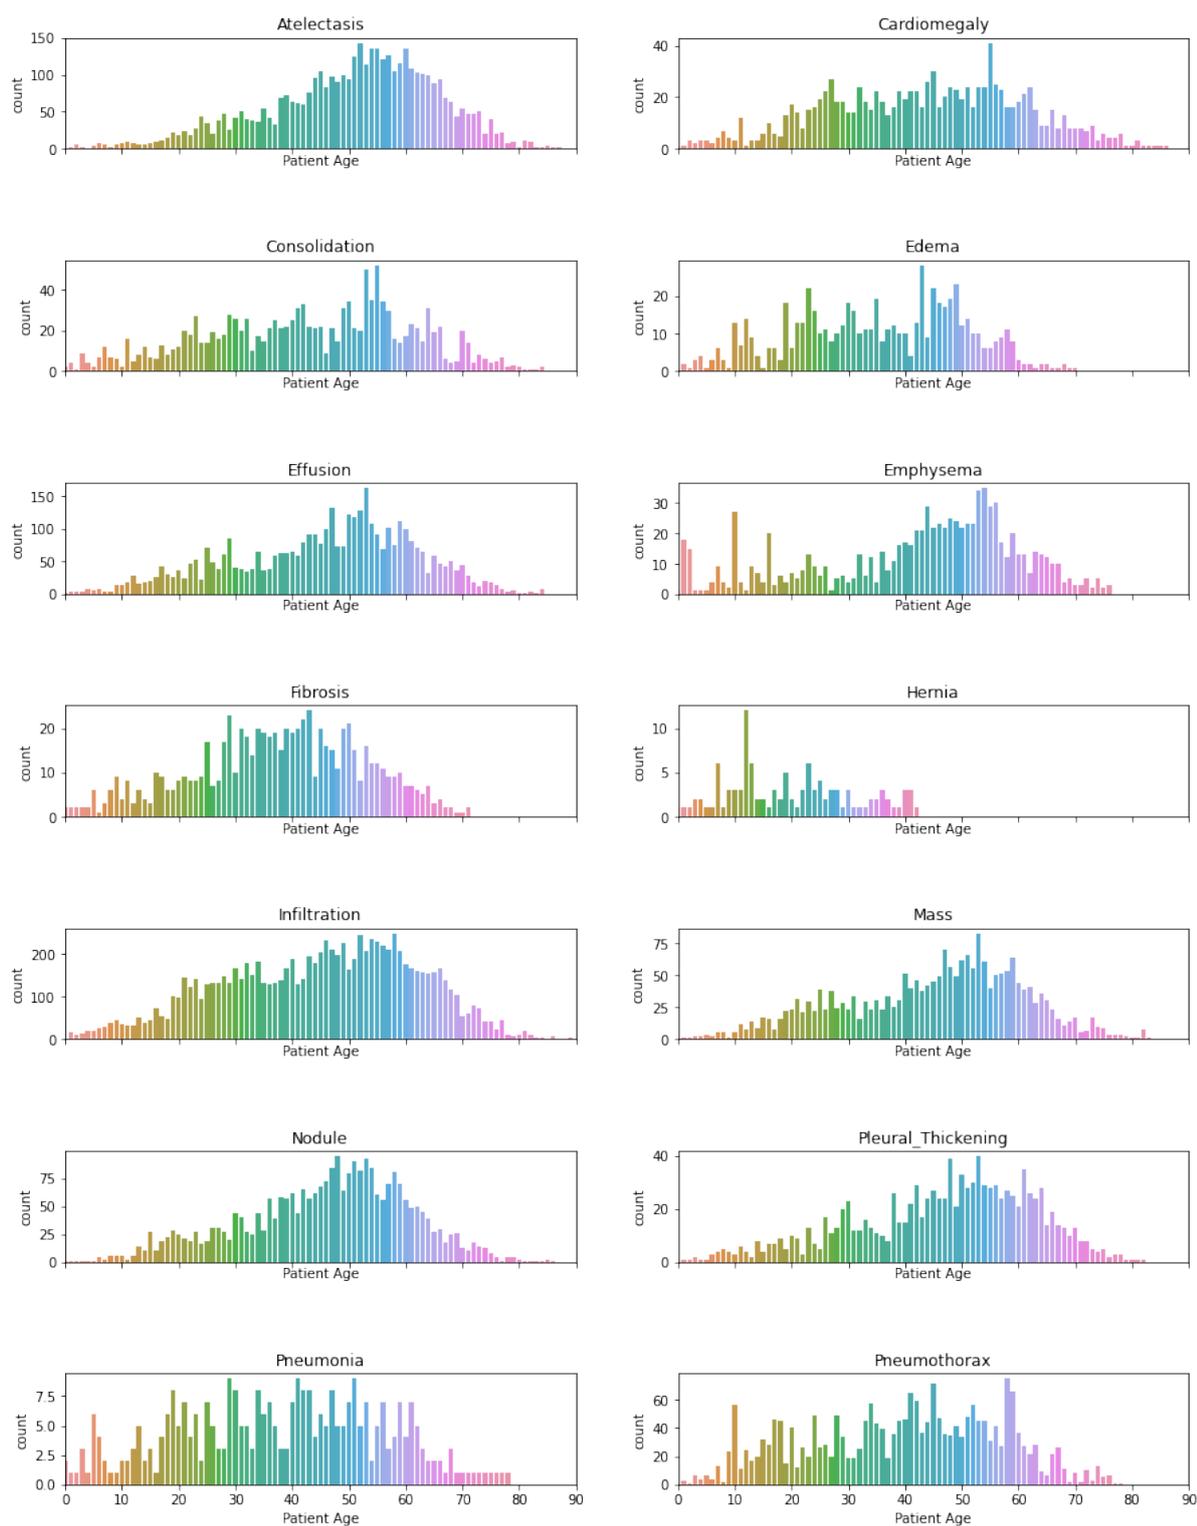


Fig. 11 ChestX-ray14 数据集中不同病理的年龄分布。

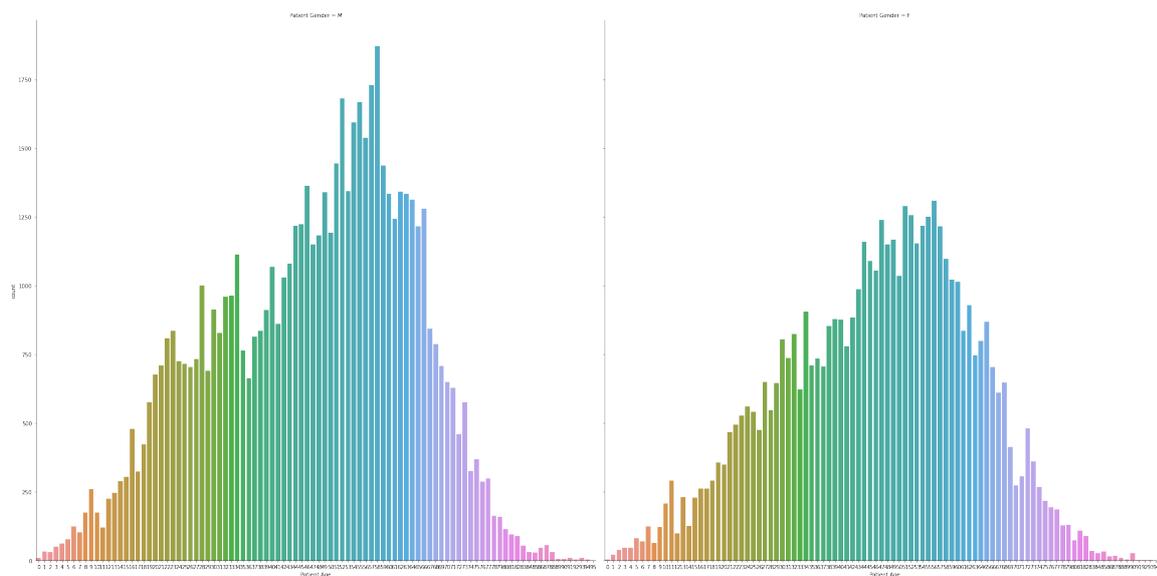


Fig. 12 ChestX-ray14 数据集中年龄的性别分布。

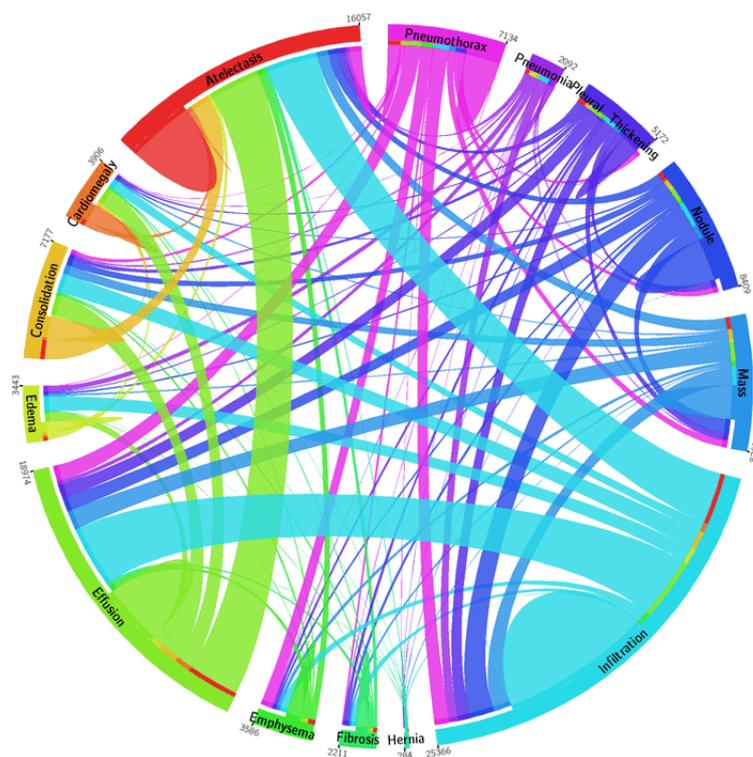


Fig. 13 ChestX-ray14 数据集中病理共现统计的和弦图 [?].

Table 6 IU-CXR 数据集中训练、验证和测试拆分中胸部 X 射线的分布

Pathology	Training	Validation	Testing	Total
No Finding	2,209	115	110	2,434
Enlarged Cardiomeastinum	693	35	41	769
Cardiomegaly	1,153	58	58	1,269
Lung Lesion	411	27	28	466
Lung Opacity	1,546	86	74	1,706
Edema	344	10	22	376
Consolidation	368	18	21	407
Pneumonia	288	9	15	312
