

# 基于 AlexNet 模型和自适应对比度增强的乳腺结节 超声图像分类

陈思文<sup>1,2</sup> 刘玉江<sup>3</sup> 刘冬<sup>3</sup> 苏晨<sup>3</sup> 赵地<sup>1</sup> 钱林学<sup>3</sup> 张佩珩<sup>1</sup>

(中国科学院计算技术研究所 北京 100190)<sup>1</sup>

(北京邮电大学国际学院 北京 100089)<sup>2</sup>

(首都医科大学重点实验室 北京 100069)<sup>3</sup>

**摘要** 乳腺癌是女性是最常见的恶性肿瘤之一,其发病率有逐年增高的趋势,严重威胁着患者健康。如何取代传统活体穿刺,快速准确地对乳腺结节进行良恶性判断,近年越来越受到关注。医学研究表明,良恶性结节在边缘处呈现较为显著的差异,因此对边界加强处理的算法为判断乳腺结节良恶性的深度学习提供了新思路。文中实验数据库的构建基础得到首都医科大学附属北京友谊医院的支持。在比较 5 种边界增强算法后对图像进行扩增,并采用在图像分类方面十分出色的 AlexNet 网络模型。将分别经过线性、非线性对比度拉伸、直方图均衡化、直方图阈值化以及自适应对比度增强算法处理后的数据用于 AlexNet 模型,比较 5 种算法对 AlexNet 模型准确度的影响,得出更适用于乳腺结节超声图像的预处理算法。扩增后的数据集图像总数量超过一万张,其中训练集占 80%,验证集与测试集各占 10%。最终,通过绘制 ROC 曲线计算敏感度、特异度、精确度参数,对测试结果进行评估,并得到了较好的测试结果。

**关键词** 乳腺癌,乳腺结节,深度学习,卷积神经网络,AlexNet 模型,图像预处理,自适应增强对比度算法

中图分类号 TP391.5 文献标识码 A

## AlexNet Model and Adaptive Contrast Enhancement Based Ultrasound Imaging Classification

CHEN Si-wen<sup>1,2</sup> LIU Yu-jiang<sup>3</sup> LIU Dong<sup>3</sup> SU Chen<sup>3</sup> ZHAO Di<sup>1</sup> QIAN Lin-xue<sup>3</sup> ZHANG Pei-heng<sup>1</sup>

(Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China)<sup>1</sup>

(International School, Beijing University of Posts and Telecommunications, Beijing 100089, China)<sup>2</sup>

(Key Laboratory, Capital Medical University, Beijing 100069, China)<sup>3</sup>

**Abstract** Breast cancer is one of the most common malignant tumors of women. The incidence of breast cancer is increasing year by year, which seriously threatens the health of the patients. In recent years, more and more attention has been paid to how to replace the traditional needle biopsy in the diagnosis of benign and malignant breast nodules. Medical research shows that significant differences exist on the edge of benign and malignant nodules. So the algorithm of boundary enhancement treatment provides a new way for the study of judgment of benign and malignant breast cancer. The database was constructed with the support of Beijing Friendship Hospital which is affiliated to Capital Medical University. The images are expanded based on the comparison of 5 kinds of boundary enhancement (ACE) algorithm. AlexNet network model is used which is excellent in image classification. The data processed by linear, nonlinear contrast stretching, histogram equalization, histogram thresholding and adaptive contrast enhancement algorithm are applied to the AlexNet model. The influence of the five algorithms on the accuracy of AlexNet model is compared, and a preprocessing algorithm, which is more suitable for ultrasonic images of breast nodules, is obtained. The total number of images in the expanded data set is more than ten thousand, of which the training set is 80%, and the verification set and the test set account for 10% each. Finally, the sensitivity, specificity and accuracy parameters are calculated by plotting the ROC curve, and the test results are evaluated. The better test results are obtained.

**Keywords** Breast cancer, Breast nodules, Deep learning, Convolutional neural network, AlexNet model, Image preprocessing, Automatic contrast enhancement algorithm

本文受北京市自然科学基金重点项目(4161004),北京市科技计划项目(Z17110000117001, Z161100000216143),国家重点研发计划项目(2018ZX10723203)资助。

陈思文(1996—),女,主要研究方向为深度学习;刘玉江(1984—),男,博士,副研究员,主要研究方向为超声医学、医学人工智能;刘冬(1984—),男,博士,副研究员,主要研究方向为超声医学、医学人工智能;苏晨(1993—),女,博士,副研究员,主要研究方向为超声医学、医学人工智能;赵地(1978—),男,博士,副研究员,主要研究方向为深度学习、类脑计算、脑科学, E-mail: zhaodi@escience.cn(通信作者);钱林学(1965—),男,博士,主要研究方向为超声医学、医学人工智能;张佩珩(1960—),男,博士,教授,主要研究方向为深度学习、类脑计算、脑科学。

