



· 知识发现与粒计算 ·

一种基于宽度学习系统变体结构的肺炎检测方法

黎珂源^{1,2}, 张清华^{1,2,3}, 靳朋仁^{1,2}, 谢 秦^{1,2}

(1. 重庆邮电大学 计算智能重庆市重点实验室, 重庆 400065; 2. 重庆邮电大学 大数据智能计算重点实验室, 重庆 400065; 3. 重庆邮电大学 旅游多源数据感知与决策技术文化和旅游部重点实验室, 重庆 400065)

摘要 肺炎作为常见的呼吸系统疾病, 准确、快速地诊断对患者的健康恢复至关重要。随着医疗技术的革新和人工智能的发展, 计算机辅助诊断在医学领域的应用日益广泛。深度学习在肺炎检测领域取得了显著的成果, 但其庞大的参数数量和复杂的网络结构导致训练时间长、计算资源消耗大等局限性。为了解决上述问题, 提出了一种基于宽度学习系统变体结构的肺炎检测方法。该方法在原始宽度学习系统的基础上, 引入了级联金字塔结构; 同时, 利用预训练的 EfficientNet 网络作为前置特征提取器; 此外, 还提出了适用于该模型的增量学习算法, 包括增加额外的增强节点、特征节点和训练样本, 以进一步优化模型性能; 最后, 在公开的肺炎胸部 X 射线数据集上进行了对比实验。实验结果表明, 该方法实现了 92.83% 的准确率, AUC 值高达 98.86%, 与众多深度卷积神经网络相比, 具有相似的精度, 同时大幅缩短了模型的训练时间。

关键词 肺炎检测; 宽度学习系统; 级联金字塔; 增量学习

中图分类号: TP391 **DOI**: 10.16152/j.cnki.xdxbzr.2024-04-009

A pneumonia detection method based on the variant structure of broad learning system

LI Keyuan^{1,2}, ZHANG Qinghua^{1,2,3}, JIN Pengren^{1,2}, XIE Qin^{1,2}

(1. Chongqing Key Laboratory of Computational Intelligence, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. Key Laboratory of Big Data Intelligent Computing, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

3. Chongqing Key Laboratory of Tourism Multisource Data Perception and Decision Ministry of Culture and Tourism, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract Pneumonia as a common respiratory disease, its accurate and rapid diagnosis is crucial to the health of patients. With the innovation of medical technology and the development of artificial intelligence, computer-aided diagnosis has been increasingly used in the medical field. Deep learning has achieved remarkable results in the field of pneumonia detection, but its large number of parameters and complex network struc-

收稿日期: 2024-05-28

基金项目: 国家自然科学基金(62276038); 重庆市创新研究群体科学基金(cstc2019jcyjxtX0002); 重庆市教委重点合作项目(HZ2021008); 重庆市人才计划项目(CQYC20210202215); 重庆市自然科学基金创新发展联合基金(CSTB2023NSCQ-LZX0164)。

第一作者: 黎珂源, 男, 从事智能信息处理、数据挖掘研究, 928226056@qq.com。

通信作者: 张清华, 男, 教授, 博士生导师, 从事粗糙集、模糊集、粒计算等研究, zhangqh@cqupt.edu.cn。

ture lead to limitations such as long training time and high consumption of computational resources. To solve the above problems, a pneumonia detection method based on the variant structure of broad learning system is proposed in this paper. The method introduces the cascade pyramid structure on the basis of original broad learning system. Meanwhile, the pre-trained EfficientNet network is utilised as the front feature extractor. In addition, the incremental learning algorithms applicable to the model are proposed in this paper, including adding additional enhancement nodes, feature nodes and training samples to further optimise the model performance. Finally, comparative experiments are conducted on the publicly available dataset of chest X-rays for pneumonia. The experimental results show that the method in this paper achieves 92.83% accuracy and 98.86% AUC value, which are comparable to many deep convolutional neural networks, while the training time of the model is significantly shortened.

Keywords pneumonia detection; broad learning system; cascade pyramid; incremental learning

随着医疗技术的不断进步和人工智能的飞速发展,计算机辅助诊断在医学领域的应用日益广泛。肺炎作为一种常见的呼吸系统疾病,其准确、快速地诊断对于患者的及时治疗和恢复至关重要。传统的肺炎诊断主要依赖于医生的临床经验和医学影像技术,但由于疾病的多样性和复杂性,人工诊断难免存在主观性和误差。因此,开发一种高效、准确的计算机辅助肺炎诊断方法具有重要的现实意义和应用价值。

近年来,深度学习^[1]作为人工智能领域的一大分支,在医学图像分析领域^[2]取得了显著的成果。通过构建深度神经网络模型,深度学习能够从海量的医学影像数据中自动提取有效特征,实现疾病的自动诊断。然而,深度学习模型通常具有庞大的参数数量和复杂的网络结构,导致训练时间长、计算资源消耗大等问题。此外,深度模型的高度复杂性也使得其在资源受限的环境中的应用受到限制。

为了解决上述问题,本文提出了一种基于宽度学习系统变体结构的肺炎检测方法。宽度学习系统作为一种新型的机器学习模型,具有训练速度快、模型简单、参数少等优点。通过利用宽度学习系统的特性,旨在保证诊断精度的同时,缩短训练时间,降低计算资源消耗,使肺炎检测方法在更广泛的场景中得以应用。

