



(12)发明专利申请

(10)申请公布号 CN 108257135 A

(43)申请公布日 2018.07.06

(21)申请号 201810103893.0

G06N 3/08(2006.01)

(22)申请日 2018.02.01

(71)申请人 浙江德尚韵兴图像科技有限公司  
地址 310012 浙江省杭州市西湖区文三路  
90号71幢7层东709、710室

(72)发明人 胡海蓉

(74)专利代理机构 杭州中成专利事务所有限公  
司 33212

代理人 周世骏

(51) Int. Cl.

G06T 7/11(2017.01)

G06K 9/46(2006.01)

G06K 9/62(2006.01)

G06T 7/00(2017.01)

G06T 7/136(2017.01)

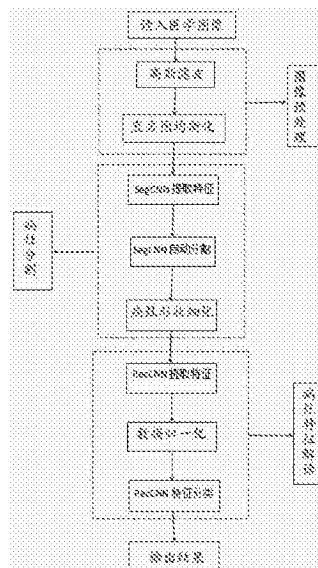
权利要求书7页 说明书16页 附图3页

(54)发明名称

基于深度学习方法解读医学图像特征的辅助诊断系统

(57)摘要

本发明涉及辅助医学诊断领域,旨在提供基于深度学习方法解读医学图像特征的辅助诊断系统。该基于深度学习方法解读医学图像特征的辅助诊断系统包括过程:读取病灶的医学影像数据并进行预处理;选取图像,建立卷积神经网络架构,自动学习分割出病灶区域,并对病灶形状进行细化;再建一个卷积神经网络架构的CNN模型自动解读良恶性病灶特征,训练后获得基于深度学习方法解读医学影像特征的辅助诊断系统。本发明不仅借助深度卷积神经网络可以自动的分割出病灶区域,弥补了基于活动轮廓等不能解决弱边界问题的不足,而且可以自动学习出提取出有价值的特征组合,避免了人工选取特征的复杂。



1. 基于深度学习方法解读医学图像特征的辅助诊断系统,其特征在于,包括下述过程:

一、读取病灶的医学影像数据:

读取病灶的医学图像,包括至少10000张良性病灶的图像和至少10000张恶性病灶的图像;

二、对医学影像进行预处理:

将过程一读取的病灶图像,先进行图像灰度化,并利用周围像素点的灰度值去掉超声图像中医生为测量结节相关量做的标记,再利用高斯滤波去噪,最后利用灰度直方图均衡化增强对比度,得到预处理后的增强图像;

三、选取图像,建立第一个卷积神经网络架构,即CNN,自动学习分割出病灶区域,称为感兴趣区域,即ROI,并对病灶形状进行细化;具体包括下述步骤:

第1步:选取过程二预处理后的增强图像20000张,包括良恶性病灶的图像各10000张;

第2步:对每一张图片,首先手动勾画出感兴趣区域,即病灶区域;然后通过第一个CNN架构训练出自动分割模型,记这个自动分割模型为SegCNN模型;

所述SegCNN模型是由15层卷积层、4层下采样层组成的网络结构;各卷积层的卷积核的大小分别为:第一层为 $13 \times 13$ ,第二层与第三层为 $11 \times 11$ ,第四层为 $5 \times 5$ ,其余各层为 $3 \times 3$ ;卷积层的步长分别是:第一个卷积层是2,其余的都是1;下采样层的大小都是 $3 \times 3$ ,步长都是2;

第3步:利用第2步得到的SegCNN模型应用于所有的病灶影像,即对第1步选取的20000张图像进行自动分割,然后建立一个分割模型,对SegCNN模型得到的病灶区域进行自动的细化分割,最终得到ROI,即所有的良恶性病灶;

四、建立第二个卷积神经网络架构的CNN模型自动解读良恶性病灶特征,记这个CNN模型为RecCNN模型;

所述RecCNN模型是由6层卷积层、4层下采样层、3层全连接层组成的网络结构;3个全连接层的神经元节点数分别为4096、4096、1;各卷积层的卷积核的大小分别为:第一层为 $13 \times 13$ ,第二层与第三层为 $11 \times 11$ ,第四层为 $5 \times 5$ ,其余各层为 $3 \times 3$ ;卷积层的步长分别是:第一个卷积层是2,其余的都是1;下采样层的大小都是 $3 \times 3$ ,步长都是2;

将过程三SegCNN模型自动分割出的ROI平均分成p组,用于训练RecCNN模型;所述p为不小于2的正整数;

五、选出过程四中p-1组数据作训练集,训练集用于训练RecCNN模型,剩余一组的数据作测试集,测试集用于对训练好的RecCNN模型进行测试;

利用训练集训练出RecCNN模型,用于解读医学图像特征,能对所有自动分割出来的病灶区域提取特征;

然后利用Softmax构造一个能进行多分类的分类器,对提取出来的特征进行分析,这个过程即求解一个损失函数的最优值,即优化损失函数

$$J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^c \theta_{ij}^2;$$

其中,所述i是指第i个样本;所述j是指第j类;所述1是指第1类;所述m表示共有m个样

本,  $m$ 取值范围为任意正整数; 所述  $c$  表示这些样本总共可分为  $c$  类,  $c$  取值范围为任意正整

数; 所述  $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$  是一个矩阵, 每一行是一个类别所对应的参数, 即权重与偏置; 所述  $\theta_j^T$  是指

第  $j$  类的参数向量的转置, 所述  $\theta_1^T$  是指第 1 类的参数向量的转置, 所述  $\theta_{ij}$  是指参数矩阵的第  $i$  行第  $j$  的元素; 所述  $1\{\cdot\}$  是一个指示性函数, 即当大括号中的值为真时, 该函数的结果为 1, 否则其结果为 0; 所述  $\lambda$  是平衡保真项与正则项的参数, 这里  $\lambda$  取正数; 所述  $e$  表示欧拉数 2.718281828,  $e^x$  就是指数函数; 所述  $T$  是表示矩阵计算中的转置运算符;  $\log$  表示自然对数, 即以欧拉数为底的对数;  $x^{(i)}$  是输入向量的第  $i$  维;  $y^{(i)}$  是每个样本标签的第  $i$  维;

Softmax 分类器的类别数  $c$  等于 5, 即分别代表病灶的回声特征、边缘特征、结构特征、钙化特征、纵横比特征五类特征; 每个类都有不同的子类, 回声特征有四子类: 高回声、等回声、低回声或者极低回声、无回声; 边缘特征有两子类: 光整、不光整; 结构特征有四子类: 实性、实性为主、囊性为主、囊性; 钙化特征有两子类: 微钙化、无微钙化; 纵横比特征有两子类: 大于 1、小于等于 1; 然后, 通过随机梯度下降方法得到输出的特征向量分别属于哪类特征的概率;

六、重复过程五, 做  $p$  次交叉检验, 即对于过程四分好的  $p$  组数据, 每次选出一组不同的数据作测试集, 余下的  $p-1$  组数据作训练集, 直至每一组数据都作过测试集;

经过  $p$  次交叉检验, 每次都会保存卷积神经网络模型 RecCNN 的权重与偏置参数, 并根据测试集上的准确率评估结果; 准确率的计算公式为  $AC = \frac{TN}{TN + FN}$ , 其中  $AC$  表示准确率,  $TN$  表示分类正确的样本数,  $FN$  表示分类错误的样本数; 最后取准确率最高的一次交叉检验中的权重与偏置参数, 作为 RecCNN 模型的最佳参数, 得到了训练好的 RecCNN 模型, 即最终确定了基于深度学习方法解读医学影像特征的辅助诊断系统;

将需要解读的病灶图像输入到这个基于深度学习方法解读医学影像特征的辅助诊断系统, 即可获得该病灶的特征, 并对其每类特征进行分析, 进而可以根据这些特征诊断良恶性病灶。

2. 根据权利要求 1 所述的基于深度学习方法解读医学图像特征的辅助诊断系统, 其特征在于, 所述过程三中的第 2 步和第 3 步, 具体为:

(1) 通过 CNN 的卷积层与下采样层自动学习特征, 并提取出特征, 具体步骤为:

步骤 A: 在一个卷积层, 上一层的特征 maps 被一个能够学习的卷积核进行卷积, 然后通过一个激活函数, 就能得到输出特征 map; 每一个输出是卷积核卷积一个输入或者组合多个卷积输入的值:

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l\right)$$

其中, 符号  $*$  表示卷积运算符; 所述  $l$  表示层数; 所述  $i$  表示  $l-1$  层的第  $i$  个神经元节点; 所

述j表示l层的第j个神经元节点;所述 $M_i$ 表示选择的输入maps的集合;所述 $x^{l-1}$ 是指l-1层的输出,作为l层的输入,所述 $x^l_j$ 是指第l层输出的第j个分量;所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数;所述k是卷积算子,所述 $k^l_{ij}$ 是指第l层卷积核的(i,j)位置的元素;所述b是偏置,所述 $b^l_j$ 是指第l层偏置的第j个分量;每一个输出map会给一个额外的偏置b,但是对于一个特定的输出map,卷积每个输入maps的卷积核都是不一样的;

通过梯度计算,以更新灵敏度,灵敏度用于表示b变化多少,误差会变化多少:

$$\delta_j^l = \beta_j^{l+1} \left( f'(s_j^l) \circ up(\delta_j^{l+1}) \right)$$

其中,所述l表示层数;所述j表示l层的第j个神经元节点;所述o表示每个元素相乘;所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率,所述 $\delta^l_j$ 是指第l层灵敏度的第j个分量,所述 $\delta^{l+1}_j$ 是指第l+1层灵敏度的第j个分量;所述 $s^l = W^l x^{l-1} + b^l$ , $x^{l-1}$ 是指l-1层的输出,W为权重,b为偏置,所述 $s^l_j$ 是指第l层 $s^l = W^l x^{l-1} + b^l$ 的第j个分量,所述 $W^l$ 是指第l层的权重参数,所述 $b^l$ 是指第l层的偏置;所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数; $f''(x)$ 是f(x)的导函数;