Atelectasis	624	31	36	691
Pneumothorax	391	26	15	432
Pleural Effusion	681	35	40	756
Pleural Other	101	3	3	107
Fracture	258	11	18	287
Support Devices	402	20	18	440
Totals	6,718	350	350	7418

ImageNet 数据集上训练，与从头开始初始化模型相比，这有助于模型更快地收敛。在训练过程中，我们对模型进行微调，使模型能够适应医学图像的特征分布。我们实现了不同的数据增强技术，包括水平翻转、旋转、对比度调整、位置平移和在模型训练期间添加噪声。动态数据增强有助于模型在训练期间查看增加的图像数量以及具有变化的图像，帮助模型克服胸部 X 光片较少的班级的过度拟合，并提高模型对数据变化的鲁棒性。我们将数据集中的图像转换为三通道图像，将图像缩小到预训练的 DenseNet-121 模型所需的 224×224 分辨率，并根据 ImageNet 的图像按平均值 $([0.485, 0.456, 0.406])$ 和标准差 $([0.229, 0.224, 0.225])$ 对图像进行归一化。

最后的全连接层是一个 14 维密集层，然后是应用于每个输出的 S 形激活，以获得 14 个病理类别存在的预测概率。我们使用具有默认参数 $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$ 和 8 批量大小的 Adam 优化器来找到最佳权重。学习率最初设置为 $1e-4$ 学习衰减因子为 0.97，如果在训练期间模型没有改进，则降低学习率。在训练期间，我们保存在验证集上提供最高分的最优模型。我们还将最佳检查点保存在验证集上，以使其用于集成学习。最终结果基于验证集上的 10 个最佳检查点的集合，并计算这些模型的输出分数的平均值。该网络是使用 ImageNet 上的预训练模型初始化的。在训练过程中，我们的目标是最小化网络在训练样本上输出的真值标签和预测标签之间的二元交叉熵损失函数。

5.2 结果

为了评估所提出的方法的有效性，我们将与基线方法 DenseNet121 模型进行比较。我们还将所提出的方法的结果与 ChestX-ray14 数据集上一些最先进的多标签胸部疾病检测方法进行了比较。大多数值得注意的作品包括 [?, ?, ?, ?]。表 ?? 显示了使用 ChestX-ray14 数据集的官方患者分割时，我们提出的模型与现有基线相比的结果。所提出的方法在为 14 种胸部疾病中的 11 种提

