



(12) 发明专利

(10) 授权公告号 CN 112163599 B

(45) 授权公告日 2023. 09. 01

(21) 申请号 202010932190.6

G06V 10/80 (2022.01)

(22) 申请日 2020.09.08

G06V 10/82 (2022.01)

G06N 3/0464 (2023.01)

(65) 同一申请的已公布的文献号

申请公布号 CN 112163599 A

(43) 申请公布日 2021.01.01

(73) 专利权人 北京工商大学

地址 100048 北京市海淀区阜成路33号

(72) 发明人 万玉钗 刘峡壁 王穆荣 郑中枢

朱正 赵心明

(56) 对比文件

CN 107292328 A, 2017.10.24

CN 110555446 A, 2019.12.10

US 2019183429 A1, 2019.06.20

石陆魁;杜伟昉;马红祺;张军.基于多尺度和特征融合的肺癌识别方法.计算机工程与设计.2020,(第05期),全文.

(74) 专利代理机构 北京理工大学专利中心

11120

专利代理师 代丽 郭德忠

审查员 贾云杰

(51) Int. Cl.

G06V 10/774 (2022.01)

G06V 10/764 (2022.01)

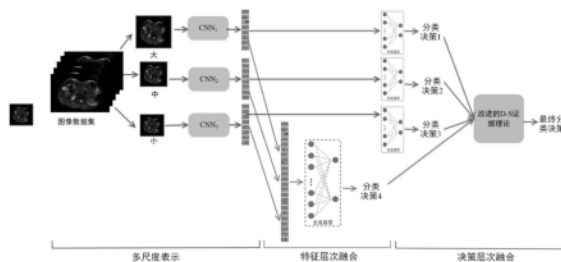
权利要求书1页 说明书8页 附图1页

(54) 发明名称

一种基于多尺度多层次融合的图像分类方法

(57) 摘要

本发明公开了一种基于多尺度多层次融合的图像分类方法,通过对输入图像进行尺度变换,将多尺度图像作为输入,能够提取图像的全局和局部特征,形成对图像目标的全面描述,然后对图像的多个尺度的描述特征进行多层次的融合,得到最终的分类识别结果,即从多尺度图像描述和多层次信息融合方面出发,有效提高了卷积神经网络图像分类器的分类性能。



1. 基于多尺度多层次融合的图像分类方法,其特征在于,包括以下步骤:

步骤1、将待分类图像表示为多个具有不同尺度的图像,将不同尺度的图像分别输入相应的基于卷积神经网络的尺度分类器,得到所述待分类图像的多个尺度分类决策结果;

步骤2、将所述尺度分类器提取的视觉特征进行串接形成融合特征,将所述融合特征作为基于卷积神经网络的特征融合分类器的输入层;根据所述融合特征对分类识别的贡献,确定所述特征融合分类器的全连接层的权值;所述特征融合分类器的输出层为所述待分类图像的特征融合分类决策结果;

步骤3、采用证据理论,根据所述尺度分类决策结果及特征融合分类决策结果计算尺度分类器及特征融合分类器的基本概率分配函数 $m(\cdot)$,如下式所示:

$$\begin{cases} m_{ij}(A) = p_{ij_{C_s}} * acc_i, & \text{if } A = C_s (s=1,2,\dots,n) \\ m_{ij}(A) = 1 - acc_i, & \text{if } A = \Theta \\ m_{ij}(A) = 0, & \text{其他} \end{cases}$$

其中, acc_i 表示尺度分类器或特征融合分类器 i 在整个数据集上的平均分类准确率; $1 - acc_i$ 表示分类器的不确定性; $p_{ij_{C_s}}$ 为尺度分类器或特征融合分类器 i 的输出,表示尺度分类器或特征融合分类器 i 将图像 j 归类为 C_s 类图像的概率, n 为图像类型的总数, Θ 为相互独立的有穷集合;

根据所述基本概率分配函数计算冲突系数,当冲突系数小于设定阈值时,融合所述尺度分类决策结果及特征融合分类决策结果得到最终分类决策结果;当冲突系数大于阈值时,计算所述尺度分类器及特征融合分类器的置信度,将置信度最高的分类器的输出作为最终分类决策结果。

