

# 光照不变量特征提取新方法 及其在目标识别中的应用

李宝奇, 贺昱曜, 陈立柱

(西北工业大学航海学院, 陕西西安 710072)

**摘要:** 针对 LNSCT 光照不变量提取方法因舍弃低频分量而丢失目标轮廓信息的问题, 本文提出了一种新的光照不变量提取方法 MLNSCT. 新方法首先用 NSCT 将对数域的输入图像进行第一重多尺度分解, 实现低频分量和高频分量的分离; 其次对高频子带系数进行 BayesShrink 阈值滤波, 低频分量做逆 NSCT 得到其特征图像; 然后对特征图像进行第二重 NSCT 分解, 并对分解后的高频子带阈值滤波以及低频分量逆 NSCT; 经多重 NSCT 分解, 最后由多次分解后的高频子带系数集提取光照不变量特征. 经进一步研究光照不变量特征与原始图像之间的关系, 设计了并行同步卷积神经网络-Dual Lenet, 通过融合两者的高层特征来提高地面目标识别的准确率. 实验结果显示, 在 Lenet 模型下, MLNSCT 比 LNSCT 具有更高的分类准确率, 并且随着分解重数的增加分类准确率更高; 同时融合了光照不变量特征的 Dual lenet 能进一步提高地面目标识别准确率.

**关键词:** 光照不变量; 非下采样轮廓波变换 (NSCT); 多重对数域非下采样轮廓波变换 (MLNSCT); 并行同步卷积神经网络; 地面目标识别

中图分类号: TP183

文献标识码: A

文章编号: 0372-2112 (2018)04-0895-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2018.04.018

## A New Method for Extracting Illumination Invariant Features and Its Application in Target Recognition

LI Bao-qi, HE Yu-yao, CHEN Li-zhu

(School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China)

**Abstract:** In order to solve the problem that LNSCT loses the target contour information due to discarding the low frequency components of image, a new illumination invariant extraction method, called MLNSCT, is proposed. Firstly, NSCT is used to decompose the input image in logarithm domain to realize the separation of the low-frequency and high-frequency components. Secondly, the BayesShrink threshold filter is applied to the high-frequency sub-band coefficients, and the inverse NSCT is performed for the low frequency components to obtain the feature image. Thirdly, a second NSCT decomposition on the feature image, the threshold filtering on high-frequency sub-band and inverse NSCT on low-frequency component are performed sequentially. After multiple NSCT decomposition, the illumination invariant features of the input image are extracted from the set of all high frequency sub-band coefficients. Through further study of the relationship between the illumination invariant features and the raw image, Dual Lenet, which is a parallel synchronous convolutional neural network, is designed to improve the accuracy of ground target recognition by fusing the high-level features of both. The experimental results show that MLNSCT has higher classification accuracy than that of LNSCT in Lenet model, and the classification accuracy is higher with the increase of decomposition number. Furthermore, it is proved that the fusion of illumination invariant features and raw image can effectively improve the classification accuracy of ground target recognition.

**Key words:** illumination invariant features; NSCT (Nonsampled Contourlet Transform); MLNSCT (Multiple LN-SCT); dual Lenet; ground target recognition

## 1 引言

地面目标检测<sup>[1,2]</sup>在无人机导航、搜索、精确打击、以及打击后的效果评估等方面有着重要作用,由于视觉信息的丰富性、及传感器系统的隐蔽性,基于视觉传感器的地面目标检测和识别技术受到越来越多的关注.除机载平台运动、应用场景复杂、天气变化、地面目标隐蔽等因素外,光照水平不一致也是影响地面目标识别精度的一个重要因素,因此,研究不同光照条件下的地面目标特征表示方法对提高地面目标识别精度具有十分重要的价值<sup>[2]</sup>.