然后对l层中的灵敏度map中的所有节点进行求和,快速计算偏置b的梯度:

$$\frac{\partial E}{\partial b_j^l} = \sum_{u,v} (\delta_j^l)_{u,v}$$

其中,所述l表示层数;所述j表示l层的第j个神经元节点;所述b表示偏置,所述 $b^l_j$ 是指第l层的偏置的第j个分量;所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率;所述u,v表示输出maps的(u,v)位置;所述 $(\delta^l_j)_{u,v}$ 是指第l层灵敏度(u,v)位置的元素;所述E是误差函数,这里 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数;所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;

最后利用后向传播算法,对损失函数进行随机梯度下降,计算卷积核的权值:

$$\Delta W^l = -\eta \frac{\partial E}{\partial W^l}$$

其中,所述W是权重参数,所述 $\Delta W$ 是指权重参数的改变量;所述 $W^l$ 是指第l层的权重参数;所述E是误差函数,且 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数;所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;所述 $\eta$ 是学习率,即步长;由于很多连接的权值是共享的,因此对于一个给定的权值,需要对所有与该权值有联系的对点求梯度,然后对这些梯度进行求和:

$$\frac{\partial E}{\partial k_{ij}^l} = \sum_{u,v} (\delta_j^l)_{u,v} (p_i^{l-1})_{u,v}$$

其中,所述 $l$ 表示层数;所述 $i$ 表示 $l$ 层的第 $i$ 个神经元节点;所述 $j$ 表示 $l$ 层的第 $j$ 个神经元节点; $b$ 表示偏置,所述 $\delta$ 表示输出神经元的灵敏度,即偏置 $b$ 的变化率;所述 $u, v$ 表示输出maps的 $(u, v)$ 位置;所述 $(\delta^l)_j$ 是指第 $l$ 层灵敏度的 $(u, v)$ 位置的元素;所述 $E$ 是误差函数,这望 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述 $C$ 表示标签的维数;所述 $t_h^n$ 表示第 $n$ 个样本对应标签的第 $h$ 维;所述 $y_h^n$ 表示第 $n$ 个样本对应的网络输出的第 $h$ 个输出;所述 $k_h^l$ 是卷积核;所述 $(p^{l-1})_{u,v}$ 是 $x_j^{l-1}$ 中的元素在卷积的时候与 $k_h^l$ 逐元素相乘的patch,即所有与卷积核大小相同的图片中所有的区域块,输出卷积map的 $(u, v)$ 位置的值是由上一层的 $(u, v)$ 位置的patch与卷积核 $k_h^l$ 逐元素相乘的结果;

步骤B:下采样层有 $N$ 个输入maps,就有 $N$ 个输出maps,只是每个输出map都变小了,则有:

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l)$$

其中,所述 $x_j^l$ 是指第 $l$ 层的输出的第 $j$ 个分量,所述 $x_j^{l-1}$ 是指第 $l-1$ 层的输出的第 $j$ 个分量;所述 $f$ 是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数, $e$ 表示欧拉数2.718281828, $e^x$ 就是指数函数;所述 $\beta_j^l$ 表示各层共享的权值;所述 $\text{down}(\cdot)$ 表示一个下采样函数;所述 $b_j^l$ 是指第 $l$ 层偏置的第 $j$ 个分量;对输入图像的不同 $n \times n$ 的块的所有像素进行求和,这样输出图像在两个维度上都缩小了 $n$ 倍, $n$ 取值范围为正整数;每个输出map都对应一个属于自己的权重参数 $\beta$ 和一个加性偏置 $b$ ;

通过梯度下降方法来更新参数 $\beta$ 和 $b$ :

$$\delta_j^l = f'(s_j^l) \circ \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), \text{'full'})$$

$$\frac{\partial E}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{u,v}$$

$$\frac{\partial E}{\partial \beta_j} = \sum_{u,v} (\delta_j^l \circ \text{down}(x_j^{l-1}))_{u,v}$$

其中,所述 $f''(x)$ 是指激活函数 $f(x)$ 的导数;所述 $\circ$ 表示每个元素相乘;所述 $\text{conv2}$ 是二维卷积算子;所述 $\text{rot180}$ 是旋转180度;所述'full'是指进行完全卷积;所述 $l$ 表示层数;所述 $i$ 表示 $l$ 层的第 $i$ 个神经元节点;所述 $j$ 表示 $l$ 层的第 $j$ 个神经元节点;所述 $b$ 表示偏置,所述 $b_j$ 是指偏置参数的第 $j$ 分量;所述 $\delta$ 表示输出神经元的灵敏度,即偏置 $b$ 的变化率,所述 $\delta_j^l$ 是指第 $l$ 层灵敏度的第 $j$ 个分量,所述 $\delta_j^{l+1}$ 是指 $l+1$ 层的灵敏度的第 $j$ 个分量;所述 $u, v$ 表示输出maps的 $(u, v)$ 位置;所述 $(\delta^l)_j$ 是指 $l$ 层灵敏度的 $(u, v)$ 位置的元素;所述 $E$ 是误差函数,表达式同上,即 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述 $C$ 表示标签的维数;所述 $t_h^n$ 表示第 $n$ 个样本对应标签的第 $h$ 维;所述 $y_h^n$ 表示第 $n$ 个样本对应的网络输出的第 $h$ 个输出;所述 $\beta$ 是权重参数,所述 $\beta_j$ 是指权重参数的第 $j$ 分量;所述 $\text{down}(\cdot)$ 表示一个下采样函数;所述 $k_j^{l+1}$ 是第 $l+1$ 层的卷积核;所

述  $x_j^{l-1}$  是  $l-1$  层的输出的第  $j$  个神经元节点; 所述  $s^l = Wx^{l-1} + b^l$ , 其中  $W$  是权重参数,  $b$  是偏置,  $s_j^l$  是  $s^l$  的第  $j$  个分量;

步骤 C: CNN 自动学习特征 map 的组合, 则第  $j$  个特征 map 组合为:

$$x_j^l = f \left( \sum_{i=1}^{N_{in}} \alpha_{ij} (x_i^{l-1} * k_i^l) + b_j^l \right)$$

s. t.  $\sum_i \alpha_{ij} = 1$ , and  $0 \leq \alpha_{ij} \leq 1$ .

其中, 符号  $*$  表示卷积运算符; 所述  $l$  表示层数; 所述  $i$  表示  $l$  层的第  $i$  个神经元节点; 所述  $j$  表示  $l$  层的第  $j$  个神经元节点; 所述  $f$  是激活函数, 这里取 sigmoid 函数  $f(x) = \frac{1}{1+e^{-x}}$  作为激活函数,  $e$  表示欧拉数 2.718281828,  $e^{\circ}$  就是指数函数; 所述  $x_i^{l-1}$  是第  $l-1$  层输出的第  $i$  个分量, 所述  $x_j^l$  是指第  $l$  层的输出的第  $j$  个分量; 所述  $N_{in}$  表示输入的 map 数; 所述  $k_i^l$  是卷积核; 所述  $b_j^l$  是偏置; 所述  $\alpha_{ij}$  表示  $l-1$  层的输出 map 作为  $l$  层的输入时,  $l-1$  层得到第  $j$  个输出 map 的其中第  $i$  个输入 map 的权值或者贡献;

(2) 利用步骤 (1) 中提取的特征结合 Softmax 自动识别出病灶区域, 输出分割的概率图, 确定好自动分割的模型; 具体 Softmax 识别过程就是给定一个样本, 就输出一个概率值, 该概率值表示的是这个样本属于类别几的概率, 损失函数为:

$$J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^c \theta_{ij}^2$$

其中, 所述  $i$  是指第  $i$  个样本; 所述  $j$  是指第  $j$  类; 所述  $l$  是指第  $l$  类; 所述  $m$  表示共有  $m$  个样本,  $m$  取值范围为任意正整数; 所述  $c$  表示这些样本总共可分为  $c$  类,  $c$  取值范围为任意正整

数; 所述  $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$  是一个矩阵, 每一行是一个类别所对应的参数, 即权重与偏置; 所述  $\theta_j^T$  是指

第  $j$  类的参数向量的转置, 所述  $\theta_1^T$  是指第 1 类的参数向量的转置, 所述  $\theta_{ij}$  是指参数矩阵的第  $i$  行第  $j$  的元素; 所述  $1\{\cdot\}$  是一个指示性函数, 即当大括号中的值为真时, 该函数的结果为 1, 否则其结果为 0; 所述  $\lambda$  是平衡保真项与正则项的参数, 这里  $\lambda$  取正数; 所述  $J(\theta)$  是指系统的损失函数; 所述  $e$  表示欧拉数 2.718281828,  $e^x$  就是指数函数; 所述  $T$  是表示矩阵计算中的转置运算符;  $\log$  表示自然对数, 即以欧拉数为底的对数;  $x^{(i)}$  是输入向量的第  $i$  维;  $y^{(i)}$  是每个样本标签的第  $i$  维; 然后利用梯度求解:

$$\nabla_{\theta_j} J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m x^{(i)} \left( 1\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta) \right) \right] + \lambda \theta_j$$

其中,所述 $\theta_j^T$ 、 $i$ 、 $j$ 、 $c$ 、 $l$ 、 $\theta_1^T$ 分别与上述损失函数 $J(\theta)$ 中表示的是相同的含义;

$$p(y^{(i)} = j | x^{(i)}; \theta) = \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}};$$

所述 $m$ 表示共有 $m$ 个样本;所述 $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$ 是一个矩

阵,每一行是一个类别所对应的参数,即权重与偏置;所述 $\theta_j$ 是指第 $j$ 类所对应的参数;所述 $1\{\cdot\}$ 是一个指示性函数,即当大括号中的值为真时,该函数的结果为1,否则其结果为0;所述 $\lambda$ 是平衡保真项与正则项的参数,这里 $\lambda$ 取正数;所述 $J(\theta)$ 是指系统的损失函数; $\nabla_{\theta} J(\theta)$ 是 $J(\theta)$ 导函数;所述 $e$ 表示欧拉数2.718281828, $e^x$ 就是指数函数;所述 $T$ 是表示矩阵计算中的转置运算符; $\log$ 表示自然对数,即以欧拉数为底的对数; $x^{(i)}$ 是输入向量的第 $i$ 维; $y^{(i)}$ 是每个样本标签的第 $i$ 维;

