

·测试、试验与仿真·

增强层次CNN模型在目标识别应用中的研究

史天予¹, 胡玉兰¹, 孙家民¹, 袁德鹏²

(1.沈阳理工大学 信息科学与工程学院, 沈阳 110159; 2.东北大学 计算机科学与工程学院, 沈阳 110819)

摘要:受生物视觉信息处理机制启发的目标识别是当前计算机视觉领域研究的热点之一,其主要思想是对大脑视觉皮层中视觉信息的层次性处理过程进行模拟,构建数学模型来实现目标识别。然而传统的层次化计算模型通常以前馈信息传递为基础,层与层之间采用被动的硬连接方式,强调对视觉信息的多层分解,却较少涉及视觉神经系统的主动感知和学习过程。因此选择以同时具备稀疏连接思想和自我学习机制、并且具备良好网络拓扑结构的卷积神经网络为框架,基于经典卷积神经网络模型,融入分层和仿生的思想,提出新的基于视觉神经增强层次CNN模型——IH-CNN。实验结果表明, IH-CNN模型可以较好的解决大规模图像中的目标识别问题,目标识别准确率高达84%。

关键词:生物视觉;目标识别;Caltech-101;卷积神经网络

中图分类号:TP391.4

文献标识码:A

文章编号:1673-1255(2016)-04-0066-07

Research on the Application of Intensive Hierarchical Convolution Neural Network Model in Target Recognition

SHI Tian-yu¹, HU Yu-lan¹, SUN Jia-min¹, YUAN De-peng²

(1. School of Information Science and Engineering, Shenyang Ligong University, Shenyang 110159, China;

2. School of Computer Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Object recognition inspired by biological visual information processing mechanism is one of the research subjects in current computer vision research field, the main idea is to simulate the hierarchical process of visual information in brain visual cortex and build mathematic model to achieve target recognition. However, traditional hierarchical calculation model is usually built based on front feed information transfer, and the passive hard wired way is used between layer and layer. The multi level decomposition of visual information is emphasized, but less involved in the active perception and learning process of visual nervous system. So the convolutional neural networks with sparsely connection thought, self learning mechanism and good network topology structure are chosen as the framework. Based on classical convolutional neural network model, with hierarchical and biomimetic idea, a new enhanced level convolution neural network (CNN) model IH-CNN based on visual nerve is proposed. Experimental results show that target recognition issue in large scale images can be better solved through IH-CNN model and the target recognition accuracy rate is 84%.

Key words: biological vision; target recognition; Caltech-101; convolutional neural network

随着人类对自身视觉信息处理机制的深入了解,对大脑视觉系统进行模拟以增强机器视觉的环境感知与认知能力已经称为计算机视觉领域的研

究热点之一。然而,如何对大脑视觉系统的典型功能和信息处理机制进行模拟,使计算机具备人类观察和理解世界的的能力,依然是计算机视觉领域面临

收稿日期:2016-08-18

基金项目:国家自然科学基金项目(61373089)

作者简介:史天予(1991-),男,硕士,主要研究方向为自适应信号处理;胡玉兰(1961-),女,硕士,教授,硕士研究生导师,主要研究方向为模式识别与图像处理、人工智能应用;袁德鹏(1992-),男,硕士,主要研究方向为图像识别;孙家民(1992-),男,硕士,主要研究方向为图像处理。

的挑战。

在计算机视觉领域,寻找好的特征来表达目标是一项非常重要的工作。以分类任务为例,如果原始数据信息能够被很好地用一个抽象特征来表达,那么通常一个线性模型就能获得满意的结果,因此许多算法的主要工作都应具有不变性(包括大小、尺度和旋转等)和可区分性,以往许多性能表现优异如SIFT的特征,都是由人工设计的^[1]。然而人工设计特征是一件非常费时费力的事情,不但需要相关领域的专业知识,而且在很大程度上也要依靠经验和运气才能选好^[2]。近年来,深度学习的发展为自主学习特征提供了可能,相比传统特征,通过深度学习获得的特征是一种高层次的深度抽象特征,利用这种深度特征,能够在图像识别等许多领域的问题求解上获得更好的效果。