有效降低光照影响的方法大致可以分为归一化方法、模型化方法以及提取光照不变量特征方法三类.考虑到归一化方法<sup>[3]</sup>很难提取高质量的目标特征以及模型化方法<sup>[4,5]</sup>的假设条件过多,提取光照不变量特征是解决光照问题更有效的方法.光照不变量采用 Lambert 光照模型<sup>[6]</sup>描述,即将原始图像目标分解为反射分量和光照分量,通常假设反射分量变化的速度低于光照分量变化的速度,其中反射分量表示图像内目标的本质结构,作为光照不变特征进行提取;而光照分量表示图像内目标接受的光照,被视为一种乘性噪声,从原始图像中将反射分量和光照分量分离是光照不变量提取的关键.早期,主要是利用低通滤波法和高通滤波法从输入图像直接或间接的提取光照不变量特征,但提取的光照不变量特征中阴影和光晕现象严重.虽然联合低通滤波器法<sup>[7]</sup>和子空间分解法<sup>[8]</sup>对提取的光照不变量特征质量有一定的改善,但阴影和光晕现象依然存在. Chen 等<sup>[9]</sup>提出的 LTV (Logarithmic Total Variation) 图像分解模型通过对原始图像进行对数域变换,将原光照分量和反射分量的乘性关系变换成加性关系,在强化图像目标边缘的同时也简化了参数的选取.直接从原始图像上提取光照不变量特征是困难的,除光照分量和反射分量的乘性关系外,更重要的是图像缺少有效的分解.

随后,提取光照不变量特征方法与图像多尺度分析理论发展之间存在密切的关联. Goh 等<sup>[10]</sup>利用 DWT (Discrete Wavelet Transform) 对输入图像进行分解,通过对高频系数进行逆 DWT 处理获得光照不变量,由于小波基的各向同性,使得提取的光照不变量中存在较为严重的吉布斯现象. Mandal 等<sup>[11]</sup>通过 Curvelet 小波对输入图像进行分解, Curvelet 小波虽然具有了多方向的特性,但分解系数包含大量的冗余信息使得提取的光照不变量特征并不理想. Contourlet<sup>[12]</sup>是一种真正意义上的图像二维表示方法,它利用拉普拉斯塔形分解 (LP) 和方向滤波器组 (DFB) 实现图像多分辨的、局部的、方向的表示. Boukabou 等<sup>[13]</sup>采用 Contourlet 对输入

图像进行多尺度和多方向分解,但由于 Contourlet 分解系数与输入图像之间缺少位移不变的特性,图像重构过程中的插值操作会影响提取光照不变量特征的质量. NSCT (Nonsampled Contourlet Transform)<sup>[14]</sup>有效解决了 Contourlet 不具备位移不变性的问题,且保留了 Contourlet 变换捕捉二维图像边缘的奇异性的优点. Cheng 等<sup>[15]</sup>提出了一种基于自适应 Normalshrink 阈值滤波的人脸图像光照不变量进行提取方法.该方法首先利用 NSCT 将对数域的输入图像进行多尺度多方向分解,对分解后的高频子带系数做自适应 Normalshrink 阈值滤波处理,将处理后的高频子带系数和原低频子带系数作为光照分量进行分离得到光照不变量. Xie 等<sup>[16]</sup>提出了基于 Bayesshrink 阈值滤波的人脸图像光照不变量特征提取方法.该方法同样利用 NSCT 将对数域输入图像进行多尺度多方向分解,不同的是直接将 Bayesshrink 阈值滤波后的高频子带进行逆 NSCT 处理得到光照不变量.文献[15]和文献[16]都是利用 LNSCT 对输入图像进行多尺度分解,舍弃低频子带,不同的是文献[15]用 Normalshrink 处理高频子带,而文献[16]用 Bayesshrink 处理高频子带.事实上,低频子带在包含光照信息的同时也包含了目标重要的轮廓信息.

为此,本文针对 LNSCT-N<sup>[15]</sup>和 LNSCT-B<sup>[16]</sup>的不足提出了一种新的光照不变量提取方法 MLNSCT (Multiple LNSCT),即将低频分量内的光照信息和目标轮廓信息在多重多尺度上分解,通过引入目标轮廓信息来改善光照不变量特征的质量,降低因光照等级不同对目标识别的干扰.同时深入研究地面目标光照不变量特征与原始图像的关系,并针对受不同等级光照影响的地面目标识别问题建立同步并行卷积神经网络模型-Dual Lenet,通过融合原始图像和光照不变量的高层次特征实现信息上的互补来提高地面目标识别的准确程度.