(3) 利用SegCNN自动分割所有的医学影像,即区分出病灶区域与非病灶区域,找到病灶区域的边界,并对分割出的病灶形状进行细化,这里是利用图割的方法进行细化的分割,具体的就是:记 $I: x \in V \rightarrow R$ 为定义在区域 $\Omega \subseteq R^2$ 上的2D超声图像数据, $S$ 为 $V$ 内所有像素点的集合, $N_x$ 是像素点 $x$ 的6-邻域点集合;假设 $l_x \in \{0, 1\}$ 为像素点 $x$ 的标签,其中0和1分别代表该像素点属于背景和前景;则需要寻找极小化下面的能量泛函的标签集 $l = \{l_x, x \in S\}$ ,

$$E(l) = \lambda E_D(l) + E_B(l) \\ = \lambda \sum_{x \in V} D_x(l_x) + \sum_{x \in V} \sum_{y \in N_x} B_{xy}(x, y) \delta(l_x, l_y)$$

其中,  $\delta_{xy}(l_x, l_y) = \begin{cases} 1, & \text{if } l_x \neq l_y \\ 0, & \text{otherwise} \end{cases}$  参数 $\lambda$ 用来调节数据惩罚项 $E_D(l)$ 和边界惩罚项 $E_B$

(1) 之间的平衡, $\lambda$ 取值范围为任意实数;所述 $V$ 是指图像的区域范围;区域项 $D_x(l_x)$ 用来描述像素点 $x$ 和前景或者背景的相似度;边缘探测函数 $B_{xy}(x, y)$ 刻画了像素点 $x$ 和 $y$ 之间的不连续性,且

$$B_{xy}(x, y) = \frac{1}{1 + \beta |I(x) - I(y)|^2}$$

$\beta$ 是常数项,所述 $I(x)$ 是指图像上像素 $x$ 处的灰度值,所述

$I(y)$ 是指图像上像素 $y$ 处的灰度值;接下来,定义一个灰度阈值函数:

$$F(x) = \frac{(I(x) - \zeta)(I(x) - \eta)}{(\eta - \zeta)^2}$$

其中,所述 $\zeta$ 是指病灶区域内像素最小灰度值,所述 $\eta$ 是指病灶区域内像素的最大灰度值;这样就能从初始病灶区域中粗略地估计出病灶的灰度值区间 $[\zeta, \eta]$ ,定义由一组特征分布构成的局部表征项,选取的特征有图像的灰度值 $I(x)$ ,改进的局部二值模式 $LBP_{p,r}^{\zeta}$ 和局部灰度方差 $VAR_{p,r}$ ;这几个特征组合成一个联合特征 $F_l(x) = (I(x), LBP_{p,r}^{\zeta}, VAR_{p,r})$ , $\tau, p, r$ 是正常数;这里

$$\text{LBP}_{P,r}^t = \sum_{p=0}^{P-1} H(I_p - I_c - \tau \cdot \text{sign}(I_p - I_c)) \times 2^p$$

$$\text{VAR}_{P,r} = \frac{1}{P} \sum_{p=0}^{P-1} (I_p - I_m)^2, I_m = \frac{1}{P} \sum_{p=0}^{P-1} I_p$$

其中 $I_p$  ( $p=0, 1, \dots, P-1$ ) 对应的是均匀分布在以 $c \in \Omega$  为圆心,  $r$  为半径的圆上的 $P$  个点的灰度值,  $I_c$  是圆心处的灰度值; 所述 $I_m$  是指以 $c \in \Omega$  为圆心,  $r$  为半径的圆上的 $P$  个点灰度值的均值, 所述 $\text{sign}$  是指符号函数,  $x$  大于 $0$  时,  $\text{sign}(x)$  大于 $0$ , 否则 $\text{sign}(x)$  小于 $0$ ;  $H(x)$  是Heaviside函数, 即

$$H(x) = \begin{cases} 1, & \text{if } x > 0, \\ 0, & \text{otherwise} \end{cases}$$

记 $H_x^i$  为像素点 $x$  在局部邻域 $\theta(x)$  内的第 $i$  个特征的累积直方图;  $H_0^i$  是第 $i$  个特征在初始化区域内的平均累积直方图, 其方差记作 $\sigma_0^i$ , 则其局部表征项可以定义为 $P(x) = \sum_{i=1}^{i=3} \frac{W^1(H_x^i, H_0^i)}{(\sigma_0^i)^2}$ ,  $W^1$

( $\cdot, \cdot$ ) 是一维的L1Wasserstein距离; 最后组合SegCNN得到的病灶区域的分割概率图 $L(x)$ , 灰度阈值函数 $F(x)$  和局部表征 $P(x)$ , 得到数据项表达式 $D_x(l_x)$  为:

$$D_x(l_x) = \max(-R(x), 0) l_x + \max(R(x), 0) (1-l_x)$$

这里 $R(x) = \sum_{y \in N_x} B_{xy}(x, y) [F(x) + L(x) - 0.5 + \gamma P(x)]$ ,  $\gamma$  是正常数; 所述 $\max$  是指取最大值; 从而得到了能对病灶区域进行细化分割的图割模型, 利用这个图割模型就可以对由SegCNN模型得到的病灶区域进行细化分割。



## 基于深度学习方法解读医学图像特征的辅助诊断系统

### 技术领域

[0001] 本发明是关于辅助医学诊断领域,特别涉及基于深度学习方法解读医学图像特征的辅助诊断系统。

### 背景技术

[0002] 近年来,随着计算机技术及数字图像处理技术的飞速发展,数字图像处理技术越来越多的应用于辅助医学诊断领域,其原理就是对通过不同方式获取的医学图像进行分割,重构,配准,识别等图像处理技术,从而获得有价值的医学诊断信息,主要目的在于使医生观察病变部位更加直接和清晰,为医生临床确诊提供辅助参考,具有非常重要的现实意义。

[0003] 基于医学影像,及早发现病灶对鉴别其良恶性、临床治疗和手术选择有重要意义。而基于超声成像技术的超声检查因可实时成像、检查费用相对较低、对病患无创伤等。已经广泛应用于临床诊断。而医生诊断病灶(例如甲状腺结节,乳腺结节,淋巴结等)的良恶性主要靠穿刺活组织细胞检查,这样的工作量会很大,另外存在过度检测的情况,并且医生解读超声图像特征主观性比较强,主要靠经验,其结果往往受到医学成像设备的成像机理、获取条件、显示设备等因素的影响而极易造成误诊或漏诊。因此,利用计算机技术,数字图像处理技术,统计方法等实现超声图像辅助诊断十分必要。但是固有的成像机制使得临床采集到的超声图像质量均较差,导致辅助诊断的准确性和自动化均受到影响,所以目前的分割超声图像中的病灶最多的是基于活动轮廓的半自动分割,分类主要是人工选取出特征,然后利用传统的机器学习方法支持向量机(SVM),K-近邻(KNN),决策树等分类识别,这些分类器只能对小样本数据可以有较好的效果。但几乎没有真正解读医学图像的,这样的辅助系统对于最终的使用者来说无疑是一个黑盒子。而且医学数据是海量的,大样本的分类识别,尤其是图像特征的解读对医学诊断才能有更好的辅助作用。

### 发明内容

[0004] 本发明的主要目的在于克服现有技术中的不足,提供一种基于深度学习方法解读医学图像特征的辅助诊断系统。为解决上述技术问题,本发明的解决方案是:

[0005] 提供基于深度学习方法解读医学图像特征的辅助诊断系统,包括下述过程:

[0006] 一、读取病灶的医学影像数据:

[0007] 读取病灶的医学图像(可以是图片格式,也可以是标准的dicom图片),包括至少10000张良性病灶的图像和至少10000张恶性病灶的图像;

[0008] 二、对医学影像进行预处理:

[0009] 将过程一读取的病灶图像,先进行图像灰度化,并利用周围像素点的灰度值去掉超声图像中医生为测量结节相关量做的标记,再利用高斯滤波去噪,最后利用灰度直方图均衡化增强对比度,得到预处理后的增强图像;

[0010] 三、选取图像,建立第一个卷积神经网络架构,即CNN(convolutional neural

network),自动学习分割出病灶区域,称为感兴趣区域,即ROI(region of interest),并对病灶形状进行细化;具体包括下述步骤:

[0011] 第1步:选取过程二预处理后的增强图像20000张,包括良恶性病灶的图像各10000张;

[0012] 第2步:对每一张图片,首先(由专家)手动勾画出感兴趣区域,即病灶区域;然后通过第一个CNN架构训练出自动分割模型,记这个自动分割模型为SegCNN模型;

[0013] 所述SegCNN模型是由15层卷积层、4层下采样层组成的网络结构;各卷积层的卷积核的大小分别为:第一层为 $13 \times 13$ ,第二层与第三层为 $11 \times 11$ ,第四层为 $5 \times 5$ ,其余各层为 $3 \times 3$ ;卷积层的步长分别是:第一个卷积层是2,其余的都是1;下采样层的大小都是 $3 \times 3$ ,步长都是2;

[0014] 第3步:利用第2步得到的SegCNN模型应用于所有的病灶影像,即对第1步选取的20000张图像进行自动分割,然后建立一个图割模型,对SegCNN模型得到的病灶区域进行自动的细化分割,最终得到ROI,即所有的良恶性病灶;

[0015] 四、建立第二个卷积神经网络架构的CNN模型自动解读良恶性病灶特征,记这个CNN模型为RecCNN模型;

[0016] 所述RecCNN模型是由6层卷积层、4层下采样层、3层全连接层组成的网络结构;3个全连接层的神经元节点数分别为4096、4096、1;各卷积层的卷积核的大小分别为:第一层为 $13 \times 13$ ,第二层与第三层为 $11 \times 11$ ,第四层为 $5 \times 5$ ,其余各层为 $3 \times 3$ ;卷积层的步长分别是:第一个卷积层是2,其余的都是1;下采样层的大小都是 $3 \times 3$ ,步长都是2;