1 相关工作

近年来,深度学习以其强大的自动特征学习能力,在肺炎检测领域展现出了独特的优势。它能够从海量数据中提取出比传统方法更为抽象和有效的特征,为医生提供更为准确、可靠的诊断依

据。在处理放射学影像数据时,卷积神经网络(CNN)等深度学习模型^[3]的应用尤为广泛。通过大量的训练数据和复杂的网络结构,深度学习模型已经取得了显著的精度提升。例如,Sharma 等人^[4]和 Stephen 等人^[5]设计了简洁高效的 CNN 架构,用于肺部 X 射线图像的分类任务。他们巧妙地利用数据增强技术,克服了数据不足的挑战,在 Kermany 等人^[6]提供的数据集(以下称为 Kermany 数据集)上分别实现了 90.68% 和 93.73% 的准确率。Rajpukar 等人^[7]采用 DenseNet-121 模型进行肺炎分类,尽管在特定数据集上的 F1 分数仅为 76.8%,但他们深入分析了患者病史的缺失对模型性能的影响,为后续研究提供了宝贵的启示。Janizek 等人^[8]进一步提出了一种基于对抗优化的框架,旨在消除模型对数据集源的依赖性,并产生更为鲁棒的预测结果。他们在源域和目标域上均取得了令人满意的 AUC 评分,证明了该框架的有效性和泛化能力。Zhang 等人^[9]提出了一种用于肺部 X 射线图像中异常检测的置信度感知模块,将检测任务视为一类问题(仅确定异常)。这种创新的方法在数据集上获得了 83.61% 的 AUC 评分,为异常检测提供了新的思路。此外,Tuncer 等人^[10]采用了一种结合机器学习和模糊树变换的方法,通过对图像进行样本划分和特征提取,成功地在由 COVID-19 和肺炎样本组成的小数据集上实现了高达 97.01% 的准确率。

尽管深度学习在肺炎检测中取得了巨大的成功,但它也存在一些固有的缺点,例如训练的硬件资源要求高、训练时间长以及待训练的参数量大等问题。随后,宽度学习系统(broad learning system, BLS)^[11]作为一种新兴的网络结构,于 2018

年被 Chen 教授及其团队提出并证明了模型具有通用逼近性^[12],旨在能够高效地解决回归和分类任务。

由于宽度学习系统显著的快速高效特点,自从宽度学习系统问世之后,它吸引了大量研究人员的兴趣和关注^[13]。BLS 凭借其独特的优势,为众多领域的研究开辟了新的道路。在情感识别领域,Zhang 等人^[14]和 Wang 等人^[15]创新性地提出了一种重要的模型结构称为图卷积宽度网络(GCB-Net),基于图卷积网络和 BLS 来探索脑电图用于情感识别的高级图拓扑信息,并在 SJTU 和 DREAMER 数据集上展现出了卓越的性能。在安全驾驶领域,Yang 等人^[16]设计了一种基于 BLS 的新型复杂网络,用于检测驾驶员疲劳驾驶的问题。该网络通过有效捕捉驾驶员的生理和行为特征,实现了对疲劳驾驶的准确检测。在生物信息学领域,Parhi 等人^[17]将 MBO 算法与 BLS 相结合提出了 MBO-BLS 模型,用于从高维基因表达中选择最具影响力的特征并对微阵列数据进行分类。此外,Zhan 等人^[18]利用随机森林筛选出关键特征,然后结合 BLS 与 Bagging 集成策略来预测 COVID-19 的传染趋势,称为 RF-Bagging-BLS 模型。在医学图像领域,Han 等人^[19]提出一种基

于多尺度 3D 卷积特征的宽度学习系统用于阿尔兹海默症诊断,为了适应医学图像的特点,设计了一种新的特征映射模块,该模块包含多组特征下采样,无需额外的特征选择即可得到图像的多尺度特征。在 ANDI-1 数据集上进行了相关实验,对 AD 诊断任务和 MCI 诊断任务的准确率分别达到 91.83% 和 75.52%。

尽管宽度学习系统在医学图像领域和图像分类任务上已经取得了不错的研究效果,但它尚未被应用于肺炎检测问题的分类任务中。因此,本研究首次尝试采用宽度学习系统来处理肺炎检测问题。

2 方法

本节将详细介绍模型的具体构建方法。该模型主要包含两个模块,首先,将基于预训练的 EfficientNet 网络作为宽度学习系统变体结构的前置特征提取器;其次,设计了一种新的宽度学习系统的变体结构,级联金字塔宽度学习系统(cascade pyramid broad learning system, CPBLS)。因此,将整个模型简称为 EfficientNet-CPBLS,其模型总体框架如图 1 所示。




图 1 EfficientNet-CPBLS 模型总体框架图

Fig. 1 General framework figure of the EfficientNet-CPBLS model

2.1 总体框架

首先,如果输入的图像是灰度图像,则需要将输入的图像处理为 RGB 格式,并调整大小为 224 × 224。因此,整个模型的输入数据大小为 224 × 224 × 3,如图 1 所示。然后,对输入的图像进行特

征提取,使用在 ImageNet 上预训练好的 EfficientNet-B4 作为前置特征提取器,提取到丰富的图像特征表示。对提取到的特征通过平均池化的操作进行降维处理后得到 X,将 X 输入到基于级联金字塔结构的宽度学习系统变体结构中。随后,通