## 2 光照不变量提取方法-MLNSCT

LNSCT-N 和 LNSCT-B 两种光照不变量提取方法通过舍弃低频分量的方式来消除光照的影响,但在降低光照影响的同时也丢失了目标重要的轮廓信息.舍弃低频分量会降低地面目标的可辨识程度,显然进一步从低频分量中提取目标轮廓信息是改善光照不变量特征质量的有效手段.

### 2.1 MLNSCT 光照不变量提取新方法

NSCT 的非下采样操作保证了低频分量和原始输入图像之间的位移不变的特性,即低频分量与输入图像之间的一一对应关系,因此可以通过对低频分量再次进行多尺度分解来实现光照信息和目标轮廓的分离.为此,本文提出了 MLNSCT (多重对数域非下采样轮

廓波变换)光照不变量提取方法. MLNSCT 的基本思路是:对数域的原始图像经 NSCT 分解以后,对低频分量做 NSCT 逆变换得到其特征图像,特征图像中的高频信息由原始图像中的目标纹理逐渐变为目标的部分轮廓信息,此时光照信息相对于轮廓信息仍属于低频信息,因此可以通过足够多重的 NSCT 分解将光照分量向更高层的低频分量中转移,实现低频分量中目标轮廓信息和光照信息的分离,最后通过准确获取低频分量中的目标轮廓信息来改善光照不变量特征的质量.

MLNSCT 首先对对数域的输入图像进行第一重的 NSCT 分解,实现图像低频分量和高频分量的分离;然后对高频子带系数进行 BayesShrink 阈值滤波、低频分量做逆 NSCT 变换得到其特征图像;接着对特征图像进行第二重 NSCT 分解以及高频子带阈值滤波和低频分量逆 NSCT 变换;经多重 NSCT 分解,原低频分量中的目标信息和光照信息得到进一步的分离;最后由每次分解后的高频子带系数集提取输入图像的光照不变量特征. MLNSCT 方法的数学描述如下.

MLNSCT 首先对原始图像  $I$  作对数域变换,得到图像  $f$ . 接着对  $f$  进行第一重 NSCT 分解,得到高频方向子带  $f_{j,k}$  和低频分量  $f_j^0$ , 其中  $f_{j,k}$  表示原始图像在第  $j$  层的第  $k$  个方向上的分解系数,  $f_j^0$  为分解尺度为  $J$  时的低频分量系数.

利用 BayesShrink<sup>[16]</sup> 对  $f_{j,k}$  进行阈值滤波处理,并用  $\bar{f}_{j,k} = \text{Bayes}(f_{j,k})$  表示 BayesShrink 阈值滤波的整个过程.

与 LNSCT-B 直接由  $\bar{f}_{j,k}$  提取光照不变量特征不同, MLNSCT 先合成  $f_j^0$  特征图像.

$$f_j^0 = g_0 f_j^0 \quad (1)$$

其中  $g_0$  为第一重 NSCT 对应的合成滤波器,  $f_j^0$  为低频分量  $f_j^0$  对应的特征图像.

随后对  $f_j^0$  进行第二重 NSCT 分解.

$$\{f_j^0(2), \{f_{j,k}(2)\}\} = \text{NSCT}(f_j^0) \quad (2)$$

$f_j^0(2)$  表示由  $f_j^0$  分解得到的低频分量,  $\{f_{j,k}(2)\}$  表示由  $f_j^0$  分解得到的高频子带系数集. 同样利用 BayesShrink 对高频子带系数集  $\{f_{j,k}(2)\}$ , 进行阈值滤波处理,同时合成低频分量  $f_j^0(2)$  的特征图像.

$$\bar{f}_{j,k}(2) = \text{Bayes}(f_{j,k}(2)) \quad (3)$$

$$f_j^0(2) = g_0(2) f_j^0(2) \quad (4)$$

其中  $\bar{f}_{j,k}(2)$  第二重高频子带系数集  $\{f_{j,k}(2)\}$  经 BayesShrink 阈值滤波的结果,  $f_j^0(2)$  为第二重低频分量分成的特征图像.