供更好的结果方面优于基线。在 Table ?? 中，我们还报告了 ChestX-ray14 数据集的随机图像拆分结果。在比较研究的平均 AUC 评分时，我们提出的方法提供了更好的结果，除了 Rajpurkar 等人的研究 [?]。但是，我们确实强调，由于数据集的随机拆分，无法进行公平的比较。

为了在 CheXpert 数据集上扩展我们提出的方法，我们首先将其应用于数据集中提供地面真实注释的五种病理，并且我们可以将结果与现有研究进行比较 [?, ?]。当我们在实验设置中考虑 U-Ones 政策时，我们会考虑 U-Ones 政策下的 [?] 结果和 U-Ones+CT+LSR 政策下的 [?] 结果，以便对结果进行公平的比较。表 ?? 显示了五种病症的诊断结果，放射科医生对此进行了注释。实验结果表明，与基线方法相比，自注意力增强 DenseNet121 模型的结果更好。

在 ChestX-ray14 和 CheXpert 数据集上证明了比较基线方法诊断胸部疾病的自注意力机制的有效性后，我们进一步扩展了我们在 MIMIC-CXR-JPG 和 IU-CXR 数据集上的实验。表 ?? 比较基线 DenseNet121 模型与自注意力增强 DenseNet121 模型的 ?? 结果。实验结果表明，利用自注意力机制增强卷积网络是有效的。表 ??、表 ?? 和表 ?? 显示了诊断胸部疾病的结果，比较了基线 DenseNet121 模型和自我注意力增强的 DenseNet121 模型。自注意力增强 DenseNet121 (SA-DenseNet121) 的结果始终优于 DenseNet121 模型。对于大多数胸部疾病，SA-DenseNet121 优于 DenseNet121 模型，除了少数观察结果的分数接近 DenseNet121 模型。在仔细研究这些结果后，我们发现自我注意力为某些胸部疾病（例如病变和实变）提供了更好的结果增量。由于病变和实变等胸部疾病发生在较小的区域，因此使用自我注意力提供更高的结果突出了其在图像中捕获全局和局部区域特征的能力。在所有四个数据集中，IU-CXR 的平均 AUC 评分分别为 0.6841，而 ChestX-ray14、MIMIC-CXR-JPG 和 CheXpert 数据集上的平均 AUC 评分分别为 0.8556、0.7733 和 0.8129。我们假设这是由于与其他三个大规模数据集相比，IU-CXR

Table 7 使用胸部 X 射线数据集的患者官方拆分时诊断胸部疾病的 ROC 曲线下面积 (AUC) 评分 14。

Pathology	[?]	[?]	[?]	[?]	SA-DenseNet121
Atelectasis	0.7003	0.733	0.767	0.7505	0.8161
Cardiomegaly	0.8100	0.856	0.883	0.8710	0.9105
Effusion	0.7585	0.806	0.828	0.8181	0.8839
Infiltration	0.6614	0.673	0.709	0.6815	0.7077
Mass	0.6933	0.718	0.821	0.7994	0.8308
Nodule	0.6687	0.777	0.758	0.7147	0.7748
Pneumonia	0.6580	0.684	0.731	0.6938	0.7651
Pneumothorax	0.7993	0.805	0.846	0.8254	0.8739
Consolidation	0.7032	0.711	0.745	0.7415	0.8008
Edema	0.8052	0.806	0.835	0.8354	0.8979
Emphysema	0.8330	0.842	0.895	0.8428	0.9227
Fibrosis	0.7859	0.743	0.818	0.8040	0.8293
Pleural Thickening	0.6835	0.724	0.761	0.7463	0.7860
Hernia	0.8717	0.775	0.896	0.9022	0.9010
Mean AUC	0.7451	0.761	0.807	0.7876	0.8357

Table 8 使用胸部 X 射线数据集的图像随机拆分时用于诊断胸部疾病的 ROC 曲线下面积 (AUC) 评分 14。

Pathology	[?]	[?]	[?]	[?]	[?]
Atelectasis	0.716	0.722	0.762	0.70	0.821
Cardiomegaly	0.807	0.904	0.913	0.81	0.905
Effusion	0.784	0.859	0.864	0.76	0.883
Infiltration	0.609	0.695	0.692	0.66	0.720
Mass	0.706	0.792	0.750	0.69	0.862
Nodule	0.671	0.717	0.666	0.67	0.777
Pneumonia	0.633	0.713	0.715	0.66	0.763
Pneumothorax	0.806	0.841	0.859	0.80	0.893
Consolidation	0.708	0.788	0.784	0.70	0.794
Edema	0.835	0.882	0.888	0.81	0.893
Emphysema	0.815	0.829	0.898	0.83	0.926
Fibrosis	0.769	0.767	0.756	0.79	0.804
Pleural Thickening	0.708	0.765	0.774	0.68	0.814
Hernia	0.767	0.914	0.802	0.87	0.939
Mean AUC	0.738	0.799	0.795	0.75	0.842