2. 根据权利要求1所述的方法,其特征在于,所述不同尺度的图像包括尺寸由小到大的三个尺度的图像。

3. 根据权利要求2所述的方法,其特征在于,当以分类目标所在区域为分析对象时,所述不同尺度的图像为围绕目标所在区域裁剪所述待分类图像得到的三种不同尺度的图像块;当以整幅图像作为分析对象时,所述不同尺度的图像为采用高斯金字塔方法对所述待分类图像进行降采样得到的三种尺度的表示。

4. 根据权利要求1所述的方法,其特征在于,所述步骤2中的特征融合分类器采用迁移学习策略进行参数训练。

5. 根据权利要求1所述的方法,其特征在于,在所述步骤3中采用soft-max函数将所述尺度分类器或特征融合分类器的输出值转化为概率值。

一种基于多尺度多层次融合的图像分类方法

技术领域

[0001] 本发明属于模式识别、深度学习及人工智能技术领域,具体涉及一种基于多尺度多层次融合的图像分类方法。

背景技术

[0002] 随着计算机技术的发展,深度学习方法受到越来越多研究者的关注,其在图像分类、视频分析、自然语言处理等领域取得了较大的突破和进展。卷积神经网络(Convolutional Neural Network,CNN)是深度学习中一种经典而广泛采用的神经网络结构,一般由卷积层、池化层、全连接层等组成。卷积神经网络的局部连接、权值共享及池化操作等特性使之可以有效地降低网络的复杂度,且也易于训练和优化。

[0003] 在图像识别和分类领域,卷积神经网络一般有两种应用模式:一类是特征提取器,该模式基于卷积神经网络提取图像的抽象视觉特征,并将该特征作为其他算法的输入进行计算。相比于传统的人工设计特征,基于卷积神经网络提取的视觉特征具有更好的描述能力,这得益于神经网络的较大参数空间和自动学习能力。另一类是端到端的分类模型,该模式为卷积神经网络在图像识别领域较常采用的模式,其将图像整体作为卷积神经网络的输入,经过计算后,在输出层输出图像的分类识别结果。相比于传统的图像分类方法,基于卷积神经网络进行图像分类的方法在分类准确率等方面上带来了较大提升,受到了广泛关注。

[0004] 综上所述,目前已有的基于卷积神经网络进行图像分类的算法大多将图像本身输入卷积神经网络进行分析,仅在图像特征层次进行融合,不能全面利用图像的分类信息,因而,导致了分类的准确率等性能依然没有较大提高,图像的分类结果不能完全令人满意。

发明内容

[0005] 有鉴于此,本发明提供了一种基于多尺度多层次融合的图像分类方法,能够实现图像的准确分类。

[0006] 本发明提供的基于多尺度多层次融合的图像分类方法,包括以下步骤:

[0007] 步骤1、将待分类图像表示为多个具有不同尺度的图像,将不同尺度的图像分别输入相应的基于卷积神经网络的尺度分类器,得到所述待分类图像的多个尺度分类决策结果;

[0008] 步骤2、将所述尺度分类器提取的视觉特征进行串接形成融合特征,将所述融合特征作为基于卷积神经网络的特征融合分类器的输入层;根据所述融合特征对分类识别的贡献,确定所述特征融合分类器的全连接层的权值;所述特征融合分类器的输出层为所述待分类图像的特征融合分类决策结果;

[0009] 步骤3、采用证据理论,根据所述尺度分类决策结果及特征融合分类决策结果计算尺度分类器及特征融合分类器的基本概率分配函数 $m(\cdot)$,如下式所示:

$$[0010] \quad \begin{cases} m_{ij}(A) = p_{ij_C_s} * acc_i, & \text{if } A = C_s (s = 1, 2, \dots, n) \\ m_{ij}(A) = 1 - acc_i, & \text{if } A = \Theta \\ m_{ij}(A) = 0, & \text{其他} \end{cases}$$

[0011] 其中, acc_i 表示尺度分类器或特征融合分类器 i 在整个数据集上的平均分类准确率; $1 - acc_i$ 表示分类器的不确定性; $p_{ij_C_s}$ 为尺度分类器或特征融合分类器 i 的输出, 表示尺度分类器或特征融合分类器 i 将图像 j 归类为 C_s 类图像的概率, n 为图像类型的总数, Θ 为相互独立的有穷集合;

[0012] 根据所述基本概率分配函数计算冲突系数, 当冲突系数小于设定阈值时, 融合所述尺度分类决策结果及特征融合分类决策结果得到最终分类决策结果; 当冲突系数大于阈值时, 计算所述尺度分类器及特征融合分类器的置信度, 将置信度最高的分类器的输出作为最终分类决策结果。