卷积神经网络(convolutional neural network, CNN)是深度学习算法中非常重要的一类,它的网络结构更类似于生物神经网络,相对于其他目标识别算法的主要优势,是采用了局部感知域、权值共享和降采样这三种结构来实现对输入图像的局部平移不变性^[3]。通过神经网络中相邻层之间节点的局部连接行为来挖掘图像中目标的空间局部关联信息,这种稀疏连接的思想构建的局部感知域便是受到了人类视觉皮层中神经元只响应某些特定区域的刺激现象的启发。权值共享使卷积神经网络的特殊结构布局更接近于实际的生物神经网络,在有效降低了网络复杂性的同时避免了特征提取和分类过程中数据重建的复杂度^[4]。降采样操作降低输入图像的分辨率,模拟了初级视皮层中的复杂细胞,有效降低数据维度的同时也使得卷积神经网络对输入的局部变换具有一定的不变性。这种分层局部连接结构是非常强的先验结构,特别适合计算机视觉任务,如果整个网络的参数处于合适的区域,基于梯度的优化算法能得到很好的学习效果^[5]。

然而经典的卷积神经网络并没有很好的模拟大脑视觉皮层腹部通路中视觉信息的层次性处理过程进行模拟。为了提高卷积神经网络的识别率和效率,将卷积神经网络自身优势更有效的发挥,将结合生物视觉特点,以模拟人脑分层信息处理机制的卷积神经网络为框架,构建分层计算感知不变性特征和具有学习、识别能力的计算模型,提出增强层次的CNN框架目标识别算法,在同样目标条件

下进行分类识别,并与其他分类模型进行比较。

1 卷积神经网络模型

卷积神经网络沿用了经典的神经元网络,解决了传统多层感知器的全连接网络权值数量过多,梯度发散,训练难度大的缺点,这种分层的结构模型受到了著名的Hubel-Wiesel生物视觉模型的启发。经典卷积神经网络模型结构如图1所示。

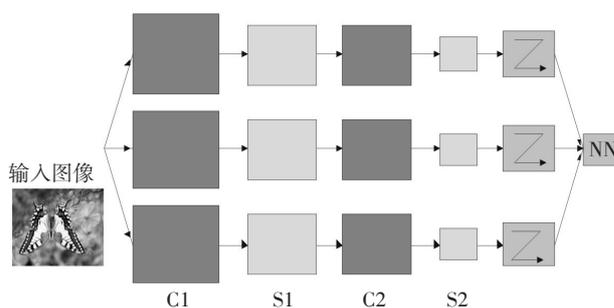


图1 经典神经网络的结构

输入图像需经过尺寸归一化,每一个神经元输入都来自上一层的某个局部邻域,再加上由一组权值决定的权重。提取的这些特征在下一层组合形成更高级的特征。同一个特征映射图的神经元共享同一组权值,再由降采样层对上一层进行平均。

卷积神经网络的训练分为两个阶段:

(1)向前传播阶段。从样本集中抽取一个样本 (X, Y_p) ,将 X 输入给网络,信息从输入层经过逐级变换传送到输出层,计算相应的实际输出,有下式

$$O_p = F_n(\dots(F_2(F_1(XW_1)W_2)\dots)W_n) \quad (1)$$

(2)向后传播阶段,也称为误差传播阶段。计算实际输出 O_p 与理想输出 Y_p 的差异为

$$E_p = \frac{1}{2} \sum_j (y_{pj} - o_{pj})^2 \quad (2)$$

并按最小化误差的方法调整权值矩阵。

一般地,C层为特征提取层,每个神经元的输入与前一层的局部感受区域相连,并提取该局部区域的特征,一旦该局部特征被提取后,它与其他特征间的位置关系也随之确定下来;S层是特征映射层,网络的每个计算层由多个特征映射组成,每个特征映射为一个平面,平面上所有神经元的权值相等。特征映射结构一般采用影响函数核小的sigmoid函数作为卷积网络的激活函数,使得特征映射具有位

