

稀疏自动编码器视觉特征融合的多弹分类算法研究

陈宇,温欣玲,刘兆瑜,马鹏阁

(郑州航空工业管理学院 电子通信工程学院,河南 郑州 450015)

摘要: 准确识别卫星设备等拍摄到的待发射(或飞行途中)导弹类型,实现及时有效防御,是国内外军事领域研究的热点之一。由于战争状态中导弹具有掩饰色,且因外形差别不显著,现有基于底层特征进行导弹分类识别难度较大甚至无法识别。针对这一问题,提出一种基于稀疏自动编码器(Sparse Auto-Encoder, SAE)高层视觉特征融合底层特征提取的新算法,为了提高分类精度,引入迁移学习,借助 STL-10 样本库局部特征,并将导弹图像局部特征向量一并送入池化层卷积神经网络(Convolution Neural Network, CNN)提取导弹目标对象图像全局特征,通过 Softmax 回归模型实现导弹分类识别。实验表明,文中提出 SAE 融合底层特征的导弹分类识别算法较传统基于底层特征及 SAE 高层特征分类算法具有更高的准确性及鲁棒性。另外,为了避免因新型导弹目标对象缺乏训练而导致分类性能下降甚至失效,算法引入迁移学习实现局部特征提取,实验验证了算法的可行性和准确性。

关键词: 导弹分类识别; 稀疏自动编码器; 视觉特征; 特征融合

中图分类号: TP391.4 文献标志码: A DOI: 10.3788/IRLA201847.0826004

Research of multi-missile classification algorithm based on sparse auto-encoder visual feature fusion

Chen Yu, Wen Xinling, Liu Zhaoyu, Ma Pengge

(College of Electronic and Communications Engineering, Zhengzhou University of Aeronautics, Zhengzhou 450015, China)

Abstract: Accurate classification of missile by the missile image (or in flight state) taken through the satellite equipment, which achieve the timely and effective defense, is one of the hot spot in the military field at home and abroad. Because the missile in the war state has masked color, and the missile shape differences are not significant, it is difficult to classify the missile type based on the low level features. Aiming at these problems, a new algorithm was presented based on Sparse Auto-Encoder (SAE) combining the high level visual feature and low level feature extraction. In order to improve classification accuracy, transfer learning was introduced, with the help of the STL-10 sample database local features, the global features of small sample missile target image can be extracted through the local features by the convolution neural network (CNN) of pooling layer, and then transmitted into the Softmax regression model to realize classification of missiles. Experiments show that compared with the traditional low level vision features and SAE high level vision feature classification algorithm, the SAE fusion feature classification algorithm has higher accuracy and robustness. In addition, in order to avoid classification

收稿日期: 2018-03-07; 修订日期: 2018-04-05

基金项目: 航空科学基金重点实验室项目(20170155001); 河南省高等学校重点科研项目(18A510018); 河南省高校科技创新团队支持计划项目(17IRTSTHN014); 河南省科技厅科技攻关项目(182102210110, 182102210111)

作者简介: 陈宇(1978-), 男, 副教授, 博士, 主要从事数据采集与信号处理方面的研究与教学。Email: chenyu@zua.edu.cn

performance reduce even failure under the lack of training for new type missile target object, the new algorithm induces transfer learning to extract local feature, experimental result proves the feasibility and accuracy of the algorithm.

Key words: classification of missiles; sparse automatic-encoder; visual features; feature fusion

0 引言

现代战争中,导弹的有效命中目标以及导弹有效防御对作战双方取得战争的胜利起到了至关重要的作用。各国都在积极发展导弹防御系统来积极应对敌方导弹的威胁,如何在导弹发射前或者导弹飞行途中尽早地发现及识别导弹类型,对主动防御中选择反导拦截系统起到了积极的辅助作用。但是,由于卫星拍摄导弹因天气因素、导弹掩饰色等多种因素的影响,往往难以对导弹的型号及类型进行及时、准确的获取,这将在一定程度上影响我方的战略部署和攻击手段。如何对导弹目标图像进行有效的识别^[1]和分类,是对导弹防御及战略部署等任务顺利实施的关键。

基于内容的图像检索是从目标图像中找出与检索内容相同(或相近)的图像。该技术利用从图像中抽取的颜色^[2]、纹理、外形等底层特征^[3],通过一定方法在数据特征库中进行比较,分类出不同的目标图像^[4]。对目标图像进行识别分类最关键之处在于对图像中的目标对象进行特征的准确提取。目前,常用的特征提取算法以统计学特征提取为主,如:基于时域的局部二元模式(Local Binary Patterns, LBP)、基于频域的通用搜索树(Generalized Search Trees, GIST)、傅里叶变换^[5]、小波变换^[6]等特征提取的方法。然而,这些特征提取方法需要建立复杂的特征模型来提取图像颜色、纹理、形状等底层视觉特征,仅仅能够表达出图像的局部表层信息,局限性较大,很难全面表达图像全局细节信息,在复杂环境下传统底层特征提取的分类算法准确性不高。