MLNSCT 经  $n$  重 NSCT 分解和处理后,低频分量  $f_j^0$  中的光照信息和目标轮廓信息得到进一步的分离,其中光照分量被分离至更高层的低频分量  $f_j^0(n)$  中,而目标轮廓信息在每一重分解的高频方向子带系数集

$\{\bar{f}_{j,k}(2)\}, \{\bar{f}_{j,k}(3)\}, \dots, \{\bar{f}_{j,k}(n)\}\}$  中表达. 因此, MLNSCT 舍弃顶层低频分量  $f_j^0(n)$ , 由所有的高频方向子带系数集  $\{\bar{f}_{j,k}\}, \{\bar{f}_{j,k}(2)\}, \dots, \{\bar{f}_{j,k}(n)\}\}$  提取光照不变量特征  $\mu$ .

首先由高频方向子带  $\{\bar{f}_{j,k}(n)\}$  重构  $n-1$  重的低频分量.

$$\hat{f}_j^0(n-1) = i\text{NSCT}(0, \{\bar{f}_{j,k}(n)\}) \quad (5)$$

其中  $\hat{f}_j^0(n-1)$  表示重构的第  $n-1$  重低频分量,  $\{\bar{f}_{j,k}(n)\}$  为第  $n$  重 BayesShrink 阈值滤波后的高频子带系数集合. 接着由第  $n-1$  重的高频方向子带系数  $\{\bar{f}_{j,k}(n)\}$  和低频分量  $\hat{f}_j^0(n-1)$  重构  $n-2$  重的低频分量.

$$\hat{f}_j^0(n-2) = i\text{NSCT}(\hat{f}_j^0(n-1), \{\bar{f}_{j,k}(n-1)\}) \quad (6)$$

其中  $\hat{f}_j^0(n-2)$  表示第  $n-2$  重的低频分量. 重复利用式 (6) 得到第一重 NSCT 的低频分量.

$$\hat{f}_j^0 = i\text{NSCT}(\hat{f}_j^0(2), \{\bar{f}_{j,k}(2)\}) \quad (7)$$

其中  $\hat{f}_j^0$  表示第一重 NSCT 分解的低频分量, 并由  $\hat{f}_j^0$  和第一重高频方向子带系数  $\{\bar{f}_{j,k}\}$  重构原始图像.

$$\hat{f} = i\text{NSCT}(\hat{f}_j^0, \{\bar{f}_{j,k}\}) \quad (8)$$

$$\mu = \hat{f} \quad (9)$$

其中  $\mu$  为由 MLNSCT 提取的光照不变量特征.

根据上述描述, 本文提出的光照不变量特征提取方法 MLNSCT 具体实现步骤如算法 1 所示.

#### 算法 1 MLNSCT 实现步骤

Step1: 对地面目标图像  $I$  进行对数域变换:  $f = \log(I)$ .

Step2: 对变换得到的图像  $f$  进行 NSCT 分解, 得到低频子带系数  $f_j^0$  和高频子带系数集  $\{f_{j,k}\}$ .

Step3: 利用公式 BayesShrink 对  $\{f_{j,k}\}$  进行阈值滤波处理, 并得到阈值滤波后的高频子带系数集  $\{\bar{f}_{j,k}\}$ .

Step4: 由低频子带系数  $f_j^0$  重构其图像特征  $f_j^0$ , 再次进行 NSCT 分解, 得到低频子带系数  $f_j^0(2)$  和高频子带系数集  $\{f_{j,k}(2)\}$ .

Step5: 重复利用 Step3 和 Step4 对低频子带系数  $f_j^0$  处理, 得到  $\{\bar{f}_{j,k}(2)\}, \{\bar{f}_{j,k}(3)\}, \dots, \{\bar{f}_{j,k}(n)\}, f_j^0(n)\}$ , 其中  $n=2, 3, 4, \dots$ . 由  $\{\bar{f}_{j,k}(2)\}, \{\bar{f}_{j,k}(3)\}, \dots, \{\bar{f}_{j,k}(n)\}\}$  合成低频子带系数  $\hat{f}_j^0$ .