## 1 引言

乳腺癌是女性最常见的恶性肿瘤之一,其发病率有逐年增高的趋势,严重威胁患者健康。如何快速准确地对乳腺结节进行确诊,近年越来越受到关注。目前,乳腺常规检查方式包括超声检查、X 线钼靶检查及 MRI 检查,而超声以其无创、无痛苦、价格便宜、准确率较高成为乳腺的首选检查方式。乳腺结节的诊断主要依靠超声医师的操作方法及经验,高年资医师与低年资医师诊断阳性率差异较大。目前乳腺结节性质的诊断仍主要依赖于结节活检的病理结果,会给一些良性结节的患者带来较大的心理及经济压力。如何快速分析、诊断乳腺结节,是本研究所面临的关键问题。因此本研究旨在通过基于超声影像大数据分析的乳腺结节诊断的决策支持的分布式集群计算与利用图像处理单元(Graphic Processing Unit,GPU)算法,对乳腺癌进行快速智能诊断,并在此基础上对该算法进行推广应用,对更多组织器官的疾病进行大数据分析,并进行影像的人工智能后处理,以对更多的疾病进行分析、诊断。


目前,国内外对于乳腺结节人工智能的应用主要有以下两个常见的算法:

1) 基于纹理特征的检测方法<sup>[3]</sup>。此类方法主要依靠提取中心矩、熵等纹理特征,应用现行分类器来识别肿瘤并判定良恶性。然而这类方法并没有考虑到肿瘤的一些特殊形态及表现,易出现假阳性及假阴性。

2) 基于形态学的检测方法<sup>[6]</sup>。先对肿瘤进行半自动分割,并提取肿瘤特征以进行乳腺癌的分级诊断。这类方法过度依赖分割效果,会出现特征提取不全面的情况。对于体积过大的肿瘤,不能充分提取该特征。并且半自动分割及应用部分数据定量分析的耗时较长,无法满足大数据时代的数据建立需求。

本文对基于乳腺结节超声影像的人工智能后处理有以下贡献:

1) 本实验针对良性、恶性肿瘤进行了增强边界效果的处理。良性、恶性结节在边缘处呈现较为显著差异的特点:良性(恶性风险 $< 2\%$ )结节呈卵圆形,有 2 个或 3 个浅分叶;(线形壁)界限边缘清楚;具有均质性;边缘声影走向与皮肤平行;缺少任何可疑特征。恶性结节形状不规则;边缘分界不清楚;中心性声影;结构扭曲;走向与皮肤不平行;具有不均质结构。基于以上差异(如图 1 所示),ACE 算法可通过差分来计算目标点与周围像素点的相对明暗关系来校正最终像素值,对影像有很好的增强效果。这一图像预处理方式给良性、恶性结节的预判带来新思路。



(a) 乳腺恶性结节 (b) 乳腺良性结节 (c) 正常腺体

图 1 乳腺结节的超声图像

2) 本文采用近年来由 CNN 模型发展起来的深度卷积模型 AlexNet。该模型不仅具有卷积网络针对图像特征提取迅速的优势,同时,虽然只有八层结构,但有 60M 以上的参数总量,相比于传统 CNN 模型深度更大、学习表达能力更强。卷

积模型通过依次学习前一层的高维的低级表示形成低维度较抽象的表示,用以发现数据的分布式特征表示。该模型符合当前基于内容的图像检索的特点。浅层模型的特征的维度大,与输入图像的相关性高,模型的泛化能力低;深层模型的特征的维度大,与输入图像的相关性低,模型的泛化能力高。

3) 深度学习需要大量的训练成本才能达到准确分类的要求。本文采用异构并行和 GPU 集群计算,以及单个 GPU 的 SIMD 并行,实现了基于超声影像大数据分析的乳腺癌诊断的决策支持算法的异构并行的最佳实现方式、GPU 集群的负载均衡,以及各个计算部分基于 GPU Direct 的通信方式。设备使用曙光 W780-G20,利用 8 块 NVIDIA Tesla K80,使 4 个分类器同时进行训练,大大节约了训练时间。

4) 本文的数据支持由北京首都医科大学附属友谊医院乳腺超声数据库提供。友谊医院超声科具有庞大的乳腺结节诊疗图像库,为本文的数据训练集奠定了扩增基础。本实验验证工作由友谊医院的资深医生协助完成,进一步加强了实验的准确性与临床适用性。

本实验使用深度学习(Deep Learning,DL)方法,用网络模型训练大量的乳腺结节图像,找出良性与恶性结节特征,进而进行预测。深度学习是机器学习的重要组成部分,它通过模拟人脑来分析、解释数据,其重点在于建立与人脑相似的神经网络。人脑的复杂程度难以想象,所以建立相匹配的网络模型并非易事。通过大量的研究,实验选用 AlexNet 模型作为预判良性、恶性结节的基础训练模型。AlexNet 是 2012 年由 Krizhevsky 等提出的 8 层卷积神经网络,对图像识别分类处理有杰出贡献。