移不变性。传统的神经网络里的全连接(full-connected)层,通过反向传播(back propagation, BP)算法更新相应的卷积核权重和偏置值。BP算法权重值的更新式为

$$W(t+1) = W(t) - \eta \delta(t)x(t) \quad (3)$$

式(3)中, $x(t)$ 表示该神经元的输出; $\delta(t)$ 表示该神经元的误差项; η 表示学习率。

2 基于视网膜模拟的多通道 Gabor 小波滤波器

在对人类视觉系统工作机理的研究中,人们发现,视觉系统把视网膜上的图像分解成许多滤波后的图像。每幅这样的图像得方向、频率的变化范围都很窄,也就是每一滤波后图像刻划了视网膜图像在一个窄的频带和方向范围内的成分,生物物理实验提供了这方面的证明。1958年,美国神经生物学家 David Hubel 和 Torsten Wiesel 记录了猫的视觉皮层中简单细胞对不同方向、频率正弦波的栅栏的响应,观察到每个细胞仅对很窄范围的频率、方向有响应,由此发现了一种被称为“方向选择性细胞(orientation selective cell)”的神经元细胞。证明在哺乳类动物的视觉皮层中呈现着一种机理,它把频率和方向结合到一起,调谐到一个很窄的区域,这种机理常称为通道,所用的多通道 Gabor 滤波器组就是受视觉系统工作机理的启发而提出的。

二维 Gabor 小波核函数表示如下

$$\psi_{\mu,\nu}(z) = \frac{\|k_{\mu,\nu}\|^2}{\sigma^2} e^{-\frac{|k_{\mu,\nu}|^2 |z|^2}{2\sigma^2}} \left[e^{j\beta_{\mu,\nu} z} - e^{-\frac{\sigma^2}{2}} \right] \quad (4)$$

其中, μ, ν 为 Gabor 核函数的方向和尺度;参数 σ 为高斯窗口的带宽和波向量长度的比例,小波向量 $k_{\mu,\nu}$ 函数如下

$$k_{\mu,\nu} = k_\nu e^{j\phi_\mu} \quad (5)$$

其中, k_{\max} 是最大采样频率; f 是采样步长,通常 $f = \sqrt{2}$ 。人类视皮层中简单细胞的感受野高度结构化的局限于非常小的空域范围内,图2为各参数设置下的多通道二维 Gabor 核函数实部的能量特征图。由图2可以看出,多通道的 Gabor 滤波器提供了具备良好的方向选择性和空间局部性,因此能够抓住图像局部范围内多方向局部性结构特征和空间频率。Gabor 特征对于图像边缘敏感的性质,能够

提供良好的尺度选择和方向选择特性,并且由于其对光照变化不敏感,还可以提供对光照变化优秀的适应性。因此不论从技术角度还是生物学角度分析,Gabor 特征都具有很好的优越性。

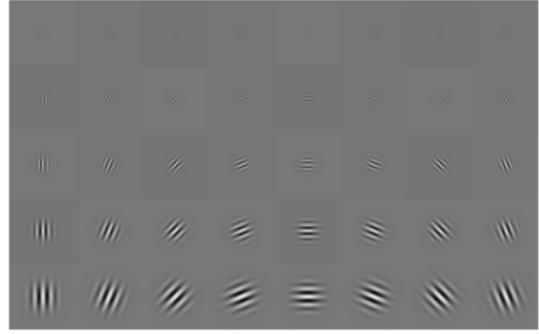


图2 各参数设置如下的多通道二维 Gabor 核函数实部的能量特征图: $\mu=8$, $\nu=5$, $\sigma=2\pi$, $k_{\max} = \frac{\pi}{2}$, $f = \sqrt{2}$

一般的,二维 Gabor 小波滤波器极坐标形式定义为

$$g(x,y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right] \exp\{j2\pi[\omega_r \cdot \cos(\theta - \phi)]\} \quad (6)$$