Table 9 使用 CheXpert 数据集的患者官方拆分时，用于诊断 5 种病理的 ROC 曲线下面积 (AUC) 评分。

Pathology	[?]	[?]	DenseNet121	SA-DenseNet21
Atelectasis	0.858	0.825	0.847	0.862
Cardiomegaly	0.832	0.855	0.859	0.861
Consolidation	0.899	0.937	0.900	0.916
Edema	0.941	0.930	0.936	0.936
Pleural Effusion	0.934	0.923	0.940	0.944
Mean AUC	0.893	0.894	0.896	0.904

数据集的规模较小。鉴于基于自注意力的模型非常复杂并且具有数十亿个参数，因此它们在较小的数据集上过拟合是合理的。

6 讨论

基于所有四个大规模胸部 X 光数据集的实验结果，与基线 (DenseNet121) 模型相比，自注意力增强卷积网络 (SA-DenseNet121) 提供了更好的结果。这表明增强对卷积网络的自我关注有助于捕获全局和局部特征，从而

提高模型识别胸部疾病的诊断能力。与 ChestX-ray14、CheXpert 和 MIMIC-CXR-JPG 三个大型数据集相比，基线和 SA-DenseNet121 在 IU-CXR 数据集上的整体性能均较低。我们假设这是由于数据集规模较小，只有 7,418 张胸部 X 光片，而其他三个数据集有超过 100,000 张胸部 X 光片。仔细观察每个病理学标签的结果，我们发现，与“肿块”和“结节”等较小的物体相比，该模型为“心脏扩大”、“肺气肿”和“气胸”等大型物体提供了更高的分数。我们假设这是因为胸部 X 光片中大面积可见的病理可以很容易地定位。另一方面，

Table 10 在 ChestX-ray14 数据集的测试集上诊断胸部疾病的 ROC 曲线下面积 (AUC) 评分。

Pathology	DenseNet121	SA-DenseNet121
Atelectasis	0.8161	0.8322
Cardiomegaly	0.9105	0.9279
Effusion	0.8839	0.9026
Infiltration	0.7077	0.7468
Mass	0.8308	0.8642
Nodule	0.7748	0.7849
Pneumonia	0.7651	0.7721
Pneumothorax	0.8739	0.8948
Consolidation	0.8008	0.8375
Edema	0.8979	0.9126
Emphysema	0.9227	0.9238
Fibrosis	0.8293	0.8435
Pleural Thickening	0.7860	0.8219
Hernia	0.9010	0.9136
Mean AUC	0.8357	0.8556

Table 11 在 CheXpert 数据集的验证集上诊断胸部疾病的 ROC 曲线下面积 (AUC) 评分。

Pathology	DenseNet121	SA-DenseNet121
No Finding	0.8885	0.9123
Enlarged Cardiomeastinum	0.6114	0.6575
Cardiomegaly	0.8157	0.8246
Lung Lesion	0.8071	0.8291
Lung Opacity	0.7740	0.8045
Edema	0.8695	0.8832
Consolidation	0.7198	0.7376
Pneumonia	0.7241	0.7345
Atelectasis	0.7088	0.7129
Pneumothorax	0.8368	0.8379
Pleural Effusion	0.8747	0.8873
Pleural Other	0.9212	0.9318
Fracture	0.7360	0.7366
Support Devices	0.8819	0.8910
Mean AUC	0.7977	0.8129

Table 12 在 MIMIC-CXR-JPG 数据集的测试集上诊断胸部疾病的 ROC 曲线下面积 (AUC) 评分。

Pathology	DenseNet121	SA-DenseNet121
No Finding	0.8051	0.8120
Enlarged Cardiomeastinum	0.6783	0.6815
Cardiomegaly	0.7816	0.7941
Lung Lesion	0.7190	0.7184
Lung Opacity	0.6945	0.7083
Edema	0.8392	0.8410
Consolidation	0.7155	0.7117
Pneumonia	0.7150	0.7184
Atelectasis	0.7623	0.7660
Pneumothorax	0.7997	0.8030
Pleural Effusion	0.8867	0.8976
Pleural Other	0.7925	0.7987
Fracture	0.6604	0.6625
Support Devices	0.8924	0.9134
Mean AUC	0.7673	0.7733