[0017] 将过程三SegCNN模型自动分割出的ROI平均分成p组,用于训练RecCNN模型(即过程五的训练RecCNN模型:利用RecCNN模型对每一组的ROI提取特征,并对特征数据进行归一化,即利用RecCNN模型提取每一组ROI的特征,再对提取出的这些特征进行线性变换,使其结果值映射到 $[0, 1]$ );所述p为不小于2的正整数;

[0018] 五、选出过程四中p-1组数据作训练集,训练集用于训练RecCNN模型,剩余一组的数据作测试集,测试集用于对训练好的RecCNN模型进行测试;

[0019] 利用训练集训练出RecCNN模型,用于解读医学图像特征,能对所有自动分割出来的病灶区域提取特征(具体训练过程为:其提取特征的方法与过程三SegCNN模型自动分割中提取特征过程的方法是一样的,即都是通过各自的各个卷积层与池化层提取特征,这两类功能层的作用是一样的,其计算公式与更新方法是一样的,但是RecCNN模型的对象只是针对病灶区域,而自动分割部分是针对非病灶区域与病灶区域同时进行提取特征,且RecCNN模型与SegCNN模型的卷积层与池化层窗口大小,步长大小,填充大小设置不同,所以彼此的卷积层与池化层作用范围不同);

[0020] 然后利用Softmax构造一个能进行多分类的分类器,对提取出来的特征进行分析,这个过程即求解一个损失函数的最优值,即优化损失函数

$$[0021] \quad J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^c \theta_{ij}^2;$$

[0022] 其中,所述i是指第i个样本;所述j是指第j类;所述l是指第l类;所述m表示共有m

个样本,  $m$ 取值范围为任意正整数; 所述  $c$  表示这些样本总共可分为  $c$  类,  $c$  取值范围为任意正

整数; 所述  $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$  是一个矩阵, 每一行是一个类别所对应的参数, 即权重与偏置; 所述  $\theta_j^T$  是指第  $j$  类的参数向量的转置, 所述  $\theta_1^T$  是指第 1 类的参数向量的转置, 所述  $\theta_{ij}$  是指参数矩阵的第  $i$  行第  $j$  的元素; 所述  $1\{\cdot\}$  是一个指示性函数, 即当大括号中的值为真时, 该函数的结果为 1, 否则其结果为 0; 所述  $\lambda$  是平衡保真项 (第一项) 与正则项 (第二项) 的参数, 这里  $\lambda$  取正数 (根据实验结果调节其大小); 所述  $e$  表示欧拉数 2.718281828,  $e^x$  就是指数函数; 所述  $T$  是表示矩阵计算中的转置运算符;  $\log$  表示自然对数, 即以欧拉数为底的对数;  $x^{(i)}$  是输入向量的第  $i$  维;  $y^{(i)}$  是每个样本标签的第  $i$  维;

[0023] Softmax 分类器的类别数  $c$  等于 5, 即分别代表病灶的回声特征、边缘特征、结构特征、钙化特征、纵横比特征五类特征; 每个类都有不同的子类, 回声特征有四子类: 高回声、等回声、低回声或者极低回声、无回声; 边缘特征有两子类: 光整、不光整; 结构特征有四子类: 实性、实性为主、囊性为主、囊性; 钙化特征有两子类: 微钙化、无微钙化; 纵横比特征有两子类: 大于 1、小于等于 1; 然后, 通过随机梯度下降方法得到输出的特征向量分别属于哪类特征的子类的概率 (具体过程与过程三中自动分割过程中预测方法是类似的, 都是优化一个损失函数, 只不过这里用的是一个多分类的 Softmax 函数, 根据输出特征向量的隶属哪类特征的概率预测出一个分类标签, 也就对一个病灶的特征进行了分类, 进一步可以得出良恶性病灶对应的各个特征的种类);

[0024] 六、重复过程五, 做  $p$  次交叉检验, 即对于过程四分好的  $p$  组数据, 每次选出一组不同的数据作测试集, 余下的  $p-1$  组数据作训练集, 直至每一组数据都作过测试集;

[0025] 经过  $p$  次交叉检验, 每次都会保存卷积神经网络模型 RecCNN 的权重与偏置参数, 并根据测试集上的准确率评估结果; 准确率的计算公式为  $AC = \frac{TN}{TN + FN}$ , 其中  $AC$  表示准确率,  $TN$  表示分类正确的样本数,  $FN$  表示分类错误的样本数; 最后取准确率最高的一次交叉检验中的权重与偏置参数, 作为 RecCNN 模型的最佳参数, 得到了训练好的 RecCNN 模型, 即最终确定了基于深度学习方法解读医学影像特征的辅助诊断系统;

[0026] 将需要解读的病灶图像输入到这个基于深度学习方法解读医学影像特征的辅助诊断系统, 即可获得该病灶的特征, 并对其每类特征进行分析, 进而可以根据这些特征诊断良恶性病灶。

[0027] 在本发明中, 所述过程三中的第 2 步和第 3 步, 具体为:

[0028] (1) 通过 CNN 的卷积层与下采样层自动学习特征, 并提取出特征, 具体步骤为:

[0029] 步骤 A: 在一个卷积层, 上一层的特征 maps 被一个能够学习的卷积核进行卷积, 然后通过一个激活函数, 就能得到输出特征 map; 每一个输出是卷积核卷积一个输入或者组合多个卷积输入的值 (这里我们选择的是组合卷积多个出入 maps 的值):

$$[0030] \quad \mathbf{x}_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l\right)$$

[0031] 其中,符号\*表示卷积运算符;所述l表示层数;所述i表示l-1层的第i个神经元节点;所述j表示l层的第j个神经元节点;所述 $M_j$ 表示选择的输入maps的集合;所述 $x_i^{l-1}$ 是指l-1层的输出,作为l层的输入,所述 $x_j^l$ 是指第l层输出的第j个分量;所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数;

所述k是卷积算子,所述 $k_{ij}^l$ 是指第l层卷积核的(i,j)位置的元素;所述b是偏置,所述 $b_j^l$ 是指第l层偏置的第j个分量;每一个输出map会给一个额外的偏置b,但是对于一个特定的输出map,卷积每个输入maps的卷积核都是不一样的;

[0032] 通过梯度计算,以更新灵敏度,灵敏度用于表示b变化多少,误差会变化多少:

$$[0033] \quad \delta_j^l = \beta_j^{l+1} \left( f'(s_j^l) \circ \text{up}(\delta_j^{l+1}) \right)$$

[0034] 其中,所述l表示层数;所述j表示l层的第j个神经元节点;所述 $\circ$ 表示每个元素相乘;所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率,所述 $\delta_j^l$ 是指第l层灵敏度的第j个分量,所述 $\delta_j^{l+1}$ 是指第l+1层灵敏度的第j个分量;所述 $s^l = W^l x^{l-1} + b^l$ , $x^{l-1}$ 是指l-1层的输出,W为权重,b为偏置,所述 $s_j^l$ 是指第l层 $s^l = W^l x^{l-1} + b^l$ 的第j个分量,所述 $W^l$ 是指第l层的权重参数,所述 $b^l$ 是指第l层的偏置;所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数; $f'(x)$ 是f(x)的导函数(即如果f取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ ,则 $f'(x) = (1-f(x))f(x)$ );所述 $\beta_j^{l+1}$ 表示各层共享的权值;所述

up(.)表示一个上采样操作(如果下采样的采样因子是n的话,上采样操作就是将每个像素水平和垂直方向上拷贝n次,这样就能恢复原来的大小了);

[0035] 然后对l层中的灵敏度map中的所有节点进行求和,快速计算偏置b的梯度:

$$[0036] \quad \frac{\partial E}{\partial b_j^l} = \sum_{u,v} (\delta_j^l)_{u,v}$$

[0037] 其中,所述l表示层数;所述j表示l层的第j个神经元节点;所述b表示偏置,所述 $b_j^l$ 是指第l层的偏置的第j个分量;所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率;所述u,v表示输出maps的(u,v)位置;所述 $(\delta_j^l)_{u,v}$ 是指第l层灵敏度(u,v)位置的元素;所述E是误差函数,这里 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数(如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ );所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;

[0038] 最后利用后向传播算法,对损失函数进行随机梯度下降,计算卷积核的权值:

$$[0039] \quad \Delta W^l = -\eta \frac{\partial E}{\partial W^l}$$

[0040] 其中,所述W是权重参数,所述 $\Delta W$ 是指权重参数的改变量;所述 $W^l$ 是指第l层的权重参数;所述E是误差函数,且 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数(如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ );所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;所述 $\eta$ 是学习率,即步长;由于很多连接的权值是共享的,因此对于一个给定的权值,需要对所有与该权值有联系连接对该点求梯度,然后对这些梯度进行求和:

$$[0041] \quad \frac{\partial E}{\partial k_{ij}^l} = \sum_{u,v} (\delta_j^l)_{u,v} (p_i^{l-1})_{u,v}$$

[0042] 其中,所述l表示层数;所述i表示l层的第i个神经元节点;所述j表示l层的第j个神经元节点;b表示偏置,所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率;所述u,v表示输出maps的(u,v)位置;所述 $(\delta_j^l)_{u,v}$ 是指第l层灵敏度的(u,v)位置的元素;所述E是误差函数,这里 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数(如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ );所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;所述 $k_{ij}^l$ 是卷积核;所述 $(p_i^{l-1})_{u,v}$ 是 $x_i^{l-1}$ 中的元素在卷积的时候与 $k_{ij}^l$ 逐元素相乘的patch,即所有与卷积核大小相同的图片中所有的区域块,输出卷积map的(u,v)位置的值是由上一层的(u,v)位置的patch与卷积核 $k_{ij}^l$ 逐元素相乘的结果;

[0043] 步骤B:下采样层有N个输入maps,就有N个输出maps,只是每个输出map都变小了,则有:

$$[0044] \quad x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l)$$

[0045] 其中,所述 $x_j^l$ 是指第l层的输出的第j个分量,所述 $x_j^{l-1}$ 是指第l-1层的输出的第j个分量;所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数;所述 $\beta_j^l$ 表示各层共享的权值;所述down(.)表示一个下采样函数;所述 $b_j^l$ 是指第l层偏置的第j个分量;对输入图像的不同 $n \times n$ 的块的所有像素进行求和,这样输出图像在两个维度上都缩小了n倍,n取值范围为正整数(这里就是将输入图像的每个元素取定一个 $3 \times 3$ 大小的块,然后将其中所有元素求和作为该元素在输出图像中的值,从而使得输出图像在两个维度上都缩小了3倍);每个输出map都对应一个属于自己的权重参数 $\beta$ (乘性偏置)和一个加性偏置b;