Step6: 通过对  $\{\bar{f}_{j,k}\}$  和  $\hat{f}_j^0$  进行逆 NSCT 处理, 提取地面目标光照不变量特征并用于后续识别.

## 2.2 算法分析

Contourlet<sup>[12]</sup> 利用 LP 和 DFB 实现输入图像多分辨的、局域的、方向的表示, 但分解系数尺寸随分解尺度增加成倍缩小, 分解系数与输入图像之间缺少位移不变的特性, 因此图像重构过程中的插值操作会影响提取光照不变量特征的质量. LNSCT<sup>[15, 16]</sup> 取消上下采样操作保证了分解系数与原始图像之间位移不变的特性, 即低频系数和所有高频子带系数与原始图像的尺寸相

同,且保留了 Contourlet 变换捕捉二维图像边缘的奇异性的优点,但由于舍弃了低频分量降低了光照不变量特征的质量.同时,LNSCT-N 与 LNSCT-B 虽然采用不同的策略对高频子带系数进行处理,但都需要对每个高频子带系数进行一次权重处理,因此在计算复杂度上两者接近. MLNSCT 基于 LNSCT,通过对低频分量进行多重 NSCT 分解实现目标轮廓信息与光照信息的分离,进而提高光照不变量特征的质量,因此 MLNSCT 的计算复杂度与分解重数  $n$  存在线性关系,分解重数  $n$  越大,计算量越大.对于一幅像素为  $128 \times 128$  的图像,Contourlet、LNSCT-N、LNSCT-B、MLNSCT-2 和 MLNSCT-3 五种光照不变量提取方法按  $[1, 2, 3]$  三个尺度进行分解,提取光照不变量特征的时间分别为 1.55s、11.64s、12.26s、28.92s 和 51.16s.

同时对 MLNSCT 光照不变量提取方法的效果进行




图1 MLNSCT光照不变量特征

### 3 实验模型

无人机在图像采集过程中,与地面目标的空间位置关系并不是固定的,即采集到的图像可能是地面目标任意角度的表示,因此本文选用能够区分地面目标角度和位置变化的 CNN 模型分类准确率<sup>[17]</sup>作为光照不变量提取方法的定量评价指标.并通过深入研究原始图像和光照不变量特征的关系,在单路卷积神经网络-Lenet 的基础上设计一个并行同步卷积神经网络 (Dual Lenet),融合原始图像和光照不变量的高层次特征来提高地面目标识别精度.

#### 3.1 光照不变量特征评价模型-Lenet

Lenet 是一种典型的深度学习<sup>[18]</sup>模型,其通过局部特征感知、权重共享以及特征采样,极大的减少了连接权重的数量,避免了特征提取和分类过程中数据重建的复杂度,对图像目标移位,缩放以及其它形式的扭曲有很好的辨识效果.由于采用大规模行的数据对模型进行训练,Lenet 模型的泛化能力更强,对训练数据集以外的图像目标也有很强的辨识能力,因此适合于地面目标光照不变量特征的定量评价.

#### 3.2 地面目标识别模型-Dual Lenet

从当前提取光照不变量方法的机理考虑,光照分量的频率变化范围和图像目标的频率变换范围必然存在重合,虽然图像多尺度分解改善了光照不变量特征的质量,但将图像目标和光照信息完全分离是不可能

比较,如图 1 所示.输入图像-图 1(a)经对数域变换,如图 1(b)所示. NSCT 对图 1(b)做多尺度分解实现图像低频分量和高频分量的分离,如图 1(c)和图 1(d)所示.从高频分量特征图 1(d)中可以发现图像内目标受光照的影响非常小,基本上去除了全部的光照信息;低频分量特征图 1(c)中不仅包含了光照信息同时也包含了图像目标重要的轮廓信息.本文提出的光照不变量提取方法 MLNSCT 在 1 重和 3 重 NSCT 分解下的光照不变量特征如图 1(e)和(f)所示,两幅图像直观上并没有明显的差异,但利用两幅图像的像素差,如图 1(g)所示,可以发现 MLNSCT 在 3 重 NSCT 分解下的光照不变量特征比在 1 重 NSCT 分解下的光照不变量特征包含了更多的轮廓信息,也没有引入不必要的光照信息.同时由 2.1 节的理论分析和公式推导可知 LNSCT-B 是 MLNSCT 在 1 重 NSCT 分解下的特殊形式.