其中, σ 为高斯函数的标准差; ω_0 为复平面波的空间频率; $\phi = \arctan(\frac{\nu}{\mu})$ 是方向角; $r = \sqrt{x^2 + y^2}$; $\theta = \arctan(\frac{y}{x})$ 。极坐标形式表示的 Gabor 小波滤波器在空间域是一个复数,由实部和虚部构成,分别称为实 Gabor 小波滤波器和虚 Gabor 小波滤波器。

1981年, Pollen 等人调查了猫的视觉皮层中相邻细胞之间的相位关系,得出结论:一对相邻细胞(用频率相似来定义,比如,相似的幅度和相似的方向)具有一定的对称性。其中之一具有偶对称,另外一个为奇对称。这使得可以通过一个合成的函数来模拟这一对细胞的感受野。Gabor 函数的实部和虚部可以模拟奇、偶对称细胞的响应特征,其中实部对应于具有偶对称的细胞,虚部对应于具有奇对称的细胞。其输出能量表征了细胞的方向选择性。由此构建的多通道的 Gabor 滤波器组模拟视网膜简单细胞视觉刺激响应对输入图像的方向尺度特征进行提取,得到的特征映射图如图3所示。与经典卷积神经网络第一层卷积层输出的特征映射

图进行对比发现,Gabor滤波器组具备多分辨率特性,该特性可以模拟视角膜和晶状体的变焦能力,可以根据需要在不同粗细粒度上分析图像,并且在提供空间局部性特征的同时提供了方向选择性特征。与其他特征提取方法相比:一方面其处理的数据量较少,能满足系统的实时性要求;另一方面,小波变换对光照变化不敏感,且能容忍一定程度的图像旋转和变形,故能提高系统的鲁棒性。因此采用Gabor小波构建多通道滤波器组模拟视网膜的简单细胞视觉刺激响应,替代传统卷积神经网络的第一层卷积层,并对目标物体的特征进一步提取。

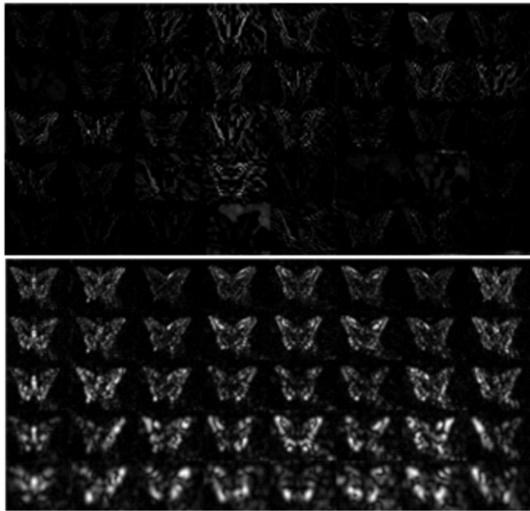


图3 上图为经典卷积神经网络第一层卷积层输出的特征映射图,下图为多尺度Gabor滤波器组对目标滤波后的特征映射图。

3 基于视觉神经层次改进的CNN框架

3.1 基于随机策略的池化层的构建

传统的池化策略如均值池化和最大值池化,它们的池化策略都是恒定的。均值池化的优点在于可以减小由池化区域受限所造成的估计值方差增大,可以更多地保留图像背景信息,然而却未考虑到负激活项和正激活项之间的影响。最大值池化的优势在于它可以减少卷积层参数误差造成的估计均值偏移,更多地保留细节特征,但却很容易在训练集上产生过拟合。随机池化(stochastic pooling)方法很好的解决了这些问题,它在每个池化区域内按概率的选取激活项,公式表达如下

$$p_i = \frac{a_i}{\sum_{k \in R_j} a_k} \quad (7)$$

其中, p_i 为多项式分布位置采样概率; a_i 为 i 位置的激活值; R_j 是特征映射图第 j 个池化区域。随机池化介于最大值池化和均值池化之间,相当于在池化区域上进行不同的形变再进行最大池化操作,在平均意义上,同均值池化类似;在局部区域中,服从最大池化策略。如图4所示。