## 2 基本概念

卷积神经网络(Convolutional Neural Network,CNN)是一种多层网络模型,是深度学习的神经网络模型。训练好的过滤器和局部邻域池化操作交替作用在输入的图片上,然后输出一系列越来越复杂的特征。它是对 BP(Back Propagation)神经网络的一种改进。它们的共同点是都采用前向传播输出计算值,利用反向传播调整权重和偏置。但 CNN 在层与层之间采用局部连接,而 BP 神经网络采用的是全连接。这个局部连接的概念被命名为局部感受野。CNN 在原始输入中重复使用卷积操作和局部池(pooling)操作得到越来越复杂的特征图(feature map)。CNN 中的层(layer)由各图(map)组成,每个 map 由多个神经元构成。map 起到过滤器的作用,同一个 map 的所有神经元共用一个特征,这个特征叫作卷积核,在 CNN 中被命名为权重。针对这个特征计算输入图片的卷积值,其中数值最大的区域与特征匹配,得到合适的特征,并将其输入到下一层结构中。但计算卷积值会耗费许多时间成本,其实在实际操作中只是用固定大小的权重矩阵与输入图片比对,而不是真正地计算。

CNN 的历史可以追溯到 1962 年,Hubel 和 Wiesel 通过毛的视觉皮层细胞提出了感受野(Receptive Field,RF)的概念。RF 的经典定义是影响神经元工作的一个视觉空间。通俗来说,RF 就是特征图与输入图像的某个区域匹配,这个区域就叫作感受野。之后,日本学者 Fukushima 基于感受野提出了神经认知机制,这可以认为是最早的 CNN。神经认知机在理论上可以识别文字,但需要大量的神经元。在实现上还

存在困难,而且对大小改变、平移等数学变换束手无策。随着 CNN 发展的深入,多层次高适应的网络结构出现。现在可以实现手写文字的识别、物体识别等图像分类问题。

由于 CNN 在图像识别上的优势,实验决定使用多层 CNN 网络作为训练模型。

卷积过程由 3 个带有偏置的过滤器完成,每个过滤器带有一个卷积核。对预处理过的超声图像进行卷积操作,然后加一个偏置得到卷积层。接下来,进入池化过程,通过求和、增加权重与偏置、激活函数计算等操作得到新的特征图。池化操作是对特征进行聚合统计的过程。这些特征可能分布在不同区域,池化只需要计算某个部分的某个特征的平均值或者最大值,而不需要关联所有特征。经过池化操作后还需要经过多次卷积和池化才能保证特征被完全识别。在经历几个周期后,图片上的像素值被栅格化(rasterize),连接成一个长向量输入到传统的神经网络中,得到输出。图 3 所示为一个完整的 CNN 框架。需要注意的是,大多 CNN 都不止经过一个周期的卷积、池化过程,而且卷积、池化过程也不一定要组合出现。




图 2 卷积神经网络

1)特征提取:特征提取作用在卷积层。神经元连接上一层的局部感受野,然后进行特征提取。特征的位置取决于现有的其他特征。

2)特征映射:特征映射作用在池化层,也叫作子采样层。它具有平移不变性,在特征经过移动后还可以做出正确的判断,在图像识别中很有优势。另外,在神经元之间进行权值共享可以达到减少自由参数的目的。

一般情况下,经过卷积层后匹配的数量会出现变化,这是卷积核的不同所造成的。但是在最大池化(max-pooling)操作后,匹配数量是不变的,因为池化并不改变特征的数量,只是聚合统计的一种方法。

CNN 优于其他网络结构的地方在于局部感受野和权值共享。例如:在一张  $256 \times 256$  的乳腺图像中,假设隐层神经元为  $256 \times 256$ ,如果使用传统神经网络做全连接,那么将产生  $256^4 = 4\,294\,967\,296$  个连接。如果引入局部感受野,每个神经元不需要连接所有像素点,也即不需要做全连接。若假设局部感受野为  $10 \times 10$ ,现在  $256 \times 256$  个神经元只需要与局部感受野连接,也就是  $256 \times 256 \times 10 \times 10 = 6\,553\,600$  个连接,是之前连接的  $1/65$ 。而且 CNN 的卷积层如果用同一个卷积核对图像操作,那么不论隐层神经元多大,这之间的权值共享只有 100,这是其他传统神经网络所望尘莫及的。