的光照不变量特征能降低光照对图像识别的干扰,然而光照不变量仅是原始图像本质的部分描述,不可避免的会存在信息丢失的问题.原始图像虽然存在光照干扰问题,但包含丰富的目标信息;光照不变量特征虽然降低了光照对地面目标的干扰,但是以丢失目标部分轮廓信息为代价;充分利用原始图像及其光照不变量特征是提高地面目标识别精度的有效手段,尤其是对于光照不一致的地面目标识别.

Dual Lenet 的整体框架,如图 2 所示,由两个对称的 Lenet 组成.原始图像和光照不变量的高层特征 Fc2 通过合并的方式进行融合,融合后的高层特征 Concat layer 同时包含原始图像和光照不变量的信息,信息上的互补是提高地面目标识别精度的保证. Dual Lenet 与 Lenet 的前向传播和反向微调方式的原理是一样,只不过 Dual Lenet 在前向传播过程中需保证两路网络之间输入和输出的时间同步以及两路输入图像的内容和数量需保持一致,而在反向微调过程中利用一个 loss 函数便可实现两路网络参数的同步调节.

### 4 实验验证及结果分析

为了验证光照不变量提取方法 MLNSCT 的有效性以及在不同分解重数下的性能差异,以 Contourlet、LNSCT-N 和 LNSCT-B 三种光照不变量提取方法为参考,设计实验 1 利用单路卷积神经网络模型 Lenet 的分类准确率定量评价光照不变量特征的质量.为了验证地

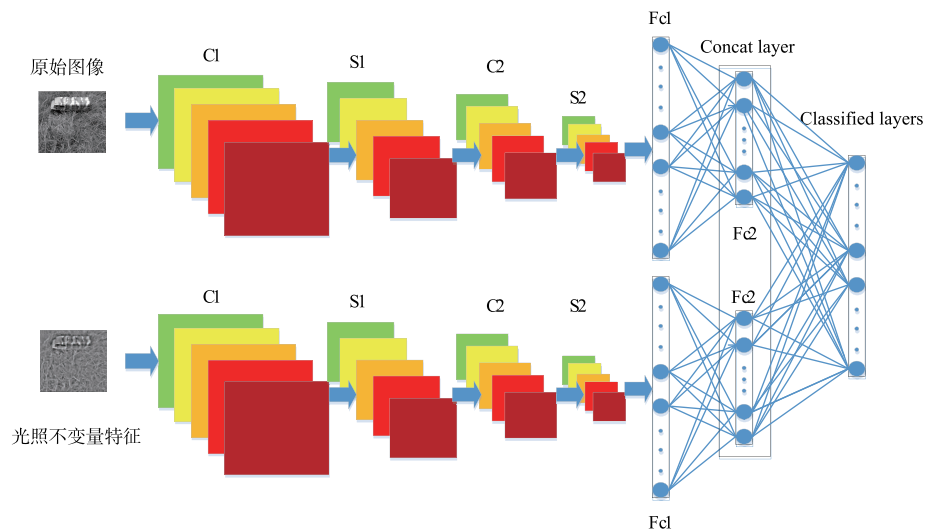


图2 Dual lenet模型结构

面目标识别模型 Dual Lenet 的性能,以原始图像输入下的 CNN 模型分类准确率为参考,设计实验 2 研究不同光照不变量特征对 Dual Lenet 性能的影响. 为了进一步研究光照等级对目标检测影响,设计实验 3 通过比较不同光照条件下的地面目标识别的准确率来说明光照的影响. 实验采用的 Lenet 和 Dual Lenet 由 caffe 工具箱设计,采用 GPU 计算方式,并利用 cuDNN 进行加速处理.