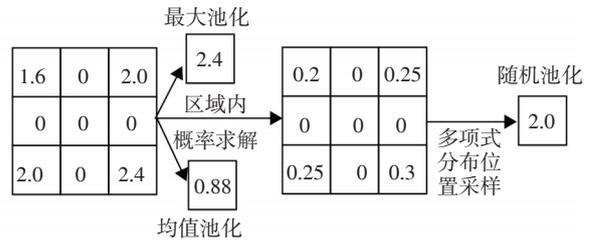


图4 区域内最大池化,均值池化和随机池化,随机池化根据区域内概率的多项式分布随机选取了位置3上的值

基于随机池化策略构建随机池化层,替代传统池化层,在保留最大池化优势的基础上添加随机特性,可以更好地防止模型训练时出现过拟合。

3.2 基于视觉感知侧抑制的归一化层的构建

侧抑制机制是生物视觉神经网络神经元间特有的一种信息筛选机制,这种机制是普遍存在于视觉系统多层次中的一种神经交互作用,从视网膜神经节细胞、LGN主细胞、一直延续到VI区的锥体细胞。这种机制在参与初级视觉感知的同时还参与类似注意机制的高层作用。由于传统CNN模型缺少对侧抑制现象的模拟,将引入基于视觉感知侧抑制机制的局部响应值归一化层(local response normalization, LRN),用 $a_{x,y}^i$ 表示点 (x,y) 处的神经元活跃程度,则归一化活性 $\beta_{x,y}^i$ 的公式表达如下

$$b_{x,y}^i = \frac{a_{x,y}^i}{\left(k + \alpha \sum_{j=\max(0,i-n/2)}^{\min(N-1,i+n/2)} (a_{x,y}^j)^2 \right)^\beta} \quad (8)$$

其中, a 为每个神经元的激活值; b 为归一化权重生成的新的激活值; n 为求和覆盖的相邻的位于相同空间位置的核映射数量; N 是该层中的核总数。常数 k, n, α 和 β 为需要在验证集上选择最优值的超参数,选取 $n=5, k=2, \alpha=10-4$ 和 $\beta=0.75$ 。

基于视觉感知侧抑制机制构建具有对比度增强及响应输出归一化的特性的LRN层,并部署于每个随机池化层之后,通过对输入特征数据的局部归一化操作将局部化的输入分散到更大范围的输出神经元中,抑制激励量并调整感知信息编码,以此将映射特征显著化,提高CNN模型泛化能力。

3.3 加入随机Dropout方法的全连接层的构建

当视觉系统接收一幅图像时,只有较少的神经元具有较强响应。大部分神经元则处于弱激活或零激活状。由这种神经元稀疏的响应状态产生了神经系统对视觉刺激的编码过程。实验研究表明,自然场景的高阶统计特性是服从超高斯分布的,由于自然图像与生物所处的外界视觉环境有着相同的统计结构,因而其分布特性与神经元对视觉刺激的稀疏编码响应具有高度一致性。

Dropout方法是有效提升神经网络全连接层泛化能力的学习方法。Dropout在网络训练过程中随机将部分神经元的取值保留下来,并将这些神经元的输出设定为0,在下一次训练过程中再将之前保留下的取值恢复,并再次随机选择部分神经元进行取值保留的动作,如此循环,以保证减弱神经元节点间的联合适应性,增强了泛化能力。当应用Dropout以后,神经网络根据概率 P 来表示每个神经元的激活概率,通常 $P \in [0.5, 1.0]$,这样的设定有效避免了网络对某一局部特征的过拟合。因此神经网络的前向传播过程如图5所示。