过线性变换和级联金字塔结构生成特征节点层,将特征节点层通过非线性变换生成增强节点层。再将特征节点层和增强节点层合并给到输出层,并通过基于岭回归的伪逆近似计算快速得到网络权重。通过训练得到的网络权重,对测试集图像做出预测,判断是否患有肺炎。

此外,该模型延续了宽度学习系统的特点,适用于增量学习。实现了 3 种该模型的增量学习算法,包括增加额外的增强节点、增加额外的特征节点、增加额外的训练样本。在后续章节将详细介绍模型的增量学习算法。

2.2 特征提取器

由于 BLS 的结构简单,只有一个隐藏层,不能有效地学习图像的特征。在之前的研究中,Liu 等人^[20]提出了 K-means-BLS 模型,在原始 BLS 基础上引入 K-means 特征表示方法。该方法使用 K-means 算法来提取图像特征,并将提取到的特征作为 BLS 的输入,从而提高 BLS 在复杂数据集 CIFAR-10 上的分类效果。Yang^[21]也提出了一种

基于 CNN 的宽度学习系统 CNNBLS,该模型使用卷积操作和池化操作从图像中提取特征。上述两个模型证明了为 BLS 添加图像特征提取器是有效的,能够帮助 BLS 更好地学习图像特征。

虽然上述两个模型确实可以提升 BLS 的分类性能,但改进仍然有限。因此,本文尝试采用更先进的方法来提取图像特征,将 EfficientNet 网络的 B4 模型作为前置特征提取器。EfficientNet^[22]结合了深度神经网络和模型缩放的概念,通过增加网络的深度、宽度和分辨率来提高模型的性能。该模型使用的 EfficientNet-B4 已在大型数据集 (ImageNet) 上进行了预训练。EfficientNet-B4 位于 EfficientNet 系列中的中等复杂度区域,它在性能和计算效率之间提供了一个良好的平衡。

2.3 级联金字塔宽度学习系统

本文设计了一种新的宽度学习系统的变体结构,级联金字塔宽度学习系统 (CPBLS),其网络结构如图 2 所示。




图 2 CPBLS 网络结构图

Fig. 2 The network structure diagram of CPBLS

假设有输入数据集 $X \in \mathbf{R}^{N \times M}$,其中 N 代表样本数, M 代表对样本特征提取后的特征数量。 X 对应的标签集为 $Y \in \mathbf{R}^{N \times C}$,其中 C 表示样本的类别数。CPBLS 网络的构建流程如下。

首先,使用随机线性映射函数将输入数据集 X 进行一次随机映射,得到每一层特征节点的第一组数据。

$$Z_{i1} = \phi(XW_{e_{i1}} + \beta_{e_{i1}}), i = 1, 2, \dots, n \quad (1)$$

其中: n 表示特征节点的层数,即级联金字塔的层数。然后,通过级联操作生成第 i 层特征节点第一组之外的其他组节点,当前组节点由同一层的前

一组节点生成,即

$$Z_{ij} = \phi(Z_{i(j-1)} W_{e_{ij}} + \beta_{e_{ij}}), \quad i = 1, 2, \dots, n, \quad j = 2, 3, \dots, i \quad (2)$$

其中: i 表示特征节点的层数; j 表示本层特征节点的组数;连接权重 $W_{e_{ij}}$ 和偏置 $\beta_{e_{ij}}$ 是随机生成的。因此,可总结所有特征节点的规律为

$$Z_{ij} = \begin{cases} \phi(XW_{e_{ij}} + \beta_{e_{ij}}), & i = 1, 2, \dots, n, j = 1; \\ \phi(Z_{i(j-1)} W_{e_{ij}} + \beta_{e_{ij}}), & i = 1, 2, \dots, n, \\ & j = 2, 3, \dots, i \end{cases} \quad (3)$$

通过 X 的随机映射,共生成 n 层特征节点,第 i 层共包含 i 组特征节点, F 表示所有的特征映射节点,即特征节点层为

$$F = [F_1, F_2, \dots, F_n] = [Z_{11}, Z_{21}, Z_{22}, \dots, Z_{nn}] \quad (4)$$

在 $n(n+1)/2$ 次随机映射中,映射函数 ϕ 可以保持相同,也可以不同。常见的可选映射函数有 Sigmoid、Tansig、Tanh、ReLU 和 LeakyReLU 等。

其次,通过非线性变换函数 ξ 对特征节点层 F 进行随机映射,得到第 k 组增强节点 H_k ,

$$H_k = \xi(FW_{h_k} + \beta_{h_k}), k = 1, 2, \dots, m \quad (5)$$

其中: W_{h_k} 和 β_{h_k} 同样是随机生成的连接权重和偏置项。将所有增强节点拼接得到增强节点层 E ,

$$E = [H_1, H_2, \dots, H_m] \quad (6)$$

最后,将特征节点层和增强节点层进行合并为 $A = [F | E]$,通过权重 W 连接到输出层 Y ,

$$Y = [Z_{11}, \dots, Z_{nn} | H_1, \dots, H_m] W = [F | E] W = AW \quad (7)$$

由此可求得权重 W ,

$$W = A^+ Y \quad (8)$$

其中: A^+ 表示 A 的伪逆。根据 BLS 的推导,可由下式计算得到 A^+ ,

$$A^+ = \lim_{\lambda \rightarrow 0} (\lambda I + AA^T)^{-1} A^T \quad (9)$$

其中: I 是单位矩阵。

2.4 增量学习算法

增量学习是 BLS 的一个重要特征,使其能够在无需对整个模型进行重新训练的情况下,对 BLS 进行快速重建。本文所提出的模型同样可以延续这个特点,提出了相应的 3 种增量学习算法,能够对 EfficientNet-CPBLS 进行轻量化地更新。3 种增量学习算法分别是增加额外的增强节点、增加额外的特征节点、增加额外的训练样本。