### 3 数据集和预处理

#### 3.1 乳腺结节超声图像

本文的实验数据由首都医科大学附属北京友谊医院具有穿刺或手术病理结果的超声影像数据库提供。北京友谊医院超声科具有多年的乳腺结节的诊断的经验,为本文奠定了坚

实的医学临床经验的基础。

#### 3.2 乳腺结节超声图像预处理

原始数据是直接来自医院获得的乳腺超声图像,需要根据建立大数据集的标准要求进行数据预处理工作。本实验基于由英伟达(NVIDIA)公司开发的第一个交互式深度学习 GPU 训练系统-DIGISTS,目的在于整合现有的 Deep Learning 开发工具,实现深度神经网络(Deep Neural Network, DNN)的设计、训练和可视化等任务。该软件可以将原始数据进行预处理操作,统一为像素  $256 \times 256$  的图片,作为实验数据集。

#### 3.3 数据预处理的方法探索

数据预处理阶段作为医学人工智能超声影像处理的前阶段,对后续实验结果的准确性有重大影响。由于医学图像本身及成像条件的限制,图像的对比特度很低。因此,探索适用于乳腺结节超声影像的人工智能前处理方法将具有较大意义。此类方法一般遵循一定的视觉原则。众所周知,人眼对高频信号(边缘处等)比较敏感。然而,细节信息往往是高频信号,却时常因嵌入在大量的低频背景信号中使得其视觉可见性降低。结合良恶性结节在边缘处呈现较为显著的差异,拟探索一种可加强结节边界清晰度的算法,这是本文的主要创新点之一。

线性拉伸是输出灰度值与输入灰度值呈线性关系的像素级运算,通过计算可线性调节图像对比度。

##### 算法 1 传统的线性对比度拉伸

1)灰度变换的一般公式为:

$$D_b = f(D_a) = a(D_a) + (b)$$

若  $a > 1$ ,则输出图像的对比特度将增强;若  $a < 1$ ,则输出图像的对比特度将减弱。其中,  $D_a, D_b$  分别为图像前后对比度。

2)对各参数赋值,得到输出图像。

非线性拉伸是输出灰度值与输入灰度值呈非线性关系的非像素级运算。

##### 算法 2 非线性拉伸

1)灰度变换的一般公式为:

$$g_{ij} = F(f_{ij})$$

其中,  $i, j = 0, 1, \dots, L-1, L$  为灰度级。

2)  $F(x) = x + cx(L-1-x)$

若  $c > 0$ ,则中间灰度范围加强;若  $c < 0$ ,则中间灰度范围减弱。其中,  $F(x)$  的格式可以是抛物线、正弦函数、正切函数等非线性函数。

3)得到输出图像。

本实验选用的函数图像如图 3 所示。




图 3  $F(x)$  函数图像

利用图像灰度直方图可以直观地看出图像中的像素亮度分布情况,可进一步提高超声图像的识别度。

##### 算法 3 直方图均衡化

1)对在图像中像素个数多的灰度值进行展宽,而对像素个数少的灰度值进行归并,从而达到清晰图像的目的。

2)若图像的灰度分别集中在较窄的区间,将引起图像细节模糊,可通过改善各部分亮度的比例关系,即通过直方图均衡化的方法来增强图像。

- 3) 根据原图像的直方图统计值就可算出均衡化后各像元的灰度值。
- 4) 直方图上灰度分布较密的部分被拉伸;灰度分布稀疏的部分被压缩,使图像对比度总体上得到增强。
- 5) 得到输出图像。

阈值法是一种简单有效的图像分割方法,它用一个或几个阈值将图像的灰度级分为几个部分,认为属于同一个部分的像素是同一个物体。结合乳腺超声图像良恶性结节在边缘处有明显差异的特点,本实验采用基于区域的全局阈值法。阈值分割法的结果很大程度上依赖于对阈值的选择,因此该方法的关键是如何选择合适的阈值。

#### 算法4 直方图阈值法

- 1) 设  $(x, y)$  是二维数字图像的平面坐标,图像灰度集的取值范围是  $G = \{0, 1, 2, \dots, L-1\}$  (通常 0 代表最暗的像素点,  $L-1$  代表最亮的像素点), 位于坐标点  $(x, y)$  上的像素的灰度级表示为  $f(x, y)$ 。设  $t \in G$  为分割阈值,  $B = \{b_0, b_1\}$  代表一个二值灰度级, 并且  $b_0, b_1 \in G$ 。于是图像函数在阈值  $t$  上的分割结果可以表示为:

$$f_i(x, y) = \begin{cases} b_0, & f(x, y) < i \\ b_1, & f(x, y) \geq i \end{cases}$$

- 2) 阈值分割法实际就是按某个准则函数求最优阈值  $i^*$  的过程。设灰度级为  $i$  的像素点个数为  $m_i$ , 则图像的像素点的总数目  $M$  为:

$$M = \sum_{i=0}^{L-1} m_i$$

灰度级  $i$  的出现概率为:

$$p_i = m_i / M$$

- 3) 得到输出结果。

基于超声乳腺结节图像的边缘特点,局部对比度增强的算法较为合适。而在局部对比度增强方面,两种方法比较完善。一种是自适应直方图均衡化(AHE),AHE 算法使用局部的直方图的相关信息对数据进行映射,这改变了图像的对比度,但是需要大量的计算。另一种是自适应对比度增强(ACE)。下面详细介绍 ACE 算法。