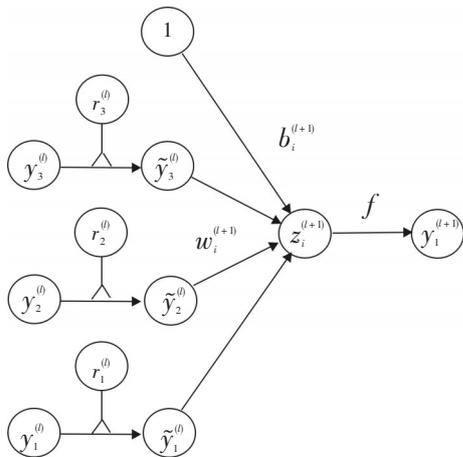


图5 Dropout单元的前向传播过程模型

$$r_j^{(l)} \sim \text{Bernoulli}(p) \tag{9}$$

$$\tilde{y}^{(l+1)} = r^{(l)} * y^{(l)} \tag{10}$$

$$Z_i^{(l+1)} = w_i^{(l+1)} y + b_i^{(l+1)} \tag{11}$$

$$y_i^{(l+1)} = f(z_i^{(l+1)}) \tag{12}$$

其中, $*$ 表示按元素点乘;对于任意隐藏层, $r^{(l)}$ 是一个向量,它的每个元素都服从伯努利随机分布,并依概率 P 取值1。使用该向量对上一层网络的输出 $y^{(l)}$ 进行采样,产生一个约减的输出 $\tilde{y}^{(l)}$ 用于下一次网络的输入。这样依次进行操作,从而从原网络中生成一个子网络。

Dropout是在训练过程中以固定概率将隐含层节点的输出值置为0,并且更新权值时,不再更新与该节点相连的权值,其公式描述如下

$$r = m * a(Wv) \tag{13}$$

其中, v 是输出的提取特征; W 是完全连接的权重矩阵; m 是二进制掩码矩阵; $a(x)$ 是一个满足 $a(0)=0$ 形式的非线性激活函数; r 是输出向量。 $m * a(x)$ 是矩阵对应元素相乘。图6所示为Dropout单元模型。

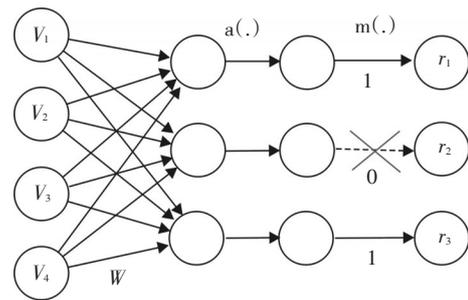


图6 Dropout单元模型

上述的Dropout方法中,通常设定概率值为0.5,即设定输出为0的神经元比例在每次网络更新时是恒定的,并在构建网络模型时进行定义。根据生物细胞是否发射信号与其自身存在的电势有关的特性,提出随机Dropout的方法,即生成随机权重的二进制掩码矩阵 m ,由此得到的模型平均数量为 $(1/\xi)^{|M|}$,相比于Dropout方法具有更强的模型平均能力。将设定输出为0的神经元比例在每次网络更新时都进行随机变化,通过随机具有稀疏性约束的非负稀疏编码,学习复杂细胞的感受野特性,从而使

网络神经元连接次序更多样化,进一步提高网络模型的泛化能力,更好的描述目标在场景中的各种变换。

4 基于视觉神经层次结构的IH-CNN框架

基于上述随机池化层和局部响应值归一化层的构建,结合CNN的层次结构,仿照基于视觉信息处理系统的三级分析模型:(1)低级视觉,从二维图像阵列中获得最基本的图像特征;(2)中级视觉,逐层抽取细节特征;(3)高级视觉,该层根据前面分析所得的结果,结合当前所掌握的领域知识,对图像中的景物进行识别并对其内容作为决策,提出基于视觉神经层次结构的增强层次CNN(IH-CNN)框架如图7所示。