2.4.1 增加额外的增强节点

在某些情况下,如果学习达不到期望的精度,一种解决方案是增加额外的增强节点以实现更好的性能。此算法的模型框架如图 3 所示。




图3 EfficientNet-CPBLS 的增量学习算法:增加额外的增强节点

Fig. 3 Incremental learning algorithm of EfficientNet-CPBLS: Adding additional enhancement nodes

在原 $A = [F | E]$ 的基础上,增加额外的增强节点 H_{m+1} ,

$$H_{m+1} = \xi(FW_{h_{m+1}} + \beta_{h_{m+1}}) \quad (10)$$

其中: $W_{h_{m+1}}$ 和 $\beta_{h_{m+1}}$ 是随机生成的连接权重和偏置。得到新的特征节点层和增强节点层的合并,

$$A^{m+1} = [A | H_{m+1}] \quad (11)$$

根据原始 BLS 的增量形式推导,可以得到新矩阵

的伪逆为

$$(A^{m+1})^+ = \begin{bmatrix} (A)^+ - DB^T \\ B^T \end{bmatrix} \quad (12)$$

其中:

$$D = (A)^+ H_{m+1} \quad (13)$$

$$B^T = \begin{cases} (C)^+, & \text{if } C \neq 0 \\ (1 + D^T D)^{-1} B^T (A)^+, & \text{if } C = 0 \end{cases} \quad (14)$$

其中: $C = H_{m+1} - AD$ 。最后,可以得到新的权重,

$$W^{m+1} = \begin{bmatrix} W - DB^T Y \\ B^T Y \end{bmatrix} \quad (15)$$

该算法仅需计算额外增强节点的伪逆而不是 A^{m+1} 的伪逆,从而能够实现快速的增量学习。

2.4.2 增加额外的特征节点

在某些情况下,只增加额外的增强节点不足以达到期望的效果,可能是由于特征节点不足导致的。因此,也可以增加额外的特征节点,来更好地映射输入数据,同样可以应用增量学习算法,无需重新训练整个模型。此算法的模型框架如图 4 所示。




图 4 EfficientNet-CPBLS 的增量学习算法:增加额外的特征节点

Fig. 4 Incremental learning algorithm of EfficientNet-CPBLS: Adding additional feature nodes

首先,在 X 基础上通过随机映射得到额外的特征节点,

$$F_{n+1} = \phi(XW_{e_{i+1}} + \beta_{e_{i+1}}) \quad (16)$$

这里增加的额外特征节点将不再生成级联金字塔形式,而是与原始BLS的思想保持一致,生成一组单独的特征节点。随后,由 F_{n+1} 再随机映射得到 m 组增强节点,合并为

$$E' = [\xi(F_{n+1}W_{h_{x1}} + \beta_{h_{x1}}), \dots, \xi(F_{n+1}W_{h_{xm}} + \beta_{h_{xm}})] \quad (17)$$

再将所有的特征节点和增强节点合并,得到

$$A_{n+1}^m = [A | F_{n+1} | E'] \quad (18)$$

然后计算 A_{n+1}^m 的伪逆

$$(A_{n+1}^m)^+ = \begin{bmatrix} (A)^+ - DB^T \\ B^T \end{bmatrix} \quad (19)$$

其中:

$$D = (A)^+ [F_{n+1} | E'] \quad (20)$$

$$B^T = \begin{cases} (C)^+, & \text{if } C \neq 0 \\ (1 + D^T D)^{-1} D^T (A)^+, & \text{if } C = 0 \end{cases} \quad (21)$$

其中: $C = [F_{n+1} | E'] - AD$ 。最后,可以得到新的权重,

$$W_{n+1}^m = \begin{bmatrix} W - DB^T Y \\ B^T Y \end{bmatrix} \quad (22)$$

该算法仅需要计算额外特征节点和增强节点的伪逆而不是整个 A_{n+1}^m 的伪逆。这种针对性的计算方式极大地减少了计算量,从而实现了快速的增量学习,使得模型能够更快速地适应新的特征节点。

2.4.3 增加额外的训练样本

在某些情况下,源源不断地有新的训练样本输入时,模型仍然具备高效的增量学习能力,以便快速适应新数据而无需耗费大量时间重新训练整个模型,此算法的模型框架如图 5 所示。

假设新增加的额外的训练样本输入模型后,首先会通过 EfficientNet-B4 网络进行图像特征的提取,将提取到的新样本的特征表示为 X_a ,随后这些特征被输入到 CPBLS 进行进一步的处理。在这个过程中,CPBLS 首先会根据新样本的特征表示 X_a 生成相应的额外的特征节点,

$$F_{n+1} = [\phi(X_a W_{e_{i+1}} + \beta_{e_{i+1}}), \dots, \phi(X_a W_{e_{i+n}} + \beta_{e_{i+n}})] \quad (23)$$