[0013] 进一步地, 所述不同尺度的图像包括尺寸由小到大的三个尺度的图像。

[0014] 进一步地, 当以分类目标所在区域为分析对象时, 所述不同尺度的图像为围绕目标所在区域裁剪所述待分类图像得到的三种不同尺度的图像块; 当以整幅图像作为分析对象时, 所述不同尺度的图像为采用高斯金字塔方法对所述待分类图像进行降采样得到的三种尺度的表示。

[0015] 进一步地, 所述步骤2中的特征融合分类器采用迁移学习策略进行参数训练。

[0016] 进一步地, 在所述步骤3中采用 soft-max 函数将所述尺度分类器或特征融合分类器的输出值转化为概率值。

[0017] 有益效果:

[0018] 本发明通过对输入图像进行尺度变换, 将多尺度图像作为输入, 能够提取图像的全局和局部特征, 形成对图像目标的全面描述, 然后对图像的多个尺度的描述特征进行多层次的融合, 得到最终的分类识别结果, 即从多尺度图像描述和多层次信息融合方面出发, 有效提高了卷积神经网络图像分类器的分类性能。

附图说明

[0019] 图1为本发明提供的一种基于多尺度多层次融合的图像分类方法的框架图。

[0020] 图2(a)为本发明提供的一种基于多尺度多层次融合的图像分类方法采用的基于图像区域的裁剪方法形成的多尺度图像示意图。

[0021] 图2(b)为本发明提供的一种基于多尺度多层次融合的图像分类方法采用的基于图像整体的高斯金字塔方法形成的多尺度图像示意图。

具体实施方式

[0022] 下面结合附图并举实施例, 对本发明进行详细描述。

[0023] 本发明提供的一种基于多尺度多层次融合的图像分类方法, 其基本思想是: 通过对图像的多尺度表示, 能够提取图像的全局和局部等全面的描述信息; 然后, 进行特征层次融合, 即将多个尺度的视觉特征信息进行融合, 并采用卷积神经网络构建各个尺度的分类器及融合后分类器, 对多个尺度的视觉特征信息及融合后的信息进行分类, 得到分类决策

结果;最后是决策层次融合,即在决策层次上对多个决策结果进行融合,以得到最终的分类决策。

[0024] 本发明提供了一种基于多尺度多层次融合的图像分类方法,如图1所示,包括图像的多尺度表示、特征层次融合和决策层次融合三个部分,具体包括以下步骤:

[0025] 步骤1、将待分类图像表示为多个具有不同尺度的图像,将不同尺度的图像分别输入相应的基于卷积神经网络的尺度分类器,得到所述待分类图像的多个尺度分类决策结果。

[0026] 本发明可采用三种尺度表示图像,分别为“Large”、“Middle”和“Small”三种。在不同尺度的图像中,图像中的识别目标具有不同的视觉特性,因此能够基于三种尺度的图像提取出三组不同的特征。

[0027] 对于多尺度图像的生成,根据不同的应用需求,本发明提供两种不同的策略。若以图像中分类目标所在的区域为分析对象,则可围绕目标区域裁剪得到三种不同尺度的图像块,例如图2(a)所示。若以整幅图像作为分析对象,则可采用高斯金字塔方法对原始图像进行降采样,得到原始图像三种尺度的表示,例如图2(b)所示。

[0028] 本发明采用卷积神经网络提取图像的视觉描述特征。对于以上每一种尺度的图像集,分别构建神经网络,并进行参数训练,得到三个不同尺度的卷积神经网络。对于每一幅图像,抽取卷积神经网络的全连接层作为其视觉特征表示,得到三个尺度的特征向量,然后,由卷积神经网络进一步对该图像的视觉特征进行分类识别,得到对应三个尺度的不同分类决策。

[0029] 步骤2、将所述尺度分类器的输入层进行串接形成融合特征,将所述融合特征作为基于卷积神经网络的特征融合分类器的输入层;根据所述融合特征对分类识别的贡献,确定所述特征融合分类器的全连接层的权值;所述特征融合分类器的输出层为所述待分类图像的特征融合分类决策结果。

[0030] 由于图像中目标的尺寸、方向、位置等的不同,不同尺度的图像具有不同的视觉特征。为充分利用多个尺度的视觉特征信息,需要对图像进行特征层次的融合,并基于融合后的特征进行分类识别。