#### 4.1 实验数据

实验以三个不同时刻四种地面目标多个拍摄角度的图像数据集为研究对象. 在地面目标图像采集过程中,针对同一目标采集得到的图像中的目标位置和角度是没有重复的,并假定短时间内地面目标接受光照的等级是相同的. 原始采集数据集如表 1 所示.

表 1 不同时刻的原始图像数据集

	目标 1	目标 2	目标 3	目标 4	合计	备注
Data-1	630	630	660	480	2400	8:00 - 09:00
Data-2	580	590	660	570	2400	13:30 - 14:30
Data-3	600	630	600	570	2400	17:30 - 18:30
Mix-average	604	616	640	540	2400	按比例混合
Mix-all	1810	1840	1980	1620	7200	混合数据集

其中 Data-1、Data-2 和 Data-3 为早中晚三种不同时刻采集的图像数据集, Mix-average 为 Data-1、Data-2 和 Data-3 三种数据集按 1/3 比例混合的实验数据集. Data-1、Data-2、Data-3 和 Mix-average 用于实验 3 的光照影响测试. 同时 Data-1、Data-2 和 Data-3 三种图像数据集按目标类型混合得到 Mix-all 数据集,并将 Mix-all 数据集内图像尺寸缩放至  $128 \times 128$  像素. Mix-all 作为光照不变量特征(实验 1)和地面目标识别准确率(实验 2)测试的原始实验数据集.

Contourlet、LNSCT-N、LNSCT-B 以及本文方法 MLN-SCT 分别对 Mix-all 数据集进行光照不变量提取,按 [1, 2, 3] 三个尺度进行分解,生成相应的实验数据集如表 2 所示. 表 2 中的光照不变量特征数据集用于实验 1 和实验 2 光照不变量特征的比较和分析.

表 2 光照不变量特征数据集

	目标 1	目标 2	目标 3	目标 4	合计	备注
Mix-contourlet	1810	1840	1980	1620	7200	Contourlet 处理
Mix-lnsct-N	1810	1840	1980	1620	7200	LNSCT-N 处理
Mix-lnsct-B	1810	1840	1980	1620	7200	LNSCT-B 处理
Mix-mlnsct-n	1810	1840	1980	1620	7200	分解 $n$ 次

为了进一步提高模型计算速度将所有的实验数据集图像尺寸缩放至  $28 \times 28$  以供 Lenet 和 Dual Lenet 处理.

#### 4.2 实验 1. 光照不变量特征质量评价

本实验以 Contourlet、LNSCT-N 和 LNSCT-B 三种光照不变量提取方法为参考,与 MLNSCT 在 2 和 3 次分解下的光照不变量特征进行比较. 按相同的随机方式从 Mix-contourlet、Mix-lnsct-N、Mix-lnsct-B、Mix-mlnsct-2 和 Mix-mlnsct-3 中抽取 6000 幅图像用于 Lenet 的训练, 1200 幅图像用于 Lenet 的测试. 实验采用批处理方式,训练数据批次大小为 100,测试数据批次大小为 50. 最大迭代次数为 2000,每 200 次进行一次测试. 如图 3 所示.

从图 3 可以发现,当 Lenet 模型迭代 2000 次时, Contourlet 分类准确率为 84.5%, LNSCT-N 分类准确率为 86.6%, LNSCT-B 分类准确率为 90.0%, MLNSCT-2 分类准确率为 91.3%, MLNSCT-3 分类准确率为 93.3%. 从最终的识别准确率看,本文方法 MLNSCT 比其它三种光照不变量提取方法效果好,同时三重 NSCT