然后,生成相应的增强节点,合并为

$$E' = [\xi(F_{n+1}W_{h_{x1}} + \beta_{h_{x1}}), \dots, \xi(F_{n+1}W_{h_{xm}} + \beta_{h_{xm}})] \quad (24)$$

随后,合并所有的特征节点和增强节点得到 A_n^m ,

$$A_n^m = \begin{bmatrix} A \\ (F_{n+1} | E')^T \end{bmatrix} \quad (25)$$

计算 A_n^m 的伪逆

$$(A_n^m)^+ = [(A)^+ - BD^T | B] \quad (26)$$

其中:

$$D^T = (F_{n+1} | E')^T (A)^+ \quad (27)$$

$$B^T = \begin{cases} (C)^+, & \text{if } C \neq 0 \\ (1 + D^T D)^{-1} (A)^+ D, & \text{if } C = 0 \end{cases} \quad (28)$$

其中: $C = (F_{n+1} | E')^T - D^T A$ 。最后,可以得到新的权重

$$W_n^m = W + (Y_a^T - (F_{n+1} | E')^T W) B \quad (29)$$

其中: Y_a^T 是额外训练样本 X_a 的标签。

该算法继承了 BLS 高效的特性。无论是面对单个新样本还是大规模的新数据集,都能迅速作出响应,通过计算额外特征节点和增强节点的伪逆,避免了对整个大矩阵进行复杂的伪逆计算。这种处理方式大大减少了计算量,显著提高了算法的效率。因此,该算法特别适用于需要频繁更新和扩展的场景。




图5 EfficientNet-CPBLS 的增量学习算法:增加额外的训练样本

Fig. 5 Incremental learning algorithm of EfficientNet-CPBLS: Adding additional training samples

3 实验与分析

为了验证本文所提出模型的有效性,本节设计并进行了一系列相关实验。实验的硬件环境为:3.00 GHz Intel i9-10980XE CPU 和 NVIDIA RTX A5000 GPU;软件环境为:Python 3.8.13 和 Pytorch 1.21.1。其中,GPU 可用于加速特征提取过程,其余部分的计算均在 CPU 上进行。

3.1 数据集

本文实验使用的是公开可用的肺炎胸部 X 射线数据集,Kermany 数据集^[6]。该数据集共包含 5 856 张图像,涵盖了两个类别:肺炎和正常。将其划分为训练集和测试集,训练集共 5 232 张图像,测试集共 624 张图像。

3.2 评价指标

本文所采用的评价指标包括准确率 (accuracy, ACC)、精确率 (precision, PRE)、召回率 (re-

call, REC)、F1 分数 (F1)、ROC 曲线下面积 (AUC)。ACC 是一个重要的评价指标,但在不平衡数据集中可能会产生误导。Precision、Recall 和 F1 能够提供更详细地评估模型在正例和负例预测上的表现,有助于全面了解模型的性能。其中, Precision 表示模型预测为正例的样本中有多少是真正的正例; Recall 表示真正的正例中有多少被模型预测为正例; F1 分数是 Precision 和 Recall 的调和平均数,综合考虑了两者的性能,在需要综合精度和召回率的情况下特别适用。此外, AUC 表示 ROC 曲线与坐标轴所形成的面积,取值范围为 $[0, 1]$, 是二分类模型的重要评价指标。较大的 AUC 值代表模型效果更好。此外,实验还加入了训练时间的比较,以比较提出的方法与深度神经网络之间的计算效率。

3.3 参数设置

所提出的 EfficientNet-CPBLS 模型共有 6 个

超参数,分别是每组特征节点的数量 N_f ,特征节点的层数 N_n ,增强节点的数量 N_e 以及收缩系数 s 、正则化系数 c 和批量大小 Batch size。其中,将收缩系数 s 和正则化系数 c 固定为一个常量。对 N_f 、 N_n 和 N_e 使用网格搜索策略,找到搜索范围内的最佳超参数。 N_f 的搜索范围为 $\{50, 100, \dots, 550\}$, N_n 的搜索范围为 $\{3, 4, \dots, 10\}$, N_e 的搜索范围为 $\{100, 200, \dots, 3\ 000\}$ 。Batch size 为 EfficientNet-B4 网络提取特征时批量输入图像的数量。详细参数设置情况如表 1 所示。

表 1 模型超参数设置情况
Tab. 1 The model hyperparameter settings

超参数	取值范围
收缩系数	$s = 0.8$
正则化系数	$c = 2^{-30}$
批量大小	Batch size = 128
每组特征节点的数量	$N_f \in \{50, 100, \dots, 550\}$
特征节点的层数	$N_n \in \{3, 4, \dots, 10\}$
增强节点的数量	$N_e \in \{100, 200, \dots, 3\ 000\}$

3.4 对比实验

为了验证所提模型的有效性,本节将所提出的 EfficientNet-CPBLS 模型首先与常见的卷积神经网络方法 (AlexNet^[23]、GoogLeNet^[24]、ResNet-18^[25]、ResNet-50^[25]、VGG-16^[26]、DenseNet-

121^[27]、MobileNet-v3^[28]) 进行对比实验,实验结果如表 2 所示。所有的卷积神经网络方法都经过 100 个 Epoch 的训练,批量大小 Batch size 为 128,初始学习率为 1×10^{-3} ,采用交叉熵损失和 Adam 优化器。