#### 算法5 自适应对比度增强(ACE)法

- 1) 假定  $x(i, j)$  是图像中某点的灰度值,局部区域的定义为:以  $(i, j)$  为中心,窗口大小为  $(2n+1) \times (2n+1)$  的区域,其中  $n$  为一个整数。当然这个窗口区域不一定是正方形。局部的平均值,也就是低频部分,可以用下式计算:

$$m_x(i, j) = \frac{1}{(2n+1)^2} \sum_{k=i-n}^{i+n} \sum_{l=j-n}^{j+n} x(k, l)$$

局部方差为:

$$\sigma_x^2(i, j) = \frac{1}{(2n+1)^2} \sum_{k=i-n}^{i+n} \sum_{l=j-n}^{j+n} [x(k, l) - m_x(i, j)]^2$$

其中,  $\sigma_x(i, j)$  是局部标准差(Local Standard Deviation)。

- 2) 定义  $f(i, j)$  表示  $x(i, j)$  对应的增强后的像素值,则 ACE 算法可以表示为:

$$f(i, j) = m_x(i, j) + G(i, j) [x(i, j) - m_x(i, j)]$$

其中,函数  $G(i, j)$  是上文提到的 CG。一般情况下 CG 总是大于 1 的,这样高频成分  $[x(i, j) - m_x(i, j)]$  就能得到增强。

- 3) 若 CG 的取值为常数,图像中的所有高频部分都被同等放大,可能有些高频部分会出现过增强现象。最优的解决方案就是使用不同的增益:

$$f(i, j) = m_x(i, j) + \frac{D}{\sigma_x(i, j)} [x(i, j) - m_x(i, j)]$$

其中,  $D$  是常数。这样,CG 是空间自适应的,并且与局部均方差成反比,在图像的边缘或者其他变化剧烈的地方,局部均方差比较大,因此 CG 的值就比较小,这样就不会产生振铃效应。然而,在平滑的区域,局部均方差会很小,因此 CG 的值比较大,从而引起了噪音的放大。所以,ACE 算法对乳腺良恶性结节超声影像在边界处差异明显这一特征进行了较好的处理。

- 4) 得到输出图像。

## 4 实验

### 4.1 训练集与测试集

实验共有 10440 张扩增后的图像,其中 8288 张作为训练集,1076 张作为验证集,1076 张作为测试集,各占总图像数量的 80%, 10%, 10%。

### 4.2 卷积神经网络 AlexNet

实验要选取适合处理医学图像的模型,我们选取 AlexNet 作为训练的网络模型原型。我们发现 AlexNet 在医学图像识别上有自身的优势。AlexNet 有 8 层结构,在图片识别上表现出色。它由 Krizhevsky 等人发明并夺得了 2012 年 ImageNet 比赛的冠军。该模型将 ImageNet 的正确识别率提高了一倍多。

若采用两台 GPU 服务器,将出现两个流程图,这里以一台 CPU 服务器为例进行描述。该模型一共分为 8 层,5 个卷积层,以及 3 个全连接层,每一个卷积层中包含了激励函数 RELU 以及局部响应归一化(Local Response Normalization, LRN)处理,然后再经过降采样(pool 处理)。我们选取一张测试图片对每一层进行分析。

- 1) 对于 conv1 层:输入 Input 的图像规格  $224 \times 224 \times 3$  (RGB 图像),实际上会经过预处理变为  $227 \times 227 \times 3$  规格。




图4 标准化后的数据

- 2) 本实验使用的是 96 个大小规格为  $11 \times 11$  的过滤器 filter,或者称为卷积核,进行特征提取。需要特别注意:原始图片为 RGB 图像,是 3 个通道的,而这 96 个过滤器也是三通道的,即我们使用的实际大小规格为  $11 \times 11 \times 3$ ,也就是原始图像是彩色的,提取到的特征也是彩色的,在卷积时,会依据以下公式来提取特征图:

$$\lfloor \text{img\_size} - \text{filter\_size} \rfloor / \text{stride} + 1 = \text{new\_feature\_size}$$

因此得到的特征图大小为:

$$\lfloor (227 - 11) / 4 + 1 \rfloor = 55$$

其中,  $\lfloor \text{img\_size} - \text{filter\_size} \rfloor$  表示向下取整。得到的新的特征图规格为  $55 \times 55$ ,因为提取到的特征图是彩色的,这样得到了 RGB 通道的 96 个  $55 \times 55$  大小的特征图。