[0031] 为进行特征层次的融合,本发明采用三层的卷积神经网络结构作为特征融合分类器,首先,对三个尺度的特征进行串接,并作为该神经网络的输入层。然后,根据串接后不同的特征值对分类识别的贡献,为其分配不同的全连接层权值。经过全连接层的计算后,在输出层输出分类结果,即为不同尺度的信息在特征层次融合后的分类决策。

[0032] 对于特征融合分类器的训练,可采用迁移学习的策略进行参数学习,即:首先在大规模的已有数据集上进行神经网络参数的预训练,然后再将神经网络迁移到具体应用领域上,利用该领域少量的数据对神经网络参数进行精调。

[0033] 步骤3、采用证据理论,根据所述尺度分类决策结果及特征融合分类决策结果计算尺度分类器及特征融合分类器的基本概率分配函数;根据所述基本概率分配函数计算冲突系数 T ,当 T 小于阈值时,融合所述尺度分类决策结果及特征融合分类决策结果得到最终分类决策结果;当 T 大于阈值时,计算所述尺度分类器及特征融合分类器的置信度,将置信度最高的分类器的输出作为最终分类决策结果。

[0034] 本发明通过步骤1和步骤2,针对“Large”、“Middle”、“Small”三个尺度以及融合后

的特征,构建了四个卷积神经网络分类器。对于每一幅图像,四个分类器可分别给出四种决策结果。由于识别目标大小、位置、方向等的不同,最优的分类决策可能在不同尺度的分类器中获得。因此,为了增强图像分类器的准确性和稳定性,本发明在决策层次上对多尺度的决策信息进行了融合。

[0035] 步骤3.1、确定基本概率分配函数。

[0036] 现有技术中的D-S证据理论是一种不确定性推理的数学理论和方法,其将不同的信息来源视为不同的证据,并基于Dempster准则对不同的证据进行融合,得到最终的决策。令 Θ 表示一个相互独立的有穷集合,称为识别框架。对于 Θ 的任意子集A,每个证据可提供其基本可信度概率值 $m(A)$,且 $m(A)$ 满足如下要求:

$$[0037] \quad \begin{cases} m(\phi) = 0 \\ \sum_{A \subset \Theta} m(A) = 1 \end{cases} \quad (1)$$

[0038] 其中, ϕ 表示空集,表示在任何情况下都不会出现的状态。 $m(\cdot)$ 函数称为基本概率分配函数(Basic Probability Assignment,BPA)。对于同一识别框架上的 w 个证据,可采用现有技术中的下述公式将其融合为一个一致的决策:

$$[0039] \quad \begin{cases} m(A) = K^{-1} \sum_{\cap A_i = A} \prod_{i=1}^w m_i(A_i) \\ K = \sum_{\cap A_i \neq \phi} \prod_{i=1}^w m_i(A_i) \end{cases} \quad (2)$$

[0040] 在本发明中,令 n 表示数据集中图像类别的个数,则 $\Theta = \{C_1, C_2, \dots, C_n\}$,其中 C_n 表示第 n 类图像类别。对于A,根据卷积神经网络分类器只输出每个类别对应概率的特点,本发明只考虑 Θ 的如下子集 $A = \{C_1\}, A = \{C_2\}, \dots, A = \{C_n\}$ 以及 $A = \Theta$ 的情况,其他子集对应的基本概率值置为0。其中 $A = \Theta$ 表示分类器不能给出明确的分类,即:分类器的不确定性。

[0041] 在D-S证据理论的相关应用中,BPA的定义是一个难点,因为其需要将解决实际问题的认知转化为一种概率表达。本发明结合分类器的整体不确定性以及在单个图像上的分类表现,设计并定义BPA。对于本发明中的卷积神经网络分类器 i ($i = 1, 2, 3, 4$),定义其对图像 j 的BPA如下公式(3)所示:

$$[0042] \quad \begin{cases} m_{ij}(A) = p_{ij_{C_s}} * acc_i, \text{ if } A = C_s (s = 1, 2, \dots, n) \\ m_{ij}(A) = 1 - acc_i, \text{ if } A = \Theta \\ m_{ij}(A) = 0, \text{ otherwise} \end{cases} \quad (3)$$