卷积神经网络(Convolutional Neural Networks, CNN)^[7]是一种有监督学习结构,CNN在各行各业多个领域有了广泛的应用结果,但是,由于该方法存在一定的局限性,当训练样本数不足时性能下降明显,其性能的好坏与有标记训练样本数目的取值有较直接的关系。近年来,对大数据的无监督特征学

习已逐步成为国内外专家学者研究的热点和重点问题^[8],该方法通过对大数据集借助一种模拟人眼感知的方法,对图像内部的本质信息进行学习,通过对数据集中的样本图像展开逐层特征变换,可将样本原空间特征表示映射到新特征空间上,从而实现图像中的高层特征学习,提高在目标对象图像中的识别和分类精度。稀疏自动编码器(Sparse Auto-Encoder, SAE)^[9]作为一种无监督的特征学习方法,通过对无标记样本数据的自我复原训练,提取图像中目标对象特征的方法被有效地推广到目标对象样本数据有限的应用场合中^[10],SAE模型无需事先定义特征^[11],通过设置隐层单元数目便能够自动学习图像中目标对象的隐层数据,从而获得数据内部的本质关联。

因此,文中提出一种基于SAE高层特征提取融合底层传统视觉特征获取图像特征的方法,实现图像局部特征提取,然后通过CNN^[12]获取导弹目标对象小样本图像的全局特征,借助Softmax归一化分类模型对导弹类型进行分类识别。由于实际战场环境下的导弹掩饰色等造成训练数据集数量较少,文中借助跨领域迁移学习方法完成局部特征提取。实验验证了文中提出算法能够较好地分类多类型导弹,实验比较验证了迁移学习较非迁移学习在小样本导弹目标对象中的导弹类型分类性能差异。

1 算法原理

文中提出算法包含4个模块:底层视觉特征提取、SAE全局特征特征提取、CNN神经网络全局特征获取以及分类识别模块等。首先,利用SAE学习导弹目标对象小样本图像中的隐含特征,结合传统底层视觉特征(颜色直方图、LBP、GIST等)对图像进行局部特征提取;然后,将局部特征送入CNN,通过连续的卷积、池化实现对目标对象的全局特征提取;最后,将全局特征送入Softmax分类器完成对图像中导弹目标对象的分类识别。算法设计框图如图1所示。

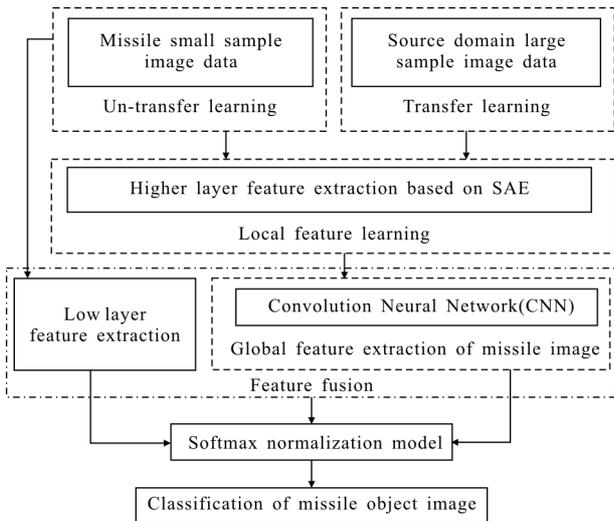


图 1 算法设计框图

Fig.1 Algorithm design frame

如图 1 所示,传统算法通过对样本图像的三大底层特征(颜色、纹理、形状)进行提取,然后将目标图像送入分类器进行分类识别;文中提出基于 SAE 对导弹图像进行高层特征提取,SAE 高层特征提取模块基于无监督学习,借助反向传播对 AE 神经网络进行训练,通过对神经网络的隐藏层加入稀疏性约束,实现训练集中代表性图像子块的局部特征学习,通过白化处理可强化图像边缘,从而实现视觉特征性能提高;利用 CNN 将学习到的局部特征在导弹目标图像上进行逐点卷积,从而获取导弹目标图像的全局特征,CNN 池化操作可得到旋转和缩放不变的全局特征向量;最后,将全局特征送入 Softmax 分类器实现对目标图像中导弹类型的分类识别。文中提出迁移学习方法,以减少因小样本目标图像数量过少而导致局部特征向量学习不充分的不足。仿真实验中,通过对目标图像划分训练集和测试集,交叉验证文中提出新算法的有效性和准确性。