从实验结果中可以看出, EfficientNet-CPBLS 模型展现出了很好的优越性,在 ACC、PRE、REC、F1 和 AUC 这些指标上都取得了不错的效果,并且在训练时间上相较于卷积神经网络方法大幅提升。EfficientNet-CPBLS 在 ACC 和 AUC 这两项指标上都取得了最好的成绩,在 F1 指标上略逊于 VGG-16。EfficientNet-CPBLS 模型在训练时间上表现出色,仅需 182.4 s 的训练时间就取得了优异的性能表现。相比之下,其他经典的卷积神经网络如 VGG-16、DenseNet-121、MobileNet-v3 等则需要更长的训练时间来达到类似的性能水平。表明 EfficientNet-CPBLS 模型能够在较短的训练时间内快速学习并取得优秀的分类效果。因为与传统的卷积神经网络不同, EfficientNet-CPBLS 模型无需进行迭代训练,意味着模型在训练过程中不需要反复调整参数和更新权重。该特性使得 EfficientNet-CPBLS 模型在训练过程中更加高效,节省了大量的计算资源和时间成本,并且在硬件资源受限(如没有 GPU 可以使用,只有 CPU 进行计算)的情况下仍然适用。

表 2 EfficientNet-CPBLS 与卷积神经网络对比实验结果

Tab. 2 Experimental results comparing EfficientNet-CPBLS with convolutional neural networks

模型	ACC/%	PRE/%	REC/%	F1/%	AUC/%	训练时间/s
AlexNet	90.92	91.24	91.17	90.96	92.63	853.7
GoogleNet	91.35	91.18	92.04	91.60	93.12	1596.7
ResNet-18	91.51	92.31	92.49	92.40	93.31	601.8
ResNet-50	91.92	92.85	92.37	92.61	93.57	1342.4
VGG-16	92.63	92.81	93.59	93.2	97.98	1506.7
DenseNet-121	92.38	92.29	93.24	92.76	98.73	1534.4
MobileNet-v3	92.74	93.33	92.95	93.14	98.49	1871.5
EfficientNet-CPBLS	92.83	93.28	93.07	93.17	98.86	182.4

然后,将 EfficientNet-CPBLS 模型与 BLS 相关方法 (BLS、CFBLS、CEBLS、CFEBLS、MRC-BLS^[29]) 进行对比实验。CEBLS、CFBLS 和 CFEBLS 都是基于 BLS 的级联变体结构,旨在进一步优化基础模型的性能。在实验过程中,针对 BLS

相关方法的参数选择,仍然采用网格搜索策略,将搜索范围限定在与 EfficientNet-CPBLS 相似的参数范围内,以确保实验的公平性和可比性。实验结果如表 3 所示。

表 3 EfficientNet-CPBLS 与 BLS 相关方法对比实验结果

Tab. 3 Experimental results comparing EfficientNet-CPBLS with BLS correlation methods

模型	ACC/%	PRE/%	REC/%	F1/%	AUC/%	训练时间/s
BLS	86. 48	86. 19	87. 71	86. 94	90. 08	82. 6
CFBLS	88. 91	89. 82	88. 95	89. 38	91. 77	90. 3
CEBLS	87. 57	88. 93	89. 32	89. 12	91. 19	89. 7
CFEBLS	89. 32	89. 74	91. 03	90. 38	92. 60	92. 8
MRC-BLS	92. 35	93. 11	93. 65	93. 38	97. 55	178. 1
EfficientNet-CPBLS	92. 83	93. 28	93. 07	92. 78	98. 86	182. 4

实验结果表明, EfficientNet-CPBLS 相较于 BLS 相关方法 (BLS、CFBLS、CEBLS、CFEBLS) 在各项评估指标上均取得了显著的提升, 表现出了更优异的性能, 为解决肺炎诊断问题提供了一种更有效的思路。另外, EfficientNet-CPBLS 的训练时间相较于 BLS 相关方法有所增加, 主要原因是引入了更加复杂的特征提取器 (EfficientNet-B4 网络)。这个特征提取器的引入使得模型能够更好地捕捉数据的特征和模式, 从而提高了模型的性能和泛化能力。尽管训练时间有所增加, 但这种增加是在可以接受的范围内, 并且带来了显著的

性能提升, 因此被认为是一种有效的权衡。

3.5 消融实验

为了验证 EfficientNet-CPBLS 模型中的级联金字塔模块和基于 EfficientNet-B4 网络的特征提取器模板的有效性, 本节设计并实现了消融实验, 实验结果如表 4 所示。在 Kermany 数据集上, 以原始 BLS 作为基准, 首先引入级联金字塔模块, 即得到 BLS + CP。然后, 在此基础上, 再引入基于 EfficientNet-B4 网络的特征提取器模板, 得到 BLS + CP + EfficientNet-B4, 将实验结果进行比较。

表 4 EfficientNet-CPBLS 消融实验结果

Tab. 4 Experimental results of EfficientNet-CPBLS ablation study

模型	ACC/%	PRE/%	REC/%	F1/%	AUC/%	训练时间/s
BLS	86. 48	86. 19	87. 71	86. 94	90. 08	82. 6
BLS + CP	89. 85	89. 91	90. 45	90. 18	93. 12	103. 3
BLS + EfficientNet-B4	90. 36	90. 48	91. 55	91. 01	95. 79	159. 7
BLS + CP + EfficientNet-B4	92. 83	93. 28	93. 07	92. 78	98. 86	182. 4