[0046] 通过梯度下降方法来更新参数 $\beta$ 和b:

$$[0047] \quad \delta_j^l = f'(s_j^l) \circ \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), \text{'full'})$$

$$[0048] \quad \frac{\partial E}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{u,v}$$

$$[0049] \quad \frac{\partial E}{\partial \beta_j} = \sum_{u,v} (\delta_j^l \circ \text{down}(x_j^{l-1}))_{u,v}$$

[0050] 其中,所述 $f'(x)$ 是指激活函数 $f(x)$ 的导数;所述 $\circ$ 表示每个元素相乘;所述conv2是二维卷积算子;所述rot180是旋转180度;所述'full'是指进行完全卷积;所述 $l$ 表示层数;所述 $i$ 表示 $l$ 层的第 $i$ 个神经元节点;所述 $j$ 表示 $l$ 层的第 $j$ 个神经元节点;所述 $b$ 表示偏置,所述 $b_j$ 是指偏置参数的第 $j$ 分量;所述 $\delta$ 表示输出神经元的灵敏度,即偏置 $b$ 的变化率,所述 $\delta_j^l$ 是指第 $l$ 层灵敏度的第 $j$ 分量,所述 $\delta_j^{l+1}$ 是指 $l+1$ 层的灵敏度的第 $j$ 分量;所述 $u, v$ 表示输出maps的 $(u, v)$ 位置;所述 $(\delta_j^l)_{u, v}$ 是指 $l$ 层灵敏度的 $(u, v)$ 位置的元素;所述 $E$ 是误差函数,表达式同上,即 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述 $C$ 表示标签的维数(如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ );所述 $t_h^n$ 表示第 $n$ 个样本对应标签的第 $h$ 维;所述 $y_h^n$ 表示第 $n$ 个样本对应的网络输出的第 $h$ 个输出;所述 $\beta$ 是权重参数(一般取值在 $[0, 1]$ ),所述 $\beta_j$ 是指权重参数的第 $j$ 分量;所述down(.)表示一个下采样函数;所述 $k_j^{l+1}$ 是第 $l+1$ 层的卷积核;所述 $x_j^{l-1}$ 是第 $l-1$ 层的输出的第 $j$ 个神经元节点;所述 $s^l = W^l x^{l-1} + b^l$ ,其中 $W$ 是权重参数, $b$ 是偏置, $s_j^l$ 是 $s^l$ 的第 $j$ 分量;

[0051] 步骤C: CNN自动学习特征map的组合,则第 $j$ 个特征map组合为:

$$[0052] \quad \mathbf{x}_j^l = f \left( \sum_{i=1}^{N_{in}} \alpha_{ij} (x_i^{l-1} * k_i^l) + b_j^l \right)$$

[0053] s. t.  $\sum_i \alpha_{ij} = 1$ , and  $0 \leq \alpha_{ij} \leq 1$ .

[0054] 其中,符号 $*$ 表示卷积运算符;所述 $l$ 表示层数;所述 $i$ 表示 $l$ 层的第 $i$ 个神经元节点;所述 $j$ 表示 $l$ 层的第 $j$ 个神经元节点;所述 $f$ 是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数, $e$ 表示欧拉数2.718281828, $e^x$ 就是指数函数;所述 $x_i^{l-1}$ 是第 $l-1$ 层输出的第 $i$ 个分量,所述 $x_j^l$ 是指第 $l$ 层的输出的第 $j$ 个分量;所述 $N_{in}$ 表示输入的map数;所述 $k_i^l$ 是卷积核;所述 $b_j^l$ 是偏置;所述 $\alpha_{ij}$ 表示 $l-1$ 层的输出map作为 $l$ 层的输入时, $l-1$ 层得到第 $j$ 个输出map的其中第 $i$ 个输入map的权值或者贡献;

[0055] (2) 利用步骤(1)中提取的特征结合Softmax自动识别出病灶区域,输出分割的概率图,确定好自动分割的模型;具体Softmax识别过程就是给定一个样本,就输出一个概率值,该概率值表示的是这个样本属于类别几的概率,损失函数为:

$$[0056] \quad J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^c \theta_{ij}^2$$

[0057] 其中,所述*i*是指第*i*个样本;所述*j*是指第*j*类;所述*l*是指第*l*类;所述*m*表示共有*m*个样本,*m*取值范围为任意正整数;所述*c*表示这些样本总共可分为*c*类,*c*取值范围为任意正

整数;所述  $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$  是一个矩阵,每一行是一个类别所对应的参数,即权重与偏置;所述  $\theta_j^T$  是

指第*j*类的参数向量的转置,所述  $\theta_l^T$  是指第*l*类的参数向量的转置,所述  $\theta_{ij}$  是指参数矩阵的第*i*行第*j*的元素;所述  $1\{\cdot\}$  是一个指示性函数,即当大括号中的值为真时,该函数的结果为1,否则其结果为0;所述  $\lambda$  是平衡保真项(第一项)与正则项(第二项)的参数,这里  $\lambda$  取正数(根据实验结果调节其大小);所述  $J(\theta)$  是指系统的损失函数;所述  $e$  表示欧拉数 2.718281828,  $e^x$  就是指数函数;所述  $T$  是表示矩阵计算中的转置运算符;  $\log$  表示自然对数,即以欧拉数为底的对数;  $x^{(i)}$  是输入向量的第*i*维;  $y^{(i)}$  是每个样本标签的第*i*维;然后利用梯度求解:

$$[0058] \quad \nabla_{\theta_j} J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m x^{(i)} \left( 1\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta) \right) \right] + \lambda \theta_j$$

[0059] 其中,所述  $\theta_j^T$ 、*i*、*j*、*c*、*l*、 $\theta_l^T$  分别与上述损失函数  $J(\theta)$  中表示的是相同的含义;

$p(y^{(i)} = j | x^{(i)}; \theta) = \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}};$  所述*m*表示共有*m*个样本;所述  $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$  是一个矩

阵,每一行是一个类别所对应的参数,即权重与偏置;所述  $\theta_j$  是指第*j*类所对应的参数;所述  $1\{\cdot\}$  是一个指示性函数,即当大括号中的值为真时,该函数的结果为1,否则其结果为0;所述  $\lambda$  是平衡保真项(第一项)与正则项(第二项)的参数,这里  $\lambda$  取正数(根据实验结果调节其大小);所述  $J(\theta)$  是指系统的损失函数;  $\nabla_{\theta_j} J(\theta)$  是  $J(\theta)$  导函数;所述  $e$  表示欧拉数 2.718281828,  $e^x$  就是指数函数;所述  $T$  是表示矩阵计算中的转置运算符;  $\log$  表示自然对数,即以欧拉数为底的对数;  $x^{(i)}$  是输入向量的第*i*维;  $y^{(i)}$  是每个样本标签的第*i*维;(这里使用的是一种新的Softmax分类器,即只有两分类的Softmax分类器,对于一张医学影像来说,根据softmax给出的概率可以得到将所有的病灶区域与非病灶区域区分开的一个概率图,根据此图可以得到了对病灶区域的粗分割)

[0060] (3) 利用SegCNN自动分割所有的医学影像,即区分出病灶区域与非病灶区域,找到病灶区域的边界,并对分割出的病灶形状进行细化,这里是利用图割的方法进行细化的分割,具体的就是:记 $I: x \in V \rightarrow R$ 为定义在区域 $\Omega \subset R^2$ 上的2D超声图像数据, $S$ 为 $V$ 内所有像素点的集合, $N_x$ 是像素点 $x$ 的6-邻域点集合;假设 $l_x \in \{0, 1\}$ 为像素点 $x$ 的标签,其中0和1分别代表该像素点属于背景(非病灶区域)和前景(病灶区域);则需要寻找极小化下面的能量泛函的标签集 $l = \{l_x, x \in S\}$ ,

$$\begin{aligned} E(l) &= \lambda E_D(l) + E_B(l) \\ [0061] \quad &= \lambda \sum_{x \in V} D_x(l_x) + \sum_{x \in V} \sum_{y \in N_x} B_{xy}(x, y) \delta(l_x, l_y) \end{aligned}$$

[0062] 其中 $\delta_{xy}(l_x, l_y) = \begin{cases} 1, & \text{if } l_x \neq l_y \\ 0, & \text{otherwise} \end{cases}$ ; 参数 $\lambda$ 用来调节数据惩罚项 $E_D(l)$ 和边界惩罚项

$E_B(l)$ 之间的平衡, $\lambda$ 取值范围为任意实数;所述 $V$ 是指图像的区域范围;区域项 $D_x(l_x)$ 用来描述像素点 $x$ 和前景或者背景的相似度;边缘探测函数 $B_{xy}(x, y)$ 刻画了像素点 $x$ 和 $y$ 之间的不连续性,且 $B_{xy}(x, y) = \frac{1}{1 + \beta |I(x) - I(y)|^2}$ ,  $\beta$ 是常数项,所述 $I(x)$ 是指图像上像素 $x$ 处的灰度值,所

述 $I(y)$ 是指图像上像素 $y$ 处的灰度值;接下来,定义一个灰度阈值函数:

$$[0063] \quad F(x) = \frac{(I(x) - \zeta)(I(x) - \eta)}{(\eta - \zeta)^2}$$

[0064] 其中,所述 $\zeta$ 是指病灶区域内像素最小灰度值,所述 $\eta$ 是指病灶区域内像素的最大灰度值;这样就能从初始病灶区域中粗略地估计出病灶的灰度值区间 $[\zeta, \eta]$ ;定义由一组特征分布构成的局部表征项,选取的特征有图像的灰度值 $I(x)$ ,改进的局部二值模式 $LBP_{p,r}^c$ 和局部灰度方差 $VAR_{p,r}$ ;这几个特征组合成一个联合特征 $F_l(x) = (I(x), LBP_{p,r}^c, VAR_{p,r})$ ,  $\tau, p, r$ 是正常数;这里

$$[0065] \quad LBP_{p,r}^c = \sum_{p=0}^{P-1} H(I_p - I_c - \tau \cdot \text{sign}(I_p - I_c)) \times 2^p$$

$$[0066] \quad VAR_{p,r} = \frac{1}{P} \sum_{p=0}^{P-1} (I_p - I_m)^2, I_m = \frac{1}{P} \sum_{p=0}^{P-1} I_p$$