2 算法设计

2.1 底层视觉特征提取

2.1.1 颜色直方图

颜色直方图是描述图像中最常用的特征之一,其主要用来描述图像中的颜色全局性分布,以及不同颜色在图像中所占比例。该方法具有运算速度快、算法简单,且具有尺度、平移和旋转不变性等优点。颜色直方图通常可采用一维向量进行表示,如公式(1)

所示。

$$H_p=[h_1, h_2, \dots, h_k, \dots, h_L], h_k=\frac{n_k}{N}, k=0, 1, \dots, L-1 \quad (1)$$

式中: h_k 表示第 k 种像素在图像中出现的频数; L 为颜色级数目; n_k 为各颜色级像素数; N 为像素总数。颜色直方图只统计图像的全局颜色信息,缺少图像的空间分布信息,不同图像可能有相同颜色直方图。因此,识别率易产生误差;另外,当颜色直方图中零点较多时,将影响直方图相交运算结果,从而导致计算结果将不能准确反映各图像间颜色差异。因此,文中采用累计颜色直方图方法解决该不足,如公式(2)所示。

$$h'_k = \frac{\sum_{i=0}^k n_i}{N}, k=0, 1, \dots, L-1 \quad (2)$$

式中: h'_k 表示 k 种颜色像素的累加频数。

2.1.2 LBP 特征提取

LBP 特征主要描述图像局部邻域的纹理特征,可借助统计学方法提取图像中目标对象的全局纹理特征。LBP 特征提取计算复杂度低,具有多尺度及旋转不变性。LBP 特征提取中,首先对目标对象中心像素灰度值与相邻的像素灰度值进行比较,从而得到邻域像素二进制编码,如过邻域像素灰度值大于中心像素灰度值时,该像素点的二进制编码设置为 1;否则设置为 0;可将得到的二进制数顺时针连接构成新的中心像素;最后,将每个二进制数加权得到中心像素局部二元模式即为其 LBP 特征值。LBP 特征如公式(3)所示。

$$LBP_{P,R} = \sum_{k=0}^{P-1} S(g_k - g_c) 2^k \quad (3)$$

式中: $S(x)=1(x>0)$,否则 $S(x)=0$; g_c 为中心像素灰度值; g_k 为邻域像素灰度值; P 为邻域中元素的个数; R 为邻域半径; 2^k 为每个二进制数分配的权重因子。由于 LBP 特征仅包含两个从 0~1 或者从 1~0 的跳变,文中对局部二进制模式对应的循环二进制数跳变次数不超过 2 次看作一个统一模式类。统一模式类下的 LBP 特征定义式如公式(4)所示。

$$LBP_{P,R}^{U2}(g_c) = \begin{cases} \sum_{k=0}^{P-1} S(g_k - g_c), & \text{如果 } LBP_{P,R}(g_c) \leq 2 \\ P+1, & \text{否则} \end{cases} \quad (4)$$

式中: $LBP_{P,R}^{U2}(g_c)$ 表示跳变次数。当 $LBP_{P,R} \leq 2$ 时为统一模式。使用二进制模式中 1 出现的次数作为中心

像素 LBP 值, 否则使用 P+1 作为中心像素值。文中采用旋转不变性统一模式 LBP 对导弹目标对象纹理进行特征提取。

2.1.3 GIST 特征提取

GIST 特征提取算法使用不同尺度、不同方向的 Gabor 滤波器对图像中的目标对象进行滤波; 然后, 将滤波后图像进行网格划分, 每个网格内部取平均值后得到目标对象局部纹理特征; 最后, 将所有网格内部的均值进行级联, 形成图像中目标对象的全局纹理特征。

由于多尺度下的 Gabor 滤波器能够捕捉图像中不同空间频率、位置及方向上的局部信息, 这些信息具有旋转不变性, 且对亮度变化不敏感, 被广泛应用到目标图像全局轮廓提取中。GIST 特征提取首先使用 n_c 个通道的滤波器对 $h \times w$ 灰度图像 $f(x, y)$ 进行卷积滤波, n_c 为滤波器尺度与方向数乘积, 由此可以得到 n_c 个滤波后图像; 然后, 将每幅滤波后的图像划分为 $n \times n$ 个区域, 对每个区域去平均得到该区域的局部特征; 最后, 将每个区域内的局部特征级联得到图像中目标对象的全局轮廓特征。如公式(5)所示。

$$G_i(x, y) = \text{cat}(f(x, y) * g_{m_i}(x, y)) \quad (5)$$

式中: cat 代表级联符号; $g_{m_i}(x, y)$ 为滤波器组; “*” 代表卷积运算符。文中采用 8 方向和 4 尺度滤波器组, 通过对图像目标对象进行卷积滤波, 采用 8×8 网格对所得图像进行划分, 每幅图像全局轮廓特征描述向量维数为 $8 \times 8 \times 4 \times 8$ 维。该特征向量既表征图像中目标对象的全局轮廓特征, 也描述了局部轮廓特征关系。