实验结果表明, 在原始 BLS 的基础上, 引入级联金字塔模块 (CP) 后, 模型性能有所提升, 在多项评价指标上均有提升, 训练时间略有增加。然后, 引入级联金字塔模块和预训练的 EfficientNet-B4 特征提取器, 模型性能得到了更显著的提升。虽然训练时间有所增加, 但相对于模型分类性能的大幅提升是值得的, 为模型应用于实际场景提供了更好的保障和效果。

3.6 增量实验

本节将展示模型的增量学习算法的快速性和有效性, 并在 Kermany 数据集上进行了相关实验, 评价指标选用 ACC、AUC、F1。首先, 对于 EfficientNet-CPBLS 的增量学习算法: 增加额外的增强节点, 设置特征节点为 500 保持不变, 增强节点的数量从 1 000 至 5 000 不断增加, 每次增

加 1 000。实验结果如表 5 所示, 从实验结果可以看出, 随着增强节点数量从 1 000 逐步增加至 5 000, 模型的性能指标均呈现逐步提升的趋势。具体来说, 随着增强节点数量的增加, 模型的准确率 (ACC) 从 91. 75% 到 92. 02% 逐步提升, AUC 从 95. 84% 到 97. 42% 不断增加, 而 F1 分数也从 91. 45% 增加至 92. 67%。综上所述, EfficientNet-CPBLS 的增量学习算法通过逐步增加增强节点数量, 可以有效提高模型的分类性能。

然后, 对于 EfficientNet-CPBLS 的增量学习算法: 增加额外的特征节点, 设置特征节点从 500 增加至 2 500, 每次增加 500, 增加节点数量从起始 1 000 也每次增加 500 至 3 000。实验结果如表 6 所示, 可以看出随着特征节点和增强节点的增加, 随之增加的训练时间也越来越多, 但模

型的性能指标 ACC、AUC、F1 仍然呈现逐步提升的趋势。具体来说,随着特征节点数量和增强节点数量的增加,模型的准确率(ACC)从 91.75% 逐步提升至 92.16%, AUC 指标从 95.84% 增加

至 97.11%, 而 F1 分数也从 91.45% 增加至 92.17%。综上所述, EfficientNet-CPBLS 的增量学习算法通过增加特征节点数量和增强节点数量对模型性能具有显著的正向影响。

表 5 增强节点的增量学习算法实验结果

Tab. 5 Experimental results of incremental learning algorithm for enhancement nodes						
特征节点数量	增强节点数量	ACC/%	AUC/%	F1/%	增加训练时间/s	累计训练时间/s
500	1 000	91.75	95.84	91.45	—	141.12
500	1 000→2 000	91.94	96.24	92.03	0.96	142.08
500	2 000→3 000	91.86	95.91	91.86	1.14	143.22
500	3 000→4 000	91.93	96.21	92.01	2.07	145.29
500	4 000→5 000	92.02	97.42	92.67	2.36	147.65

表 6 特征节点的增量学习算法实验结果

Tab. 6 Experimental results of incremental learning algorithm for feature nodes						
特征节点数量	增强节点数量	ACC/%	AUC/%	F1/%	增加训练时间/s	累计训练时间/s
500	1 000	91.75	95.84	91.45	—	141.12
500→1 000	1 000→1 500	91.83	95.97	91.84	3.13	144.25
1 000→1 500	1 500→2 000	92.11	96.20	92.05	5.78	150.03
1 500→2 000	2 000→2 500	92.08	96.14	92.04	8.52	158.55
2 000→2 500	2 500→3 000	92.16	97.11	92.17	14.61	173.16

最后,对于 EfficientNet-CPBLS 的增量学习算法:增加额外的训练样本,设置初始训练样本数量为 3 000,每次增加 500 个样本,增加至 5 000;特征节点数量从 500 递增至 2 500,每次增加 500;增强节点数量从 1 000 增加到 3 000,每次增加 500。实验结果如表 7 所示,可以明显看出,当不断增加新的训练样本,训练时间随之增加,模型的性能也逐步提升,而且提升的幅度较之前两种增

量算法更大。具体来说,随着训练样本数量、特征节点数量和增强节点数量的增加,模型的准确率(ACC)从 89.87% 逐步提升至 92.14%, AUC 指标从 92.81% 增加至 97.03%, 而 F1 分数也从 90.25% 增加至 92.11%。因此, EfficientNet-CPBLS 的增量学习算法通过增加训练样本数量能够更显著地提升模型的分类性能。

表 7 训练样本的增量学习算法实验结果

Tab. 7 Experimental results of incremental learning algorithm for training samples							
训练样本数量	特征节点数量	增强节点数量	ACC/%	AUC/%	F1/%	增加训练 时间/s	累计训练 时间/s
3 000	500	1 000	89. 87	92. 81	90. 25	–	91. 15
3 000→3 500	500→1 000	1 000→1 500	90. 35	92. 97	90. 88	11. 36	102. 51
3 500→4 000	1 000→1 500	1 500→2 000	91. 42	94. 09	91. 36	14. 67	117. 18
4 000→4 500	1 500→2 000	2 000→2 500	91. 89	95. 87	91. 79	20. 85	138. 03
4 500→5 000	2 000→2 500	2 500→3 000	92. 14	97. 03	92. 11	33. 91	171. 94