[0043] 其中 acc_i 表示分类器 i 在整个数据集上的平均分类准确率, $1 - acc_i$ 表示分类器的不确定性。 $p_{ij_{C_s}}$ 来源于分类器 i 的输出,表示分类器 i 将图像 j 归类为 C_s 类的概率。由于卷积神经网络分类器输出的值的范围不为 $[0, 1]$,本发明采用soft-max函数将其转化为概率值,即 $p_{ij_{C_s}} \circ$

[0044] 步骤3.2、冲突消除。

[0045] 已有的传统D-S证据理论融合方法存在的问题是:不同的证据之间可能会存在冲

突。利用传统D-S证据理论方法对高冲突证据进行融合时,得到的结果会产生误差。为消除冲突,本发明对传统D-S证据理论进行改进,设计并提出一种自适应的融合方法。

[0046] 在公式(2)中, K 是一个归一化系数,同时也是冲突系数。较大的 K 值表示证据之间的冲突较高,较小的 K 值表示证据之间的冲突较低。因此,本发明根据 K 的值设定阈值,若 K 值小于阈值,则采用传统的D-S证据理论方法对四个卷积神经网络分类器进行融合;若 K 值大于阈值,则计算各证据的置信度,将置信度最高的证据对该图像的分类决策作为融合后的分类决策。置信度量一个证据被其他证据的支持度高,高的置信度表示其与其他证据的一致度越高,重要性也越高。

[0047] 置信度的计算过程包括:首先,计算证据的支持度矩阵;然后,计算证据与其他证据之间的相似度,对证据的相似度求和,得到证据 i 的支持度;最后,对支持度进行归一化,得到证据的置信度。

[0048] 决策层次融合的方法概括描述为:对于一幅图像,四个尺度的卷积神经网络分类器可输出四个分类结果。本发明对传统的D-S证据理论方法进行改进,以对四个分类结果进行融合。首先计算四个分类器的冲突系数 K ,若 K 小于阈值,则按照传统D-S证据理论方法对分类结果进行融合;若 K 大于阈值,则计算四个证据的置信度,并取置信度最高的分类器的分类结果作为该图像融合后的分类结果。算法1对决策层次融合方法进行详细描述。

[0049] 算法1. 决策层次融合算法

输入: 1)4个卷积神经网络分类器的分类输出结果

2)每个分类器的平均分类准确率 acc_i

3) 阈值 T

输出: 决策层次融合后的分类决策

步骤:

1. 使用 `softmax` 函数归一化分类器的输出结果;

[0050] 2. 使用公式(3)计算每个分类器的BPA;

3. 使用公式(2)计算冲突系数 K ; (现有技术)

4. 如果 K 小于阈值 T :

5. 采用传统D-S证据理论融合方法对四个分类器的输出进行融合,得到最终分类结果;

6. 否则:

7. 使用公式(4)-(7)计算每个卷积神经网络分类器的置信度;

8. 选出置信度最高的分类器,将其分类决策作为最终分类决策。

[0051] 为了验证本发明所提出的一种基于多尺度多层次融合的图像分类方法,本发明在肝脏MRI图像数据集上进行了肝脏病灶良恶性分类的实验。

[0052] 实验设置

[0053] A) 数据集:本发明在肝脏MRI图像数据集上进行了实验。该数据集由中国医学科学院肿瘤医院收集并标注。该数据集内的MRI图像均基于美国GE Signa Excite HD 3.0T超导MR成像仪进行拍摄。数据集包含85例(良性35例,恶性50例)患者,每例患者均进行常规扫描和动态增强扫描等,共获取不同时期的5个扫描图像。因此数据集中共包含425幅肝脏MRI图像,其中良性175幅,恶性250幅。数据集中图像的病灶区域均由中国医学科学院肿瘤医院有经验的放射科医生进行人工标注,以提供实验对比标准。

[0054] B) 对比方法:为了验证本发明所提出方法的通用性,选用多个目前常用的性能较好的卷积神经网络架构进行实验,包括:Resnet18、VGG11和Alexnet架构。三种网络架构均在ImageNet大规模图像数据集上进行预训练,然后迁移到本数据集上进行参数精调。对于