2.2 SAE 局部特征学习

SAE 是对自动编码器中各隐层单元响应加入稀疏约束的改进形式。首先使网络中大多数神经元处于抑制状态; 然后通过反向传播(BP)训练方法找到最小代价函数, 学习目标对象图像中的关键特征。文中提出采用零相位成分分析方法对 SAE 算法学习到的多个图像子块采取白化处理。假设采集到第 i 个图像块大小 $n \times n$, 按照 RGB 分量排序可以得到 $m = n \times n \times 3$ 维向量 $x^{(i)}$ 。对其进行白化处理, 得到输入向量 $x^{(i)} = W_{\text{white}}^{(i)}$ 。其中, W_{white} 为 $m \times m$ 维白化变换系数矩阵。

SAE 第 s 维隐层响应向量如公式(6)所示。

$$a^{(i)} = \sigma(W_x^{(i)} + b_1) = \sigma(W_{\text{SAE}} W_{\text{white}} x^{(i)} + b_1) \quad (6)$$

式中: W_{SAE} 为连接 SAE 隐藏层和白化处理后各图像块的输入权重系数; b_1 为输入偏置系数; $\sigma(\cdot)$ 表示激

活函数; $W_{\text{SAE}} W_{\text{white}}$ 为隐藏层与原始数据间映射关系的整体权重系数。白化处理后因输入数值可能超出 $[0, 1]$ 范围。因此, 数据重建过程中不利用激活函数 $\sigma(\cdot)$ 对 SAE 输出进行映射。

$$\hat{x}^{(i)} = W_{\text{SAE}}^T a^{(i)} + b_2 \quad (7)$$

式中: $\hat{x}^{(i)}$ 为第 i 个复原样本; W_{SAE}^T 为输出权重; b_2 为输出偏置。为了保持隐层响应稀疏性, 防止过度拟合现象发生, 文中对代价函数加入权重衰减项系数以及稀疏性惩罚项系数, 代价函数表示式如公式(8)所示。

$$J_{\text{SAE}}(W_{\text{SAE}}, b) = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} \|\hat{x}^{(i)} - W_{\text{white}} x^{(i)}\|^2 + \lambda \|W_{\text{SAE}}\|^2 + \beta \sum_{j=1}^s \left(\rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{\rho - \hat{\rho}_j}{1 - \hat{\rho}_j} \right) \quad (8)$$

式中: N 为无标记的训练图像样本数; λ 为权重衰减系数; β 为稀疏惩罚权重; s 为隐层单元数; ρ 表示目标稀疏值; $\hat{\rho}_j$ 表示所有训练样本在第 j 个隐层单元上的平均响应。在进行 SAE 高层特性学习后可得 W_{SAE} , 由 W_{SAE} 可在各图像块上得到局部特征响应, 如公式(9)所示。

$$a_T = \sigma(W_s x_T + b_{1s}) \quad (9)$$

式中: W_s 为白化处理后局部特征整体权重; b_{1s} 为输入偏置; x_T 为目标对象图像块。为了提高导弹目标对象的类型识别, 文中提出采用迁移学习时借用与导弹目标图像数据不相关的无标记数据集 STL-10^[13] 进行局部特征学习, 借助卷积 SAE 网络实现全局特征提取。

2.3 CNN 全局特征提取

基于 SAE 从导弹目标图像样本数据库中学习 $n \times n$ 大小的图像子块局部特征, 由于导弹图像样本数据过少, 文中引入迁移学习思想, 从其他源领域大样本图像数据集中学习各图像子块的局部特征。然后, 在导弹目标对象图像上卷积操作可得图像特征响应, 由此组合出导弹目标对象图像全局特征向量, 用于对当前待识别导弹类型图像中的导弹分类。CNN 全局特征模型结构^[14]如图 2 所示。