[0067] 其中 $I_p (p=0, 1, \dots, P-1)$ 对应的是均匀分布在以 $c \in \Omega$ 为圆心, $r$ 为半径的圆上的 $P$ 个点的灰度值, $I_c$ 是圆心处的灰度值;所述 $I_m$ 是指以 $c \in \Omega$ 为圆心, $r$ 为半径的圆上的 $P$ 个点灰度值的均值,所述 $\text{sign}$ 是指符号函数, $x$ 大于0时, $\text{sign}(x)$ 大于0,否则 $\text{sign}(x)$ 小于0; $H(x)$ 是Heaviside函数,即

$$[0068] \quad H(x) = \begin{cases} 1, & \text{if } x > 0, \\ 0, & \text{otherwise} \end{cases}$$

[0069] 记 $H_x^i$ 为像素点 $x$ 在局部邻域 $O(x)$ 内的第 $i$ 个特征的累积直方图; $H_0^i$ 是第 $i$ 个特征在



初始化区域内的平均累积直方图,其方差记作 $\sigma_0^i$ ,则其局部表征项可以定义为

$$P(x) = \sum_{i=1}^{i=3} \frac{W^1(H_x^i, H_0^i)}{(\sigma_0^i)^2}$$

$W^1(\dots)$ 是一维的L1 Wasserstein距离;最后组合SegCNN得到的病灶区

域的分割概率图 $L(x)$ ,灰度阈值函数 $F(x)$ 和局部表征 $P(x)$ ,得到数据项表达式 $D_x(1_x)$ 为:

$$[0070] \quad D_x(1_x) = \max(-R(x), 0) 1_x + \max(R(x), 0) (1-1_x)$$

[0071] 这里 $R(x) = \sum_{y \in N_x} B_{xy}(x, y) [F(x) + L(x) - 0.5 + \gamma P(x)]$ ,  $\gamma$ 是正常数;所述max是指取最大

值;从而得到了能对病灶区域进行细化分割的图割模型,利用这个图割模型就可以对由SegCNN模型得到的病灶区域进行细化分割。

[0072] 与现有技术相比,本发明的有益效果是:

[0073] 本发明不仅借助深度卷积神经网络可以自动的分割出病灶区域,弥补了基于活动轮廓等不能解决弱边界问题的不足,而且可以自动学习出提取出有价值的特征组合,避免了人工选取特征的复杂,这样提取出来的特征更有利于找到病灶的主要规律信息,而且对超声影像特征进行了分类,可以客观的量化主要的临床医学指标,提高了诊断病灶良恶性的准确率,并获得了高度的适应性。

## 附图说明

[0074] 图1为基于深度卷积神经网络方法解读医学图像特征的流程图。

[0075] 图2为实施例中所用病灶的原始超声图像。

[0076] 图3为专家画出的图2中病灶区域的mask图片。

[0077] 图4为实施例中病灶的原始超声图像。

[0078] 图5为利用SegCNN自动分割出图4病灶区域的效果图片。

## 具体实施方式

[0079] 下面结合附图与具体实施方式对本发明作进一步详细描述:

[0080] 下面的实施例可以使本专业的专业技术人员更全面地理解本发明,但不以任何方式限制本发明。

[0081] 如图1所示,一种基于深度学习方法解读医学图像特征的辅助诊断系统,包括以下步骤:

[0082] 一、读取病灶的医学影像数据:

[0083] 读取病灶的医学图像,包括至少10000张良性病灶的图像和至少10000张恶性病灶的图像;图像可以是图片格式,也可以是标准的dicom图片。

[0084] 二、对医学影像进行预处理:

[0085] 将过程一读取的病灶图像,先进行图像灰度化,并利用周围像素点的灰度值去掉超声图像中医生为测量结节相关量做的标记,再利用高斯滤波去噪,最后利用灰度直方图均衡化增强对比度,得到预处理后的增强图像。

[0086] 三、选取图像,建立第一个卷积神经网络架构,即CNN(convolutional neural network),自动学习分割出病灶区域,称为感兴趣区域,即ROI(region of interest),并对

病灶形状进行细化。具体包括下述步骤：

[0087] 第1步：选取过程二预处理后的增强图像20000张，包括良恶性病灶的图像各10000张；

[0088] 第2步：对每一张图片，首先（由专家）手动勾画出感兴趣区域，即病灶区域，然后通过第一个CNN架构训练出自动分割模型，这个CNN模型记作SegCNN；

[0089] 所述SegCNN是由15层卷积层、4层下采样层组成的网络结构；各卷积层的卷积核的大小分别为：第一层为 $13 \times 13$ ，第二层与第三层为 $11 \times 11$ ，第四层为 $5 \times 5$ ，其余各层为 $3 \times 3$ ；卷积层的步长分别是：第一个卷积层是2，其余的都是1；下采样层的大小都是 $3 \times 3$ ，步长都是2。

[0090] 通过第一个CNN架构训练出自动分割模型SegCNN的具体方法为：

[0091] (1) 通过CNN的卷积层与下采样层自动学习特征，并提取出特征，具体步骤为：

[0092] 步骤A：在一个卷积层，上一层的特征maps被一个能够学习的卷积核进行卷积，然后通过一个激活函数，就能得到输出特征map；每一个输出是卷积核卷积一个输入或者组合多个卷积输入的值（这里我们选择的是组合卷积多个输入maps的值）：

$$[0093] \quad x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l\right)$$

[0094] 其中，符号\*表示卷积运算符；所述l表示层数；所述i表示l-1层的第i个神经元节点；所述j表示l层的第j个神经元节点；所述 $M_j$ 表示选择的输入maps的集合；所述 $x_i^{l-1}$ 是指l-1层的输出，作为l层的输入；所述f是激活函数，这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数，e表示欧拉数2.718281828， $e^x$ 就是指数函数；所述k是卷积算子；所述b是偏置；每一个输出map会给一个额外的偏置b，但是对于一个特定的输出map，卷积每个输入maps的卷积核都是不一样的；

[0095] 这一步还需要进行梯度计算，以更新灵敏度，灵敏度用于表示b变化多少，误差会变化多少：

$$[0096] \quad \delta_j^l = \beta_j^{l+1} \left( f'(s_j^l) \circ up(\delta_j^{l+1}) \right)$$

[0097] 其中，所述l表示层数；所述j表示l层的第j个神经元节点；所述 $\circ$ 表示每个元素相乘；所述 $\delta$ 表示输出神经元的灵敏度，即偏置b的变化率；所述 $s^l = W^l x^{l-1} + b^l$ ， $x^{l-1}$ 是指l-1层的输出，W为权重，b为偏置；所述f是激活函数，这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数，e表示欧拉数2.718281828， $e^x$ 就是指数函数； $f'(x)$ 是f(x)的导函数（即如果f取sigmoid

函数 $f(x) = \frac{1}{1+e^{-x}}$ ，则 $f'(x) = (1-f(x))f(x)$ ）；所述 $\beta_j^{l+1}$ 表示各层共享的权值；所述up(.)表示一个上采样操作（如果下采样的采样因子是n的话，上采样操作就是将每个像素水平和垂直方向上拷贝n次，这样就能恢复原来的大小了）；

[0098] 然后对l层中的灵敏度map中的所有节点进行求和，快速计算偏置b的梯度：

$$[0099] \quad \frac{\partial E}{\partial b_j^l} = \sum_{u,v} (\delta_j^l)_{u,v}$$

[0100] 其中,所述l表示层数;所述j表示l层的第j个神经元节点;所述b表示偏置;所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率;所述u,v表示输出maps的(u,v)位置;所述E是误差函数,这里 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数,如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ ;所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;

[0101] 最后利用后向传播算法,对损失函数进行随机梯度下降,计算卷积核的权值:

$$[0102] \quad \Delta W^l = -\eta \frac{\partial E}{\partial W^l}$$

[0103] 其中,所述W是权重参数;所述E是误差函数,且 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数,如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ ;所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;所述 $\eta$ 是学习率,即步长;由于很多连接的权值是共享的,因此对于一个给定的权值,需要对所有与该权值有联系的对点求梯度,然后对这些梯度进行求和:

$$[0104] \quad \frac{\partial E}{\partial k_{ij}^l} = \sum_{u,v} (\delta_j^l)_{u,v} (p_i^{l-1})_{u,v}$$

[0105] 其中,所述l表示层数;所述i表示l层的第i个神经元节点;所述j表示l层的第j个神经元节点;b表示偏置,所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率;所述u,v表示输出maps的(u,v)位置;所述E是误差函数,这里 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数,如果是两分类的问题,则标签就可以记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ ;所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;所述 $k_{ij}^l$ 是卷积核;所述 $(p_i^{l-1})_{u,v}$ 是 $x_i^{l-1}$ 中的元素在卷积的时候与 $k_{ij}^l$ 逐元素相乘的patch,即所有与卷积核大小相同的图片中所有的区域块,输出卷积map的(u,v)位置的值是由上一层的(u,v)位置的patch与卷积核 $k_{ij}^l$ 逐元素相乘的结果;

[0106] 步骤B:下采样层有N个输入maps,就有N个输出maps,只是每个输出map都变小了,则有:

$$[0107] \quad x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l)$$

[0108] 其中,所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数;所述 $\beta_j^l$ 表示各层共享的权值 $\beta_j^l$ 表示各层共享的权值;

所述down(.)表示一个下采样函数;对输入图像的不同nxn的块的所有像素进行求和,这样输出图像在两个维度上都缩小了n倍(这里就是将输入图像的每个元素取定一个3x3大小的块,然后将其中所有元素求和作为该元素在输出图像中的值,从而使得输出图像在两个维度上都缩小了3倍);每个输出map都对应一个属于自己的权重参数 $\beta$ (乘性偏置)和一个加性偏置b;

[0109] 通过梯度下降方法来更新参数 $\beta$ 和b:

$$[0110] \quad \delta_j^l = f'(s_j^l) \circ \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), \text{'full'})$$

$$[0111] \quad \frac{\partial E}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{u,v}$$

$$[0112] \quad \frac{\partial E}{\partial \beta_j} = \sum_{u,v} (\delta_j^l \circ \text{down}(x_j^{l-1}))_{u,v}$$