每一种卷积神经网络架构,分别对比单尺度下(即:只使用一种尺度的图像,且不考虑融合)的分类性能、仅采用特征层次融合的分类性能以及采用本发明提出的多尺度多层次融合方法的分类性能。本实验采用基于病灶区域的分类,即:在MRI图像中,围绕病灶区域裁剪得到三个不同尺度的病灶区域图像。“Large”、“Middle”和“Small”三个尺度所对应的图像像素分别为 256×256 , 128×128 , 64×64 。为适应三个网络架构的输入尺寸要求,病灶区域图像均采用双线性插值方法调整到要求的尺寸。

[0055] 同时,本实验与非深度学习的传统分类方法进行了对比。对于传统分类方法,采用广泛使用的灰度级同现矩阵GLCM(Grey Level Co-Occurrence Matrices)特征进行病灶描述,并分别使用AdaBoost、支持向量机(Support Vector Machine, SVM)和随机森林(Random Forest, RF)分类器进行分类实验。

[0056] C) 评价指标:本实验采用5个常用的指标评价分类器的性能,分别为:分类准确率、敏感度(sensitivity)、特异度(specificity)、阳性预测值(positive predictive value, PPV)和阴性预测值(negative predictive value, NPV)。分类准确率度量在整个数据集中被正确分类的图像所占的比例,敏感度或特异度度量阳性或阴性数据中被正确分类的比例,PPV和NPV度量在被分类为阳性或阴性的集合中真正为阳性或阴性的图像的比例。

[0057] 若一个阳性样本被正确分类,称其为“真阳性”(True Positive, TP),否则称其为“假阴性”(False Negative, FN);若一个阴性样本被正确分类,称其为“真阴性”(True Negative, TN),否则称其为“假阳性”(False Positive, FP)。则分类准确率、敏感度、特异度、PPV和NPV的计算公式分别为:

$$[0058] \quad \text{准确率} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$[0059] \quad \text{敏感度} = \frac{TP}{TP + FN} \quad (9)$$

$$[0060] \quad \text{特异度} = \frac{TN}{TN + FP} \quad (10)$$

$$[0061] \quad \text{准确率} = \frac{TP}{TP + FP} \quad (11)$$

$$[0062] \quad \text{准确率} = \frac{TN}{TN + FN} \quad (12)$$

[0063] D) 设置细节:本实验采用5折交叉验证方法对模型进行训练和测试,并取5次实验的平均值作为最终结果进行呈现。采用随机梯度下降方法对神经网络的参数进行优化,其中学习率、迭代次数、批次大小分别设置为0.001、500和10。冲突系数阈值设置为0.85。所有实验均在具有10GB内存和一块Nvidia GeForce 1080Ti的GPU的计算机上完成。

[0064] 实验结果

[0065] 本实验采用上述各对比方法进行肝脏病灶良恶性分类实验,各方法的实验结果如表1所示。表1对各个神经网络框架或传统方法的结果进行分成显示,并分别用粗体和斜体字体将每组中的最优和次优结果进行呈现。

[0066] 表1. 在肝脏病灶良恶性分类问题中,不同方法分类性能比较

方法		平均准确率 (%)	敏感度 (%)	特异度(%)	PPV(%)	NPV(%)
[0067] 传统方法	GLCM+ AdaBoost	85.31	87.97	81.23	87.31	75.45
	GLCM + SVM	84.30	93.20	71.62	82.53	75.64
	GLCM + RF	87.09	90.69	81.63	88.02	80.83
Resnet18	Large 尺度	92.20	94.34	88.63	92.45	91.64
	Middle 尺度	90.58	92.77	87.38	91.52	89.17
	Small 尺度	92.15	92.94	91.00	93.83	89.79
	特征层次融合	92.56	94.47	89.75	93.17	91.65
	多层次融合	95.70	97.02	93.75	95.80	95.54
[0068] VGG11	Large 尺度	94.02	95.74	91.50	94.32	93.67
	Middle 尺度	95.65	96.94	93.75	95.80	95.43
	Small 尺度	94.28	94.89	93.38	95.48	92.59
	特征层次融合	97.97	98.30	97.50	98.30	97.53
	多层次融合	98.99	98.72	99.38	99.57	98.15
Alexnet	Large 尺度	96.60	97.45	95.38	96.91	96.15
	Middle 尺度	95.04	95.74	94.00	95.91	93.77
	Small 尺度	98.03	98.21	97.75	98.51	97.39
	特征层次融合	98.86	98.93	98.75	99.14	98.46
	多层次融合	99.49	99.15	100	100	98.77