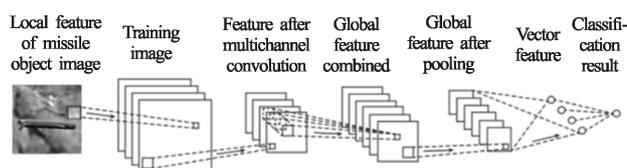


图 2 CNN 模型结构图

Fig.2 CNN model structure frame

2.3.1 卷积层

如图 3 所示, 假设 SAE 高层特征提取过程中, 在 $n \times n$ 大小的图像子块中学习 K 个局部特征 (K 表示 SAE 隐层单元数), 则将这些局部特征与 $l \times l$ 大小的导弹对象图像中各像素点卷积后, 可得 K 个 $(l-n+1) \times (l-n+1)$ 大小的全局特征图案。为了提高 RGB 空间局部特征提取效率, 文中在全局特征获取前借助 SAE 学习各局部特征权重, 并且拆分为 3 个色彩通道, 将其与 $l \times l$ 大小的导弹图像 R、G、B 分量分别逐点卷积得到 3 个 $(l-n+1) \times (l-n+1)$ 大小的全局特征向量; 对各分量全局特征向量求和, 得到各导弹图像全局特征向量。如公式(10)所示。

$$a = f(WW_{ZW}^{RGB} x' + b) \quad (10)$$

式中: W 和 b 分别为算法学习到的局部特征系数; x' 为训练样本中待卷积的子区域个数; W_{ZW}^{RGB} 为白化系数。

2.3.2 池化层

由于各图像具有独立静态属性, 故不同区域的有用特征极有可能相互适用。基于该思想, 对卷积层提取出的不同区域特征进行聚合统计, 去除冗余特征, 即池化操作。通常, 池化方式主要包括: 平均池化、求和池化、最大值池化以及 l_p 范数池化。文中卷积 SAE 结构中采用白化预处理, 适宜采用平均池化, 如公式(11)所示。

$$s_j = \frac{1}{|R_j|} \sum_{i \in R_j} a_i \quad (11)$$

文中选择平均池化作为池化方式, 将前一层特征某个区域平均值作为该区域的统计表示, 通过降维、防过拟合方法, 确保聚合特征在空间上具有缩放不变性以及旋转不变性等优点。

2.3.3 Softmax 分类器

为使输出层得出导弹分类结果, 文中在 CNN 网络中加入 Softmax 分类器^[19], 对于训练集 $\{(x^{(0)}, y^{(0)}), \dots, (x^{(i)}, y^{(i)}), \dots, (x^{(m)}, y^{(m)})\}$ 中, $y^{(i)} \in \{1, 2, \dots, k\}$, k 表示待分类的导弹类型数, Softmax 分类器使用假设函数 $h_\theta(x)$ 对输入样本进行分类概率计算, $h_\theta(x)$ 如公式(12)所示。

$$h_\theta(x^{(i)}) = \begin{bmatrix} p(y^{(i)}=1|x^{(i)}; \theta) \\ p(y^{(i)}=2|x^{(i)}; \theta) \\ \vdots \\ p(y^{(i)}=k|x^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \vdots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix} \quad (12)$$

式中: $p(y^{(i)}=j|x^{(i)})$ 表示第 i 个样本的输入 $x^{(i)}$ 属于类别 j 的概率; θ 表示模型参数, 通过 $1/\sum_{j=1}^k e^{\theta_j^T x^{(i)}}$ 对概率分布进行归一化。此时, 系统代价函数如公式(13)所示。

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)}=j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \right] \quad (13)$$

式中: $1\{\cdot\}$ 为指示性函数, 即 $1\{\text{值为真的表达式}\} = 1, 1\{\text{值为假的表达式}\} = 0$ 。而对 $J(\theta)$ 的最小化问题, 文中采用梯度下降法迭代求解, 保证收敛到全局最优解。梯度参数如公式(14)所示。

$$\nabla_{\theta} J(\theta) = -\frac{1}{m} \sum_{i=1}^m [x^{(i)}(1\{y^{(i)}=j\} - p(y^{(i)}=j|x^{(i)}; \theta))] \quad (14)$$

将 $\nabla_{\theta} J(\theta)$ 代入梯度下降法更新参数, 为了确保唯一解, 添加权重衰减项修改代价函数, 使代价函数变为严格的凸函数, 防止网络训练过程中参数值过大, 代价函数如公式(15)所示。

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)}=j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^k \sum_{j=0}^n \theta_{ij}^2 \quad (15)$$

通过最小化 $J(\theta)$ 训练 Softmax 分类器可得到一个可用的回归模型。加入衰减项 $\lambda \theta_j$ 后, 梯度如公式(16)所示。

$$\nabla_{\theta} J(\theta) = -\frac{1}{m} \sum_{i=1}^m [x^{(i)}(1\{y^{(i)}=j\} - p(y^{(i)}=j|x^{(i)}; \theta))] + \lambda \theta_j \quad (16)$$