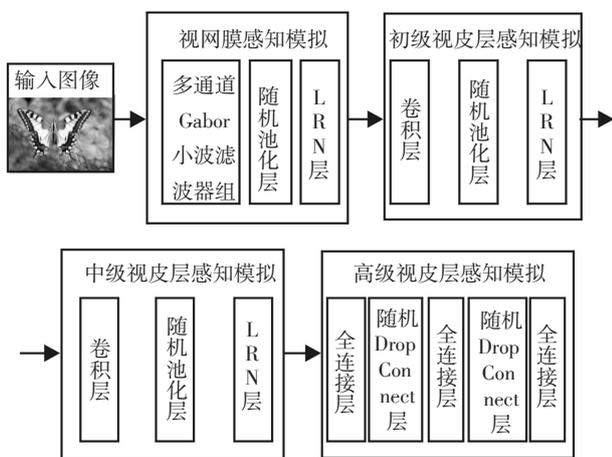


图7 基于视觉神经层次结构的AH-CNN框架

该模型采用卷积两个卷积层、两个随机池化层和两个LRN层交替组成视觉神经系统的初、中级层次结构,并采用全连接层和分类器模拟视觉神经系统的高级层次结构对目标图像进行决策识别。

5 实验结果与分析

为了验证文中提出的分层计算感知模拟算法的有效性,将在Caltech-101数据集上测试其分类准确率,并与其他同类方法进行比较。Caltech-101数据集是由加州理工学院Feifei Li等,于2011年整理而成。该数据集有101个目标类和1个背景类,共102个类别,9 145幅图像。这101个目标类中包含了人脸、建筑、图标、动物、植物以及符号等图像,这

些图像有不同的尺度,匹配空间金字塔池化层的特点,具有一定代表性。如图8所示。

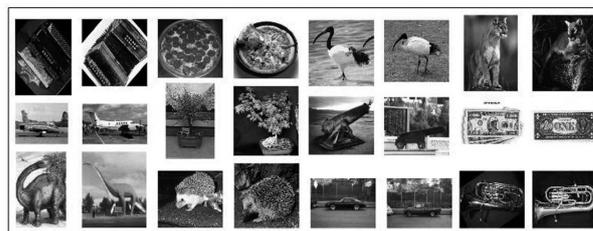


图8 Caltech-101数据集

卷积神经网络模型在大数据集上的训练比较耗时耗资源,为了减少训练开销,采用基于C++/CUDA编写的深度学习框架Caffe对HCPM算法进行开发和训练。由于卷积神经网络本身的特性,需要用GPU加速运算以缩短算法训练的时间,Caffe提供CPU和GPU间的无缝切换,是目前训练速度最快的开源CNN框架。本算法运行环境为Intel i7-3630QM CPU@2.40GHz×8、NVIDIA GeForce GT 750m GPU,在每目标类中随机选择30幅训练样本和30幅测试样本,再给出平均的分类精度,即被正确分类的样本数与全部样本数之比,一共重复10次实验,得到损失函数和准确率曲线如图9所示。

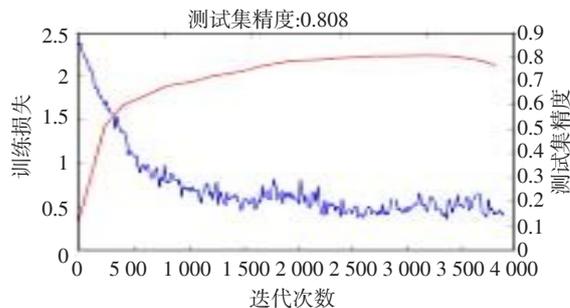


图9 基于Caltech-101数据集的损失函数和分类精度曲线

图10列出了当前各主要CNN模型在Caltech-101上的平均分类识别精度,各模型结果均由文中实验获得,重复实验五次,结果取均值。由图10可以看出,IH-CNN模型的分类识别精度较其他模型有更好的表现,在Alex-Net的基础上提高了5.5%,识别精度达到了80.8%,比GoogLeNet高出1.8%;比VGG16模型提高了1.1%;与SPP-Net模型尚有些许差距,但收敛速度更快。