[0113] 其中,所述 $f'(x)$ 是指激活函数 $f(x)$ 的导数;所述conv2是二维卷积算子;所述rot180是旋转180度;所述'full'是指进行完全卷积;所述l表示层数;所述i表示l层的第i个神经元节点;所述j表示l层的第j个神经元节点;所述b表示偏置;所述 $\delta$ 表示输出神经元的灵敏度,即偏置b的变化率;所述u,v表示输出maps的(u,v)位置;所述E是误差函数,表达式同上,即 $E = \frac{1}{2} \sum_{h=1}^C (t_h^n - y_h^n)^2$ ;所述C表示标签的维数,如果是两分类的问题,则标签就可以

记为 $y_h \in \{0, 1\}$ ,此时 $C=1$ ,也可以记为 $y_h \in \{(0, 1), (1, 0)\}$ ,此时 $C=2$ ;所述 $t_h^n$ 表示第n个样本对应标签的第h维;所述 $y_h^n$ 表示第n个样本对应的网络输出的第h个输出;所述 $\beta$ 是权重参数(一般取值在 $[0, 1]$ );所述down(.)表示一个下采样函数;所述 $k_j^{l+1}$ 是第l+1层的卷积核;所述 $x_j^{l-1}$ 是第l-1层的输出的第j个神经元节点;所述 $s^l = W^l x^{l-1} + b^l$ ,其中 $W^l$ 是权重参数, $b^l$ 是偏置, $s_j^l$ 是 $s^l$ 的第j个分量。

[0114] 步骤C:CNN自动学习特征map的组合,则第j个特征map组合为:

$$[0115] \quad x_j^l = f\left(\sum_{i=1}^{N_{in}} \alpha_{ij} (x_i^{l-1} * k_i^l) + b_j^l\right)$$

[0116] s. t.  $\sum_i \alpha_{ij} = 1$ , and  $0 \leq \alpha_{ij} \leq 1$ .

[0117] 其中,符号\*表示卷积运算符;所述l表示层数;所述i表示l层的第i个神经元节点;所述j表示l层的第j个神经元节点;所述f是激活函数,这里取sigmoid函数 $f(x) = \frac{1}{1+e^{-x}}$ 作为

激活函数,e表示欧拉数2.718281828, $e^x$ 就是指数函数;所述 $x_i^{l-1}$ 是第l-1层输出的第i个分量;所述 $N_{in}$ 表示输入的map数;所述 $k_i^l$ 是卷积核;所述 $b_j^l$ 是偏置;所述 $\alpha_{ij}$ 表示l-1层的输出map作为l层的输入时,l-1层得到第j个输出map的其中第i个输入map的权值或者贡献;

[0118] (2) 利用(1)中提取的特征结合Softmax自动识别出病灶区域,输出分割的概率图,确定好自动分割的模型;具体Softmax识别过程就是给定一个样本,就输出一个概率值,该

概率值表示的是这个样本属于类别几的概率, 损失函数为:

$$[0119] \quad J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^c \theta_{ij}^2$$

[0120] 其中, 所述m表示共有m个样本; 所述c表示这些样本总共可分为c类; 所述 $\theta =$

$$\begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$$

是一个矩阵, 每一行是一个类别所对应的参数, 即权重与偏置; 所述 $1\{\cdot\}$ 是一个指示性函数, 即当大括号中的值为真时, 该函数的结果为1, 否则其结果为0; 所述 $\lambda$ 是平衡保真项 (第一项) 与正则项 (第二项) 的参数, 这里 $\lambda$ 取正数 (根据实验结果调节其大小); 所述 $J(\theta)$ 是指系统的损失函数; 所述e表示欧拉数2.718281828,  $e^x$ 就是指数函数; 所述T是表示矩阵计算中的转置运算符; log表示自然对数, 即以欧拉数为底的对数; n表示权重与偏置参数的维度;  $x^{(i)}$ 是输入向量的第i维;  $y^{(i)}$ 是每个样本标签的第i维; 然后利用梯度求解:

$$[0121] \quad \nabla_{\theta_j} J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m x^{(i)} \left( 1\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta) \right) \right] + \lambda \theta_j$$

[0122] 其中,  $p(y^{(i)} = j | x^{(i)}; \theta) = \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}};$  所述m表示共有m个样本; 所述 $\theta =$

$$\begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$$

是一个矩阵, 每一行是一个类别所对应的参数, 即权重与偏置; 所述 $1\{\cdot\}$ 是一个指示性函数, 即当大括号中的值为真时, 该函数的结果为1, 否则其结果为0; 所述 $\lambda$ 是平衡保真项 (第一项) 与正则项 (第二项) 的参数, 这里 $\lambda$ 取正数 (根据实验结果调节其大小); 所述 $J(\theta)$ 是指系统的损失函数;  $\nabla_{\theta_j} J(\theta)$ 是 $J(\theta)$ 导函数; 所述e表示欧拉数2.718281828,  $e^x$ 就是指数函数; 所述T是表示矩阵计算中的转置运算符; log表示自然对数, 即以欧拉数为底的对数;  $x^{(i)}$ 是输入向量的第i维;  $y^{(i)}$ 是每个样本标签的第i维; (这里使用的是一种新的Softmax分类器, 即只有两分类的Softmax分类器, 对于一张医学影像来说, 根据softmax给出的概率可以得到将所有的病灶区域与非病灶区域区分开的一个概率图, 根据此图可以得到了对病灶区域的粗分割;)

[0123] (3) 利用SegCNN自动分割所有的医学影像, 即区分出病灶区域与非病灶区域, 找到病灶区域的边界, 并对分割出的病灶形状进行细化, 这里我们利用图割的方法进行细化的分割, 具体的就是: 记 $I: x \in \Omega \rightarrow R$ 为定义在区域 $\Omega \subset R^2$ 上的2D超声图像数据, S为 $\Omega$ 内所有像素点的集合,  $N_x$ 是像素点x的6-邻域点集合。假设 $l_x \in \{0, 1\}$ 为像素点x的标签, 其中0和1分别代表该像素点属于背景 (非病灶区域) 和前景 (病灶区域)。则我们需要寻找极小化下面

的能量泛函的标签集  $l = \{l_x, x \in S\}$ ,

$$[0124] \quad \begin{aligned} E(l) &= \lambda E_D(l) + E_B(l) \\ &= \lambda \sum_{x \in V} D_x(l_x) + \sum_{x \in V} \sum_{y \in N_x} B_{xy}(x, y) \delta(l_x, l_y) \end{aligned}$$

[0125] 其中  $\delta_{xy}(l_x, l_y) = \begin{cases} 1, & \text{if } l_x \neq l_y \\ 0, & \text{otherwise} \end{cases}$  参数  $\lambda$  用来调节数据惩罚项  $E_D(l)$  和边界惩罚项  $E_B(l)$

(1) 之间的平衡。区域项  $D_x(l_x)$  用来描述像素点  $x$  和前景或者背景的相似度。边缘探测函数  $B_{xy}(x, y)$  刻画了像素点  $x$  和  $y$  之间的不连续性, 且  $B_{xy}(x, y) = \frac{1}{1 + \beta |I(x) - I(y)|^2}$ ,  $\beta$  是常数项。接

下来, 我们还需要定义一个灰度阈值函数:

$$[0126] \quad F(x) = \frac{(I(x) - \zeta)(I(x) - \eta)}{(\eta - \zeta)^2}$$

[0127] 这样就可以从初始病灶区域中粗略地估计出病灶的灰度值区间  $[\zeta, \eta]$ 。定义由一组特征分布构成的局部表征项, 选取的特征有图像的灰度值  $I(x)$ , 改进的局部二值模式  $LBP_{P,r}^c$  和局部灰度方差  $VAR_{P,r}$ 。这几个特征组合成一个联合特征

[0128]  $F_l(x) = (I(x), LBP_{P,r}^c, VAR_{P,r})$ ,  $\tau, P, r$  是正常数, 这里

$$[0129] \quad LBP_{P,r}^c = \sum_{p=0}^{P-1} H(I_p - I_c - \tau \cdot \text{sign}(I_p - I_c)) \times 2^p$$

$$[0130] \quad VAR_{P,r} = \frac{1}{P} \sum_{p=0}^{P-1} (I_p - I_m)^2, I_m = \frac{1}{P} \sum_{p=0}^{P-1} I_p$$

[0131] 其中  $I_p$  ( $p=0, 1, \dots, P-1$ ) 对应的是均匀分布在以  $c \in \Omega$  为圆心,  $r$  为半径的圆上的  $P$  个点的灰度值,  $I_c$  是圆心处的灰度值。  $H(x)$  是 Heaviside 函数, 即:

$$[0132] \quad H(x) = \begin{cases} 1, & \text{if } x > 0, \\ 0, & \text{otherwise} \end{cases}$$

[0133] 记  $H_x^i$  为像素点  $x$  在局部邻域  $O(x)$  内的第  $i$  个特征的累积直方图。  $H_0^i$  是第  $i$  个特征在初始化区域内的平均累积直方图, 其方差记作  $\sigma_0^i$ 。则其局部表征项可以定义为

$$P(x) = \sum_{i=1}^{i=3} \frac{W^1(H_x^i, H_0^i)}{(\sigma_0^i)^2}, \quad W^1(\dots)$$

是一维的 L1 Wasserstein 距离。最后组合 SegCNN 得到的病灶区

域的分割概率图  $L(x)$ , 灰度阈值函数  $F(x)$  和局部表征  $P(x)$  得到数据项表达式  $D_x(l_x)$  为,

$$[0134] \quad D_x(l_x) = \max(-R(x), 0) l_x + \max(R(x), 0) (1 - l_x)$$

[0135] 这里  $R(x) = \sum_{y \in N_x} B_{xy}(x, y) [F(x) + L(x) - 0.5 + \gamma P(x)]$ ,  $\gamma$  是正常数。从而我们就可以得到

图割模型, 对病灶区域进行细化分割。

[0136] 第3步: 利用第2步得到的 SegCNN 模型应用于所有的病灶影像, 即对第1步选取的 20000 张图像进行自动分割, 然后建立一个图割模型, 对 SegCNN 得到的病灶区域进行自动的细化分割。最终得到 ROI, 即所有的良恶性病灶。