3 实验验证

为了验证文中提出算法的有效性及其准确性, 将传统基于底层视觉特征 (颜色直方图、LBP 特征、GIST 特征) 分类算法与文中提出的新算法应用在导弹目标对象分类识别中。仿真实验中, 采用导弹图像样本为卫星拍摄的美国阿姆拉姆、中国红箭及红鸟小样本导弹图像, 并将该图像样本作为算法交叉验证中的目标图像。3 类图像各 100 幅, 尺寸为 64×64 , 3 类导弹图像的部分样本如图 3 所示。



(a) 阿姆拉姆

(a) Missile of AMRAAM

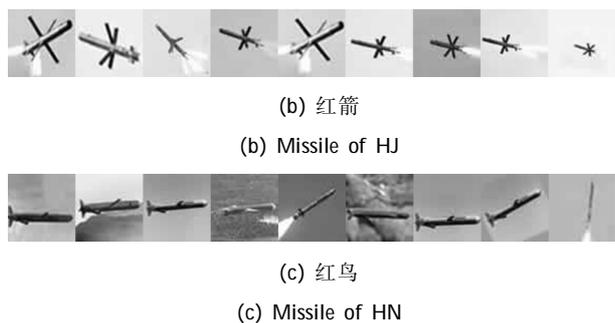
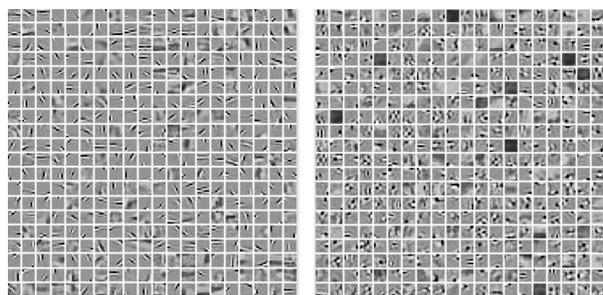


图 3 导弹目标图像

Fig.3 Missile target image

3.1 局部特征向量提取

在提取目标对象图像的底层视觉特征时, 分别采用累计颜色直方图、旋转不变性统一模式的 LBP 特征算子、8 个方向和 4 个尺度滤波器组的 GIST 特征算子分别提取导弹图像的特征。利用文中提出的 SAE 提取导弹图像高层视觉特征, 白化预处理阶段正则化常数 $\epsilon=0.1$, SAE 隐藏层单元数 $units=400$, 即选取数目等于 400 的自学习特征, 权重衰减系数 λ 设置为 0.003, 稀疏惩罚权重系数 β 设置数值为 5, 目标稀疏值 $\rho=0.035$, SAE 池化区域尺寸 $=19 \times 19$ 。文中采用非迁移学习的方法直接提取导弹目标图像中的局部特征向量, 另外, 为了验证迁移学习在对小样本导弹目标对象分类识别的有效性, 直接借助借用与导弹目标图像数据不相关的无标记数据集 STL-10 提取的局部特征向量。借助迁移学习以及非迁移学习获取的图像局部特征向量分别如图 4(a)、(b) 所示。



(a) STL-10 源数据

(b) 导弹图像数据

(a) Source of data STL-10

(b) Data of missile image

图 4 SAE 提取的图像局部特征向量

Fig.4 Image local feature vector extracted by SAE

局部特征向量的边缘性能强弱能够反映局部特征之间的相似性, 由图 4(a) 可以看出, 对 STL-10 数据集图像的特征向量之间的相似性较导弹小样本目

标对象图像提取的局部特征向量间相似性小, 差异性显著。因此, 利用迁移学习 SAE 方法对源领域局部特征提取性能有所提高。

3.2 分类性能比较

将 300 幅导弹目标图像中的 240 幅图像用做训练, 60 幅图像用做测试, 连续运行 5 次交叉验证取平均值后得到算法的分类识别性能结果。算法性能通常可用精度 (Precision) 或准确率 (Accuracy) 指标进行比较验证。Precision 指标代表分类器预测出的正样本中真正正样本的比例, Accuracy 指标表示分类器正确预测的比例, 即算法整体判断能力。文中采用 Accuracy 指标对算法分类性能进行验证。Accuracy 指标如公式 (17) 所示。

$$Accuracy = \frac{TP+TN}{TP+NP+TN+FN} \times 100\% \quad (17)$$

式中: TP 为正确预测出的正样本数目; FP 为错误预测出的正样本个数; TN 为正确预测出负样本个数; FN 为错误预测出负样本数目。

分别利用传统底层特征 (颜色直方图、LBP、GIST) 提取方法, 对导弹目标图像进行颜色、纹理、轮廓等底层特征的提取; 利用 SAE 进行图像高层视觉特征提取, 并通过 CNN 获取目标对象图像的全局特征后, 将其送入 Softmax 回归模型对导弹目标对象进行识别分类。不同特征提取算法下, 导弹目标对象的分类 Accuracy 如表 1 所示。