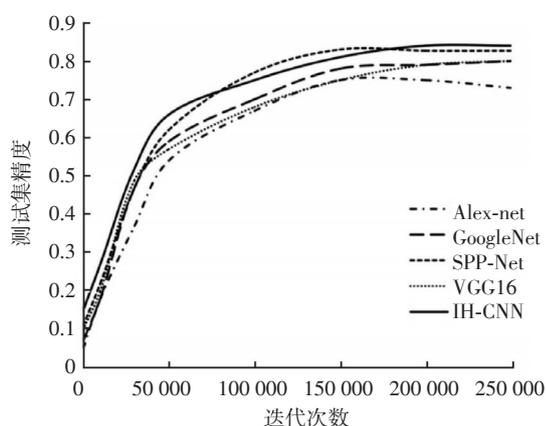


图10 各主流模型基于 Caltech-101 数据集的准确率曲线

6 结论

引入的分层计算感知模拟系统的网络结构是将在生物视觉领域所取得的研究进展与计算机视觉应用结合起来,基于生物理论和模型提出的新的目标识别模型。该模型能够有效的提高图像目标

识别的准确度,对比以往的经典卷积神经网络,不仅在算法的效果上有所提高,而且训练的参数有所减少,训练所需的时间也更短。虽然距离世界先进算法的水平还有差距,但本结构的准确度比传统的目标识别算法依旧高出许多。

参考文献

- [1] Cun Y Le, Boser B, Denker J S, et al. Back propagation applied to handwritten zip code recognition[J]. Neural Computation, 1989.
- [2] Deng J, Dong W, Socher R, et al. Image net: A large-scale hierarchical image database[J]. CVPR, 2009.
- [3] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks[J]. NIPS, 2012.
- [4] Zeiler M D, Fergus R. Visualizing and understanding convolutional neural networks[J]. ArXiv, 2013:1311, 2901.
- [5] Sermane P, Eigen D, Zhang X, et al. Overfeat: integrated recognition, localization and detection using convolutional networks[J]. ArXiv, 2013:1312, 6229.

(上接第14页)

- [2] Brusgard, Thomas C. Distributed aperture infrared sensor systems[J]. SPIE, 1999: 3436.
- [3] Yves Klein. ARTEMIS: First naval staring IRST in service.
- [4] Nougues. Third-generation naval IRST using the step-and-stare architecture[J]. SPIE Defense & Security, 2008.
- [5] Michael Engel, Amir Navot. Sea spotter-a fully staring naval IRST system[J]. SPIE 2013.
- [6] Dominique M, Olivier D, Guillaume V, et al. New generation of Naval IRST: example of EOMS NG[J]. SPIE 2010 (7660).
- [7] 翟尚礼, 孙宁, 王文胜. 地基红外搜索跟踪系统设计与实现[J]. 指挥信息系统与技术, 2011, 2(4): 17-21.
- [8] Grollet, C. ARTEMIS staring IRST for the FREMM frigate [J]. SPIE, 2007, 6542.
- [9] 白学福, 梁永辉, 江文杰. 红外搜索跟踪系统的关键技术和发展前景[J]. 国防科技, 2007(1): 34-36.
- [10] Quaranta C, Balzarotti G. Probabilistic data association applications to data fusion[J]. Optical Engineering, 2008 (2).
- [11] Buss J R. Staring infrared panoramic sensor (SIRPS). SPIE, 1998, 743:3436.
- [12] Mark Everett. A naval infrared search and track demonstrator and its fusion with other ship sensors[J]. SPIE, 2006, 6206:620626.
- [13] Rioland J. Disposition de veille optronique sectorielle ou panorama a grand witnesses sans movement apparent. 0115534[P]. 2001.
- [14] Guzzetti L E, Busnelli L. EF2000 PIRATE test flights campaign[J]. SPIE, 2008:7109.
- [15] Ceglie de S U, Moro M Lo. A bispectral panoramic IRST-results from measurement campaigns with the Italian navy[J]. SPIE, 2010:7660.
- [16] Pozzi A, Ondini A, Casagrande G. Fully automated IR target search and recognition processor[J]. Proc OPTRO, 2016.