在使用过滤器 filter 和数据进行卷积时,我们使用的卷积核尺寸是  $11 \times 11$ ,也就是采用局部连接,每次连接  $11 \times 11$  大小的区域,然后得到一个新的特征,在此基础上再卷积,从而再得到新的特征,也即对传统上采用的全连接的浅层次神经网络增加隐藏层,通过权重共享来逐步扩大局部视野,最后达到全连接的效果,以节约内存。

- 3) 使用 RELU(Rectified Linear Units)激励函数来确保特征图的值在合理范围之内。

- 4) 降采样处理(pool 层也称为池化),其在 digits 中的输出如图 5 所示。




图5 池化后的输出

5)使用局部区域归一化(LRN),对降采样的特征图数据进行提取。源码默认的是 ACROSS\_CHANNELS,跨通道归一化。*local size*(局部值)为5,表示局部弱化在相邻5个特征图间中求和并且每一个值除去这个和。官方提供的内核大小为 $3 \times 3$ ,该过程就是对 $3 \times 3$ 区域的数据计算区域均值、最大值、最小值。通过降采样处理,可以得到96个 $27 \times 27$ 的特征图,然后将这些特征图作为输入数据,进行第二次卷积。




图6 经LRN后 norm1 输出

6)全连接处理。这里使用4096个神经元,对256个大小为 $6 \times 6$ 特征图进行一个全连接,也就是将 $6 \times 6$ 大小的特征图进行卷积变为一个特征点。该点是将256个特征图中某些特征图卷积后得到的特征点乘以相应的权重,再加上一个偏置得到的。




图7 fc6 全连接图

fc8 链接层和 fc6 类似,采用的是1000个神经元,对 fc7 中4096个神经元进行全连接,通过高斯过滤器得到1000个float型的值。若是训练模型,会通过标签 label 进行误差比对,然后求解出残差,再通过链式求导法则将残差通过求解偏导数逐步向上传递,并将权重进行推倒更改,类似于BP网络,逐层地调整权重及偏置。

### 5 结果和评价

使用前文提到的5种算法分别处理数据,得到的结果如下。

#### 1)算法1的结果

根据前文介绍的线性对比度拉伸算法,得到图像处理结果,如图8所示。




图8 经算法1处理后的图像对比图

由图8可知,线性对比度拉伸得到的结果边界明显清晰,但存在的问题是由于各图像的灰度分度不同,无法统一线性

灰度值的变化范围。

#### 2)算法2的结果

根据前文介绍的非线性对比度拉伸算法,得到图像处理结果,如图9所示。




图9 经算法2处理后的图像对比图

通过分析可以发现,非线性拉伸的图像处理结果与曲线的选取有重要关系,此方法仍需进行如何选取最优曲线的探究。图9中的曲线是查找深色与浅色的最佳曲线,但实验结果中显示,深色与浅色的差异仍不够明显。

#### 3)算法3的结果

根据前文介绍的直方图均衡化算法,得到图像处理结果,如图10所示。




图10 图像及直方图前后对比图

对实验结果进行反思可知,虽然直方图均衡化法是一个相当直观的技术并且是可逆操作,如果已知均衡化函数,那么就可以恢复原始的直方图,且操作简单。但该方法也存在以下缺点:

- ①变换后图像的灰度级减少,某些细节消失;
- ②对于某些图像,如直方图有高峰,经处理后对比度不自然地过分增强。

这种方法的缺点是其由于对处理的数据不加选择,可能会增加背景杂讯的对比度并且降低有用信号的对比度。

#### 4)算法4的结果

根据前文介绍的直方图阈值法算法,得到图像处理结果,如图11所示。

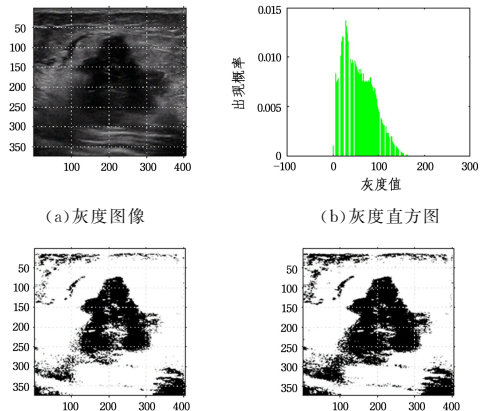


图11 算法4处理过的图像

图11 算法4处理过的图像

通过分析可以发现,该方法提取出的分割图像会包含冗余信息或缺少重要信息,这是由于超声图像信息依赖于探头摆放的位置。另外,由于结节内部的成分不均一,会造成结节内部回声不均匀现象。

5)算法 5 的结果

根据前文介绍的自适应对比度增强算法,得到图像处理结果,如图 12 所示。




图 12 经算法 5 处理后的图像对比图

通过分析,初步可得基于自适应增强(ACE)的通过差分计算目标点与周围像素点的相对明暗关系来校正最终像素值,有很好的增强效果。该方法针对上万张图像灰度分布差异较大这一特点做了相关改进。算法本身的适应能力较强,因此更适合超声乳腺结节的医学图像的前处理工作。