[0137] 四、建立第二个卷积神经网络架构自动解读良恶性病灶特征,将过程三SegCNN模型自动分割出的ROI (即所有的良恶性病灶) 平均分成p组,这个CNN模型记作建立的RecCNN,再对特征数据进行归一化。即利用SegCNN模型自动分割出病灶之后,再利用RecCNN模型提取这些病灶的特征,对提取出的这些特征进行线性变换,使结果值映射到[0, 1]。

[0138] 其中,所述p取值范围为大于等于2的正整数;

[0139] 所述RecCNN是由6层卷积层、4层下采样层、3层全连接层组成的网络结构,三个全链接层的神经元节点数分别为4096, 4096, 1;各卷积层的卷积核的大小分别为:第一层为13×13,第二层与第三层为11×11,第四层为5×5,其余各层为3×3;步长分别是:第一个卷积层是2,其余的都是1;下采样层的大小都是3×3,步长都是2。

[0140] 五、选出步骤四中p-1组数据作训练集,训练集用于训练RecCNN模型,剩余一组作测试集,测试集用于对训练好的RecCNN模型进行测试。

[0141] 利用训练集训练出RecCNN模型,用于解读医学图像特征,能对所有自动分割出来的病灶区域提取特征,然后进行分析。具体训练过程为:其提取特征的方法与过程三的SegCNN模型自动分割中提取特征过程的方法是一样的,即都是通过各自的各个卷积层与池化层提取特征,这两类功能层的作用是一样的,其计算公式与更新方法是一样的,但是SegCNN模型自动分割部分是针对非病灶区域与病灶区域同时进行提取特征,本过程五中RecCNN模型的对象只是针对病灶区域,而自动分割部分是针对非病灶区域与病灶区域同时进行提取特征,且RecCNN模型与SegCNN模型的卷积核大小与池化窗口大小,以及卷积层和池化层的步长大小和填充大小设置不同,所以彼此的卷积层与池化层作用范围不同。

[0142] 然后利用Softmax构造一个能进行多分类的分类器,对提取出来的特征进行分析,这个过程实际上就是求解一个损失函数的最优值,一般地即是优化损失函数

$$J(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^c e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^c \theta_{ij}^2, \text{ 其中, 所述 } i \text{ 是指第 } i \text{ 个样本;}$$

[0143] 所述j是指第j类;所述l是指第l类;所述m表示共有m个样本,m取值范围为任意正

整数;所述c表示这些样本总共可分为c类,c取值范围为任意正整数;所述 $\theta = \begin{bmatrix} \theta_1^T \\ \theta_2^T \\ \vdots \\ \theta_c^T \end{bmatrix}$  是一个矩

阵,每一行是一个类别所对应的参数,即权重与偏置;所述 $\theta_j^T$ 是指第j类的参数向量的转置,所述 $\theta_1^T$ 是指第1类的参数向量的转置,所述 $\theta_{ij}$ 是指参数矩阵的第i行第j的元素;所述 $1\{.\}$  是一个指示性函数,即当大括号中的值为真时,该函数的结果为1,否则其结果为0;所述 $\lambda$ 是平衡保真项(第一项)与正则项(第二项)的参数,这里 $\lambda$ 取正数(根据实验结果调节其大小);所述e表示欧拉数2.718281828, $e^x$ 就是指指数函数;所述T是表示矩阵计算中的转置运算符;log表示自然对数,即以欧拉数为底的对数; $x^{(i)}$ 是输入向量的第i维; $y^{(i)}$ 是每个样本标签的第i维;Softmax分类器的类别数c等于5(即分别代表病灶的回声特征、边缘特征、结构特征、钙化特征、纵横比特征五类特征),每个类都有不同的子类,其中回声特征有高回声,等回

声,低回声或者极低回声,无回声四类,边缘特征有光整与不光整两类,结构特征有实性,实性为主,囊性为主,囊性四类,钙化特征有微钙化与无微钙化两类,纵横比特征有大于1与小于等于1两类;通过随机梯度下降方法就可以得到输出的特征向量分别属于哪类特征的子类的概率;具体过程为:与过程三中SegCNN模型自动分割过程中预测方法是类似的,都是优化一个损失函数,只不过这里用的是一个多分类的Softmax函数,根据输出特征向量的隶属哪类特征的概率预测出一个分类标签,即得到该病灶的特征属于哪类特征的概率,也就对一个病灶特征进行了分类,进一步可以得出良恶性病灶对应的特征种类。

[0144] 六、重复步骤五,做p次交叉检验,即对于过程四分好的p组数据,每次选出一组不同的数据作测试集,余下的p-1组数据作训练集,直至每一组数据都作过测试集。

[0145] 经过过程五与过程六的p次交叉检验,每次都会保存卷积神经网络模型RecCNN的权重与偏置参数,根据测试集上的准确率评估结果,这里准确率的计算公式为 $AC = \frac{TN}{TN + FN}$ ,其中AC表示准确率;TN表示分类正确的样本数;FN表示分类错误的样本数。每次的准确率与p次的平均值相差不大,就取其中准确率稍高的一组权重与偏置参数作为RecCNN的参数,即最终得到RecCNN的最佳参数,也就是训练好了RecCNN模型,从而最终确定了基于深度学习方法解读医学影像特征的辅助诊断系统。

[0146] 将需要解读的病灶图像输入到这个辅助诊断系统,即可获得该病灶的五类特征,并对其每类特征进行分析,进而可以根据这些特征诊断良恶性病灶。

[0147] 图2、图3是展示了实验中用来训练SegCNN模型的病灶的原始超声图像与对应的病灶区域的mask图片;图4、图5展示了一张病灶的原始超声图像与利用SegCNN自动分割出病灶区域mask的效果图片。

[0148] 最后,需要注意的是,以上列举的仅是本发明的具体实施例。显然,本发明不限于以上实施例,还可以有很多变形。本领域的普通技术人员能从本发明公开的内容中直接导出或联想到的所有变形,均应认为是本发明的保护范围。



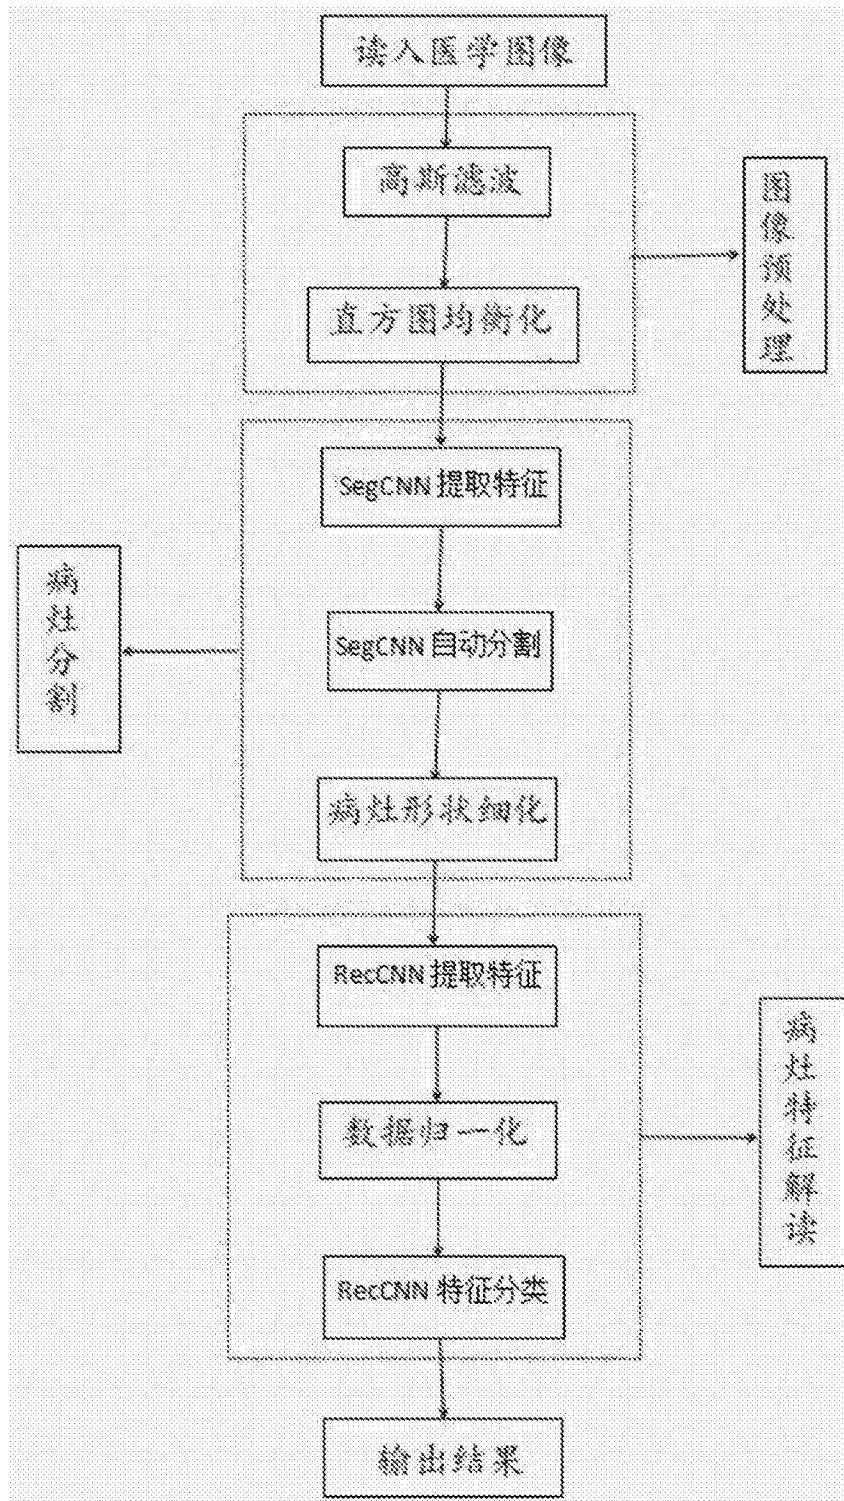


图1




图2




图3




图4




图5