Table 13 在 IU-CXR 数据集的测试集上诊断胸部疾病的 ROC 曲线下面积 (AUC) 评分。

Pathology	DenseNet121	SA-DenseNet121
No Finding	0.7152	0.7301
Enlarged Cardiomeastinum	0.7013	0.7264
Cardiomegaly	0.7179	0.7360
Lung Lesion	0.5130	0.5439
Lung Opacity	0.6924	0.6941
Edema	0.7331	0.7422
Consolidation	0.4973	0.5218
Pneumonia	0.7003	0.7160
Atelectasis	0.7707	0.7873
Pneumothorax	0.5974	0.6204
Pleural Effusion	0.5783	0.5829
Pleural Other	0.8473	0.8485
Fracture	0.6021	0.6113
Support Devices	0.6904	0.7170
Mean AUC	0.6683	0.6841

肿块和结节等病理发生在较小的区域,这使得模型很难在胸部 X 光片中轻松定位。结果表明,自我注意力与卷积网络具有互补性,使得该方法能够学习不同病理的更多判别特征。将数据集中所有病理的平均 AUC 评分作为数据集上的模型性能,我们发现所有四个数据集的结果都存在差异。这可以归因于具有不同采集协议、不同扫描仪和不同患者人口统计数据的数据集来源。拥有一个可以在不同数据集上很好地泛化并提供相同性能水平的单一模型是具有挑战性的。

尽管所提出的方法在通过胸部 X 光诊断胸部疾病方面取得了可喜的结果,但我们想强调一些局限性。首先,本研究中考虑的所有四个胸部 X 光数据集都存在类别不平衡的问题。虽然数据增强和迁移学习有助于减轻类不平衡问题的影响,但可以应用处理类不平衡的特定技术。其次,肺炎等病理标签不能仅根据胸片进行诊断。在实际临床实践中,为了诊断肺炎,要评估病理学实验室检查以及胸部 X 线检查以做出最终决定。因此,这可能会影响模型性能。第三,本研究中使用的胸部 X 射线数据集的结构化标签是通过在放射学报告上应用 NLP 技术来整理的,这些报告伴随着医院 PACS。NLP 标记器建立在解析、否定检测、提及提取、提及分类和聚合等不同方法之上,每个阶段的错误都可能为错误标签提供空间。CheXpert NLP 提供了超过 95% 的准确性,为 5% 结构化标签的错误标签留下了空间。胸部 X 光片的错误标记会对模型训练产生不利影响。第四,尽管已经采用了不同的策略将不确定标签映射到零 (U-Zeros 策略) 或 1 (U-One 策略),但它仍然不是模型学习这些不确定情况的有效方法。处理此问题的一种方法是将不确定标签视为多标签类之一,从而为评估提供成倍增加的方面。第五,将不同胸部疾病之间的相关性纳入一个领域,可以进一步改善结果。

7 结论

胸部疾病的早期诊断和治疗对于挽救人类生命至关重要。在本文中,我们提出了一种用于胸部 X 射线诊断常见胸部疾病的多头自注意力增强卷积网络。在四个最大的胸部 X 射线数据集上的实验表明,所提出的模型在诊断胸部疾病方面是有效的。与基线方法相比,我们提出的方法产生了有竞争力的结果。用于诊断胸部疾病的计算机辅助系统的开发可以通过提供第二意见来增强放射科医生的能力,改善临床结果,减少诊断错误,并加快临床工作流程。

8

数据可用性 NIH ChestX-ray14 数据集在 <https://nihcc.app.box.com/v/ChestXray-NIHCC> 上公开提供。印第安纳大学胸部 X 光片收藏可在 <https://openi.nlm.nih.gov/>。CheXpert 数据集可以通过填写 <https://stanfordmlgroup.github.io/competitions/chexpert/> 的表格来下载。MIMIC-CXR 和 MIMIC-CXR-JPG 数据集可在 <https://physionet.org/content/mimic-cxr-jpg/2.0.0/> 签署数据使用协议后下载。

Acknowledgements This research was undertaken with the assistance of resources from the National Computational Infrastructure (NCI) supported by the Australian Government.

利益冲突: 本作品不存在利益冲突。