将上述 5 种算法处理后的图像导入 digits 的数据集,通过测试结果可知,算法 5(自适应对比度增强算法)的精确度最高。由于训练集需要大量数据,接下来,对算法 5 处理后的数据进行数据扩增,方法包括水平对称、垂直对称、旋转、加入 15% 噪点,这样原始 985 张数据可扩增至 10440 张,将其导入 digits 数据集,将数据集分为 3 类:80%用于训练,10%用于验证,10%用于测试模型选取 AlexNet 模型得到的测试结果如图 13 所示。




图 13 未经边界处理的深度学习曲线

我们将经算法 5 处理并扩增后的数据与经过没有经过边界处理但进行扩增后的数据导入 digits 的数据集,并用 AlexNet 模型进行训练,得到的训练结果图如 14 所示。




图 14 经 ACE 算法处理后的深度学习曲线

经算法 5 处理后的数据测试结果相比未经边缘化处理的数据训练结果明显提高了近 2 个百分点,进一步说明算法 5 对乳腺结节良恶性超声图像的判断具有适用性。

对训练好的模型进行测试,测试数据有 1231 张,测试结果如表 1 所列。

表 1 测试集的验证结果

	恶性(真实值)	良性(真实值)	准确度/%
恶性(测试值)	482	29	94.32
良性(测试值)	8	712	98.89

将计算结果可视化之后,与上文详细阐述的 CNN 结果的应用示例相对应。实验输入的训练集为灰度图,但根据 AlexNet 网络结构,输入为  $227 * 227 * 3$  (3 代表 RGB 三通道),因此服务器将灰度图转化成彩色图。CNN 经过多个周期的卷积、池化过程后输出最终测试结果。

由表 2 可知,ACE(自适应增强对比度)算法在处理超声乳腺图像上明显好于其他算法。为了分析 3 种处理的优缺点,实验基于测试结果绘制了受试者工作特征曲线(ROC),计算灵敏度、特异度。ROC 曲线广泛用于医学诊断,可以通过统计数据确定疾病的最佳诊断点。ROC 曲线只针对二分类问题,图 15 是针对表 2 中 3 种处理方法做出的 ROC 曲线。

表 2 经 3 种不同处理后的结果比较

(单位:%)

	未做边缘处理	直方图均衡化算法	ACE 算法
精确度(accuracy)	94.0557	96.5993	98.0769
损失(loss)	0.153818	0.106628	0.055222




图 15 根据未经处理、经直方图均衡化算法处理、经 ACE 算法处理结果绘制的 ROC 曲线

在 ROC 曲线中有两个重要指标:灵敏度(sensitivity)和特异度(specificity)。灵敏度又叫真阳性率(TPR),是正样本预测结果数和正样本实际数的比值。100-特异度又叫做假阳性率(FDR),指被预测为正样本但其实是负样本的结果数和负样本实际数的比值。不难推测,特异度就是负样本预测的结果数与负样本实际数的比值。在医生看来,精确判断良性、恶性肿瘤是当务之急,所以 TPR 越高越好;如果把良性误诊为恶性可能会引起严重的后果,所以 FPR 越低越好。如果医生对恶性很敏感,那么统计数据中 TPR 会很高,相应地 FPR 也会很高。所以这两个指标是相互制约的。理想的情况是  $TPR=1, FPR=0$ ,即把所有的恶性结节都正确诊断出来,并且没有误诊任何一个有良性结节的患者。在 ROC 曲线上,如果拐角越接近左上方,说明结果越理想。ROC 曲线下方面积

代表诊断的精确度(AUC)。表3列出了未经边缘处理、经直方图均衡化算法处理、经ACE算法处理过后的ROC曲线与统计数据。

表3 3种经不同处理后的精确度比较

方法	精确度(AUC)
未经处理组	0.8687
直方图均衡化算法组	0.9125
ACE算法组	0.9325

从统计数据和ROC曲线不难看出,经ACE算法处理后的数据集在判断良性、恶性结节上更有优势,它的AUC值达到0.9325。因此从精确度角度分析,ACE算法组优于直方图均衡化算法组与未经处理组。这进一步说明了基于边缘进行图像前处理对于乳腺结节良恶性判断具有重大意义,也为深度学习的发展带来新思路。在对测试组进行测试时虽然得出了较准确的结果,但临床实验更加复杂与多样,本实验究竟是否可以面对临床考验,依旧给实验者带来希望与挑战。

**结束语** 本文对基于乳腺结节超声影像的人工智能后处理提供了以下思路:

1)根据良恶性结节在边缘处出现较大特征差异这一特点,对构建的大数据集的图像前处理工作进行了增强边缘效果的前处理。

2)分别对5种算法进行测试与比较,最终选取准确率与AUC值较高的自适应对比度增强(ACE)算法。选取有8层结构的AlexNet模型对训练集的数据进行训练,经历了验证后对测试集进行测试,所提算法展示出了较好的分类效果。