表 1 不同特征提取算法下导弹分类识别性能比较

Tab.1 Missile classification performance comparison under different feature extracting algorithms

Feature extracted algorithm	Accuracy
SAE feature under transfer learning	92.67%
SAE feature under un-transfer learning	91.67%
Feature of color histogram	85.67%
Feature of GIST	69.67%
Feature of LBP	70.33%
Combining tradition low layer feature	85.33%

如表 1 所示, 基于传统底层特征颜色直方图提取进行导弹分类 Accuracy 最高, 基于 GIST 和 LBP 特征提取进行导弹分类 Accuracy 较差, 而综合三种底层特征后, 导弹分类 Accuracy 并未提高。文中提出利用 SAE 算法提取图像高层特征下的导弹分类 Accuracy 与基于颜色直方图特征提取下的导弹分类

Accuracy 接近,且实验验证了基于迁移学习获取局部特征、送入 CNN 实现导弹分类的方法优于直接对导弹图像进行 SAE 局部特征提取、送入 CNN 实现导弹分类的方法,验证了迁移学习的有效性及准确性。特别是在实际战场环境下,如对未训练过的新型导弹进行分类识别失效的情况下,提供了一种有效的解决方法。基于底层特征 GIST 与 LBP,主要从图像的形状、纹理进行图像特征的提取,从图 3 可以看出,不同类型的导弹形状及纹理区别并不明显,这是导致算法分类 Accuracy 较差的原因。

由于基于 SAE 无监督特征学习的方法不需要事先定义特征模型,通过设置隐层单元数,模拟人眼对图像进行扫描感知来获取目标对象图像中高层的视觉特征,通过学习局部特征向量,送入 CNN 中的 Softmax 分类器对导弹进行分类,实验中,Softmax 分类器衰减项系数 $\lambda=1 \times 10^{-6}$,实验结果表明,基于 SAE 高层特征提取的分类算法性能较传统基于 GIST 或 LBP 特征提取的分类算法性能提高明显。

文中提出将底层特征与 SAE 高层视觉特征融合的方法提高导弹分类性能。不同特征融合情况下,导弹分类性能 Accuracy 如表 2 所示。

表 2 不同特征提取算法下导弹分类识别性能比较
Tab.2 Missile classification performance comparison under different feature extracting algorithm

	Feature extracting algorithm	Accuracy
Un-transfer learning	Pure high layer feature extracted by SAE	91.67%
	Comprehensive feature combining SAE and color histogram feature	91.33%
	Comprehensive feature combining SAE and GIST feature	93.67%
	Comprehensive feature combining SAE and LBP feature	91.33%
	Comprehensive feature combining SAE and all lower layer feature	91.67%
Transfer learning	Pure higher layer feature extracted by SAE	92.67%
	Comprehensive feature combining SAE and color histogram feature	91.33%
	Comprehensive feature combining SAE and GIST feature	93.33%
	Comprehensive feature combining SAE and LBP feature	89.67%
	Comprehensive feature combining SAE and all lower layer feature	92%

由表 2 可以看出,将基于 SAE 提取出的导弹目标图像高层视觉特征与传统底层特征相结合,分类识别性能均高于单一底层特征或高层视觉特征提取下的分类识别算法。且基于 SAE 融合 GIST 特征得到的分类 Accuracy 较不融合底层特征的 SAE 特征提取下的分类算法性能有所提高。由此说明,将两种不同机制下提取出来的特征进行融合,可以实现优势互补,组合后的特征包含更多的图像信息,使分类识别能力得以提升。综合比较来看,SAE 高层视觉特征融合 GIST 特征下的算法分类识别性能最优,无论迁移学习还是不迁移学习下,算法性能最佳,较传统基于 GIST 提高明显,且优于 SAE 高层特征下的分类性能。另外,迁移学习能够有效弥补缺少导弹目标对象下的训练过程,从实验可以看出,采取迁移学习,算法的分类识别性能并未明显下降,有效避免传统缺少目标对象样本数据情况下,分类识别性能下降甚至失效的问题。