综上所述,模型的 3 种增量学习算法可以在不重新训练整个模型的情况下,通过增加训练样

本、特征节点或增强节点的数量,实现提升模型的性能。

4 结语

本研究成功构建了基于宽度学习系统变体结构的肺炎检测模型。通过级联金字塔结构的设计,提升了模型特征表示的层次性和丰富性,增强了模型对复杂医学图像的处理能力。同时,将 EfficientNet-B4 作为前置特征提取器,实现了在保持高精度的同时减少计算资源和时间消耗的目标。此外,本文还介绍了适用于本模型的增量学习算法,包括增加额外的增强节点、特征节点以及训练样本,进一步提升了模型的灵活性和泛化能力。最后,在 Kermany 数据集上,设计并进行对比实验、消融实验以及增量学习实验,验证了模型的有效性和优越性。

参考文献

- [1] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521: 436-444.
- [2] 梁隆恺,付鹤,陈峰蔚,等. 深度学习与医学图像处理[M]. 北京:人民邮电出版社,2023.
- [3] 蒋清婷,叶海良,曹飞龙. 基于三路径网络的医学图像分割方法[J]. 模式识别与人工智能, 2024, 37(1): 1-12.
JIANG Q T, YE H L, CAO F L. Medical image segmentation method with triplet-path network [J]. Pattern Recognition and Artificial Intelligence, 2024, 37(1): 1-12.
- [4] SHARMA H, JAIN J S, BANSAL P, et al. Feature extraction and classification of chest X-ray images using CNN to detect pneumonia[C]//2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence). Noida, India: IEEE, 2020: 227-231.
- [5] STEPHEN O, SAIN M, MADUH U J, et al. An efficient deep learning approach to pneumonia classification in healthcare[J]. Journal of Healthcare Engineering, 2019: 4180949.
- [6] KERMAN Y D S, GOLDBAUM M, CAI W J, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning[J]. Cell, 2018, 172(5): 1122-1131.
- [7] 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) [2024-03-10]. <https://arxiv.org/abs/1711.05225>.
- [8] JANIZEK J D, ERION G, DEGRAVE A J, et al. An adversarial approach for the robust classification of pneumonia from chest radiographs [C]// Proceedings of the ACM Conference on Health, Inference, and Learning. Toronto, Ontario, Canada: ACM, 2020: 69-79.
- [9] ZHANG J P, XIE Y T, PANG G S, et al. Viral pneumonia screening on chest X-rays using confidence-aware anomaly detection [J]. IEEE Transactions on Medical Imaging, 2021, 40(3): 879-890.
- [10] TUNCER T, OZYURT F, DOGAN S, et al. A novel Covid-19 and pneumonia classification method based on F-transform [J]. Chemometrics and Intelligent Laboratory Systems, 2021, 210: 104256.
- [11] CHEN C L, LIU Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [12] CHEN C L, LIU Z L, FENG S. Universal approximation capability of broad learning system and its structural variations [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(4): 1191-1204.
- [13] GONG X R, ZHANG T, CHEN C L, et al. Research review for broad learning system: Algorithms, theory, and applications [J]. IEEE Transactions on Cybernetics, 2022, 52(9): 8922-8950.
- [14] ZHANG T, WANG X H, XU X M, et al. GCB-Net: Graph convolutional broad network and its application in emotion recognition [J]. IEEE Transactions on Affective Computing, 2022, 13(1): 379-388.
- [15] WANG X H, ZHANG T, XU X M, et al. EEG emotion recognition using dynamical graph convolutional neural networks and broad learning system [C]//2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Madrid, Spain: IEEE, 2018: 1240-1244.
- [16] YANG Y X, GAO Z K, LI Y L, et al. A complex network-based broad learning system for detecting driver fatigue from EEG signals [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(9): 5800-5808.
- [17] PARHI P, BISOI R, DASH P K. Influential gene selection from high-dimensional genomic data using a bio-inspired algorithm wrapped broad learning system [J]. IEEE Access, 2022, 10: 49219-49232.
- [18] ZHAN C J, ZHENG Y F, ZHANG H J, et al. Random-forest-bagging broad learning system with applica-

- tions for COVID-19 pandemic[J]. IEEE Internet of Things Journal, 2021, 8(21): 15906-15918.
- [19] HAN R Z, LIU Z L, CHEN C L. Multi-scale 3D convolution feature-based broad learning system for alzheimer's disease diagnosis via MRI images[J]. Applied Soft Computing, 2022, 120: 108660.
- [20] LIU Z L, ZHOU J, CHEN C L. Broad learning system: Feature extraction based on K-means clustering algorithm [C]//2017 4th International Conference on Information, Cybernetics and Computational Social Systems. Dalian, China: IEEE, 2017: 683-687.
- [21] YANG F. A CNN-based broad learning system [C]//2018 IEEE 4th International Conference on Computer and Communications. Chengdu, China: IEEE, 2018: 2105-2109.
- [22] TAN M X, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks [EB/OL]. (2019-05-28) [2024-03-10]. <http://arxiv.org/abs/1905.11946>.
- [23] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [24] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: IEEE, 2015: 1-9.
- [25] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770-778.
- [26] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2024-03-10]. <https://arxiv.org/pdf/1409.1556>.
- [27] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 2261-2269.
- [28] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [EB/OL]. (2017-04-17) [2024-03-10]. <https://arxiv.org/abs/1704.04861>.
- [29] MA Y, LIU Z, CHEN C L. Multiscale random convolution broad learning system for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 5503605.

(编辑 张欢)