[0069] 从表1可以看出：

[0070] 1) 基于深度学习的方法在分类性能上明显优于传统方法；

[0071] 2) 与Large、Middle或Small等单尺度的方法相比，特征层次融合方法在整体上可以带来分类性能的提高。除了在Resnet18框架中的特异度和PPV指标外，特征层次融合方法在五个指标上都比单尺度的方法带来了性能的提升。

[0072] 3) 本发明提供的多尺度多层次融合方法在取得了最优的分类性能，其在三个卷积神经网络框架的五个指标中都获得了最高的结果。

[0073] 4) 通过2) 和3) 中的对比可以看出，特征层次融合方法具有比单尺度方法更好的分类性能，而决策层次融合能够在特征层次融合的基础上进一步提高分类性能。这说明特征层次融合和决策层次融合的必要性，二者缺一不可。证明了本发明提供的多尺度多层次融合方法在分类表现上的优越性。

[0074] 5) 在实验对比的三个常用的卷积神经网络框架中，本发明提供的卷积神经网络图像分类器多尺度多层次融合方法都取得了最优的表现，证明本发明所提供方法具有较强的稳定性和通用性。

[0075] 进一步地，为了观察在特征层次进行不同尺度特征串接后的特征表现，本实验采用PCA(Principal Component Analysis)方法对串接后的特征进行降维，并映射到2维空间中进行呈现。GLCM特征以及各卷积神经网络框架串接后的特征降维结果，可以看出在GLCM特征中，大部分良性和恶性病灶混合在一起，较难对其进行区分。与GLCM特征相比，采用深度特征对病灶的区分度较高。深度特征对病灶的区分度越来越高，不可区分的数据逐渐减

少,这与表1中三个框架对应分类平均准确率的逐步提升相呼应。

[0076] 综上所述,以上仅为本发明的较佳实施例而已,并非用于限定本发明的保护范围。凡在本发明的精神和原则之内,所作的任何修改、等同替换、改进等,均应包含在本发明的保护范围之内。

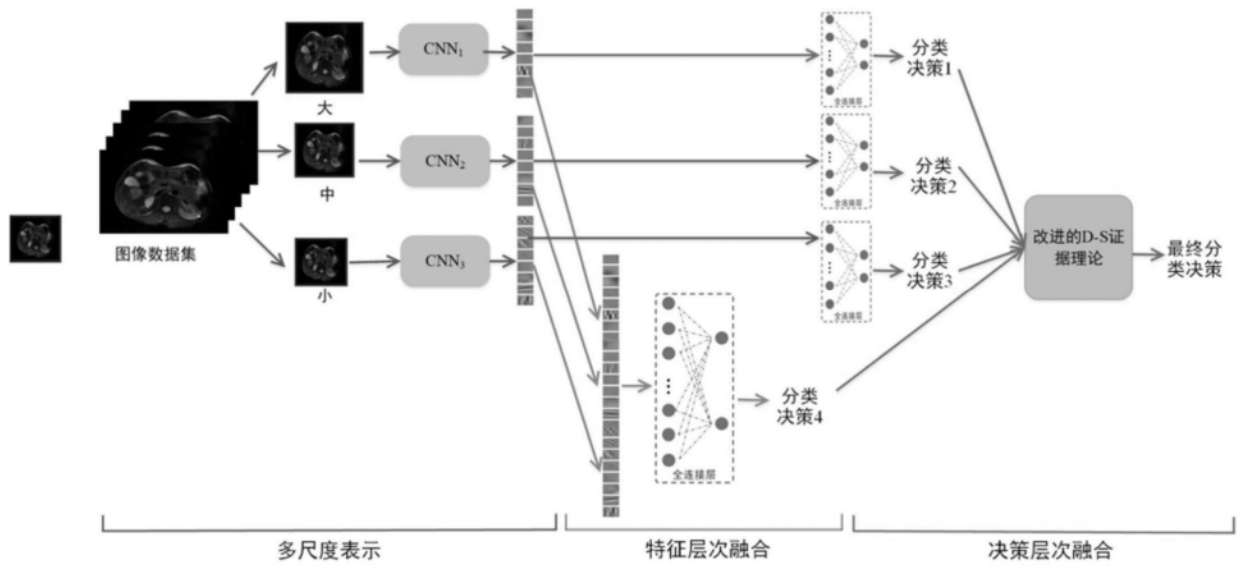


图1




图2(a)




图2(b)