4 结论

文中针对多弹小样本目标对象图像,提出一种基于 SAE 高层视觉特征融合传统底层特征的提取新算法,并利用 CNN 中 Softmax 分类器实现了对多弹目标对象进行分类识别,实验验证了文中提出新算法的有效性和准确性。

参考文献:

- [1] Cheng Peirui, Wang Jianli, Wang Bin, et al. Salient object detection based on multi-scale region contrast [J]. Chinese Optics, 2016, 9(1): 97-105. (in Chinese)
成培瑞,王建立,王斌,等.基于多尺度区域对比的显著目标识别[J].中国光学,2016,9(1):97-105.
- [2] Shi Dongcheng, Ni Kang. Background modeling based on YCbCr color space and gesture shadow elimination [J]. Chinese Optics, 2015, 8(4): 589-595. (in Chinese)
史东承,倪康.基于 YCbCr 颜色空间背景建模与手势阴影消除[J].中国光学,2015,8(4):589-595.
- [3] Chen Chao, Yu Yanqin, Huang Shujun, et al. 3D small-field imaging system [J]. Infrared and Laser Engineering, 2016, 45(8): 0824002. (in Chinese)
陈超,於燕琴,黄淑君,等.三维小视场成像系统[J].红外与激光工程,2016,45(8):0824002.
- [4] Zhang Zhongyu, Jiao Shuhong. Infrared ship target detection

- method based on multiple feature fusion [J]. *Infrared and Laser Engineering*, 2015, 44(s): 29-34. (in Chinese)
- 张仲瑜, 焦淑红. 多特征融合的红外舰船目标检测方法 [J]. *红外与激光工程*, 2015, 44(s): 29-34.
- [5] Guo Congzhou, Shi Wenjun, Qin Zhiyuan, et al. Non-convex sparsity regularization for wave back restoration of space object images [J]. *Optics and Precision Engineering*, 2016, 24(4): 902-912. (in Chinese)
- 郭从洲, 时文俊, 秦志远, 等. 空间目标图像的非凸稀疏正则化波后复原[J]. *光学 精密工程*, 2016, 24(4): 902-912.
- [6] Yin Ming, Duan Puhong, Chu Biao, et al. Fusion of infrared and visible images combined with NSDTCT and sparse representation [J]. *Optics and Precision Engineering*, 2016, 24(7): 1763-1771. (in Chinese)
- 殷明, 段普宏, 褚标, 等. 基于非下采样双树复轮廓波变换和稀疏表示的红外和可见光图像融合[J]. *光学 精密工程*, 2016, 24(7): 1763-1771.
- [7] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [C]// *Proceedings of the 26th Annual Conference on Neural Information Processing Systems(NIPS)*, 2012: 1097-1105.
- [8] Bengio Y, Clurville A, Vincent P. Representation learning: a review and new perspectives [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35 (8): 1798-1828.
- [9] Masci J, Meier U, Dan C, et al. Stacked convolutional auto-encoders for hierarchical feature extraction [C]//*Proceedings of the 21st International Conference on Artificial Neural Networks*, 2011: 52-59.
- [10] Li Zuhe, Fan Yangyu, Wang Fengqin. Unsupervised feature learning with sparse autoencoders in YUV space [J]. *Journal of Electronics & Information Technology*, 2016, 38(1): 29-37. (in Chinese)
- 李祖贺, 樊养余, 王凤琴. YUV 空间中基于稀疏自动编码器的无监督特征学习[J]. *电子与信息学报*, 2016, 38(1): 29-37.
- [11] Zhang F, Du B, Zhang L. Saliency-guided unsupervised feature learning for scene classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53 (4): 2175-2184.
- [12] Luo Haibo, Xu Lingyun, Hui Bin, et al. Status and prospect of target tracking based on deep learning [J]. *Infrared and Laser Engineering*, 2017, 46(5): 0502002. (in Chinese)
- 罗海波, 许凌云, 惠斌, 等. 基于深度学习的目标跟踪方法研究现状与展望[J]. *红外与激光工程*, 2017, 46(5): 0502002.
- [13] Adam Coates, Honglak Lee, Andrew Y Ng. An analysis of single-layer networks in unsupervised feature learning [C]// *14th International Conference on Artificial Intelligence and Statistics*, 2011: 215-223.
- [14] Dan C Ciresan, Ueli Meier, Jonathan Masci, et al. Flexible, high performance convolutional neural networks for image classification [C]//*Proceedings of the 22nd International Joint Conference on Artificial Intelligence*, 2011: 1237-1242.
- [15] Zeng R, Wu J, Shao Z, et al. Quaternion softmax classifier [J]. *Electronics Letters*, 2014, 50(25): 1929-1930.