本文为人工智能处理乳腺结节良恶性分类带来了新思路,有望给严重危及现代女性健康的乳腺癌的早诊早治以及避免活体穿刺的检查带来新希望。然而,实验如何与临床诊断完美结合,仍是今后我们的探索和研究方向。

## 参考文献

- [1] DOI K. Computer-aided diagnosis in medical imaging: history review, current status and future potential [J]. *Computerized Medical Imaging and Graphics*, 2007, 31: 198-211.
- [2] GUPTA A, AYHAN M, MAIDA A. Natural image bases to represent neuroimaging data[C]// *Proceedings of the 30th International Conference on Machine Learning (ICML-13)*. Atlanta, USA, 2013: 987-994.
- [3] CHEN W J, MU W. Value texture feature analysis of MRI dynamic contrast enhancement in diagnosis of benign and malignant breast nodules [J]. *Chin. J. Med. Imaging Technol.*, 2017, 33(5): 647-651.
- [4] MEHDY M M, NG P Y, SHAIR E F, et al. Artificial Neural Networks in Image Processing for Early Detection of Breast Cancer [J]. *Computational and Mathematical Methods in Medicine*, 2017: 1-15.
- [5] HIZUKURI A, NAKAYAMA R, ASHIBA H. Segmentation Method of Breast Masses on Ultrasonographic Images Using Level Set Method Based on Statistical Model [J]. *Journal of Biomedical Science and Engineering*, 2017, 10(4): 149-162.
- [6] SU Y N. Automatic Detection and Classification of Breast Tumors in Ultrasonic Images Using Texture and Morphological Features [J]. *The Open Medical Informatics Journal*, 2017, 11: 26-37.
- [7] GUO Y H, CHENG H D, ZHANG Y T. Breast Ultrasound Image Segmentation Based on Particles Swarm Optimization And The Characteristics of Breast Tissue [J]. *Natural Computation*, 2011, 7(1): 135-154.
- [8] MINAVATHI M, MURALI S, DINESH M S. Classification of Mass in Breast Ultrasound Images using Image Processing Techniques [J]. *International Journal of Computer Applications*, 2012, 42(10): 29-36.
- [9] BANDYOPADHYAY S K. Pre-processing of Mammogram Images [J]. *International Journal of Engineering Science and Technology*, 2010, 2(11): 6753-6758.
- [10] ZHANG J, WANG C, CHENG Y. Comparison of despeckle filters for breast ultrasound images [J]. *Circuits Syst. Signal Process*, 2015, 34(1): 185-208.
- [11] QUAN L, ZHANG D, YANG Y, et al. Segmentation of tumor ultrasound image via region-based ncut method [J]. *Wuhan Univ. J. Nat. Sci.*, 2013, 18(4): 313-318.
- [12] ZHOU Z, WU W, WU S, et al. Semiautomatic breast ultrasound image segmentation based on mean shift and graph cuts [J]. *Ultrason. Imaging*, 2014, 36(4): 256-276.
- [13] PONS G, MART J, MART R, et al. Evaluating lesion segmentation on breast sonography as related to lesion type [J]. *J. Ultrasound Med.*, 2013, 32(9): 1659-1670.
- [14] DEODHARE D, SURI N R, AMIT R. Preprocessing and Image Enhancement Algorithms for a Form-based Intelligent Character Recognition System [J]. *International Journal of Computer Science & Applications*, 2005, 2(2): 131-144.
- [15] SAHINER B, CHAN H P, PETRICK N, et al. Classification of mass and normal breast tissue: a convolution neural network classifier with spatial domain and texture images [J]. *IEEE Trans. Med. Imaging*, 1996, 15: 598-610.
- [16] GARRA B S, KRASNER B H, HORII S C, et al. Improving the distinction between benign and malignant breast lesions: the value of sonographic texture analysis [J]. *Ultrasound Imaging* 1993, 15: 267-285.
- [17] GONZALEZ R C, WOODS R E. *Image Compression in Digital Image Processing Reading, Mass* [M]. Wesley, 1992: 312-315.
- [18] KARIMI B, KRZY ŻAK A. A novel technique for detecting suspicious lesions in breast ultrasound images. *Concurrency and Computation [J]. Practice and Experience*, 2016, 28(7): 2237-2260.
- [19] LECUN Y, BENGIO Y. *Convolutional networks for images, speech, and time series* [M]. *The Handbook of Brain Theory & Neural*, 1995.
- [20] CHENG J Z, et al. Computer-Aided diagnosis with deep learning architecture: applications to breast lesions in us images and pulmonary nodules in CT scans. [R] *Scientific Reports* 6, 2016.
- [21] WENG S. *Automating Breast Cancer Detection with Deep Learning* [D]. Houston, USA. Rice University, 2017.