分解下的 MLNSCT-3 比两重 NSCT 分解下的 MLNSCT-2 的效果好。

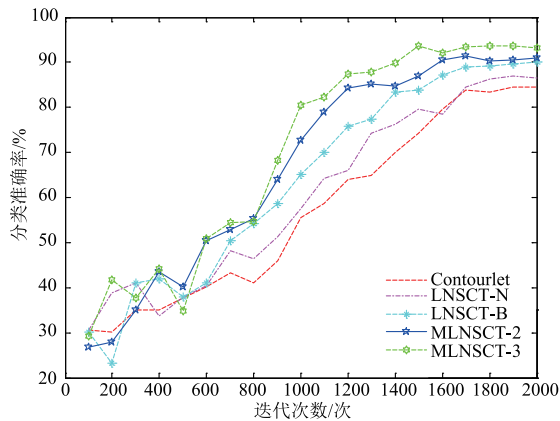


图3 光照不变量特征质量评价

#### 4.3 实验 2. Dual Lenet 性能分析

本实验在 Dual Lenet 模型中固定上路输入为原始图像数据集 Mix-all (Raw), 分别以光照不变量特征数据集 Mix-contourlet、Mix-Insct-N、Mix-Insct-B、Mix-mlnsct-2 和 Mix-mlnsct-3 作为下路输入, 建立 Dual Lenet 的五种形式 Raw + contourlet、Raw + Insct-n、Raw + Insct-b、Raw + mlnsct-2 和 Raw + mlnsct-3, 并以原始图像数据集 Mix-all 在 Lenet 模型下 (Raw) 和双路 Mix-all 在 Dual Lenet (Raw + Raw) 下的分类准确率为参考。所有实验数据集按相同的随机方式抽取 6000 幅图像用于模型的训练, 剩余的 1200 幅图像用于模型的测试。实验采用批处理方式, 训练数据批次大小为 100, 测试批次大小为 50。最大迭代次数为 350, 每 50 次进行一次测试并生成表 3。

表 3 Dual Lenet 的分类准确率

类型	不同迭代次数下的分类准确率					
	100	150	200	250	300	350
Raw	49.2	74.8	82.2	86.5	88.2	91.7
Raw + Raw	55.3	56.4	65.1	76.1	87.3	91.1
Raw + contourlet	49.1	62.4	71.7	83.0	91.0	92.4
Raw + Insct-n	52.6	76.4	82.4	87.1	90.5	94.0
Raw + Insct-b	52.6	73.7	84.7	86.7	90.0	93.6
Raw + mlnsct-2	51.9	75.0	87.9	90.1	92.4	95
Raw + mlnsct-3	52.6	79.6	89.3	91.0	93.4	95.8

通过表 3 对比 Dual Lenet 与 Lenet 下的分类准确率可以发现, 融合光照不变量特征的 Dual Lenet 较 Lenet 的分类准确率存在一定程度的提升, 同时结合实验 1 的结果可以发现光照不变量特征的质量越好 Dual Lenet 的分类准确率越高, 并且在模型迭代 350 次时, 以 MLNSCT-3 为下路输入的 Dual Lenet 模型分类准确率达到了 95.8%, 明显高于 Raw 在 Lenet 下的分类准确率

(91.7%)。与此同时, Raw + Raw 的分类准确率并没有因为增加数据量而提高, 其分类准确率与 Raw 接近, 为 91.1%。

#### 4.4 实验 3. 光照对目标识别精度的影响

在 Lenet 模型下, 分别用原始图像数据集 Data-1、Data-2、Data-3 和 Mix-average 作为输入, 通过 Lenet 的分类准确率间接评价光照等级对图像识别精度的影响。从上述原始图像实验数据集中按相同的随机方式抽取 2000 幅图像用于模型的训练, 剩余的 400 幅图像用于模型的测试。实验采用批处理方式, 训练数据批次大小为 100, 测试批次大小为 50。最大迭代次数为 500, 每 25 次进行一次测试。如图 4 所示。




图4 光照对地面目标识别的影响

从图 4 可以发现, 当 Lenet 模型迭代次数达 500 次, Data-1 分类准确率为 100%, Data-2 分类准确率为 97.5%, Data-3 分类准确率为 98.5%, Mix-average 分类准确率为 96.2%。其中 Data-1 代表较弱光照数据集、Data-2 代表强光照数据集、Data-3 代表较强光数据集、Mix-average 代表混合光照数据集。由此可见, 光照越强、越复杂对卷积神经网络高层特征的干扰越大。

#### 4.5 讨论

与 DWT、Curvelet、Contourlet 等图像多尺度表示方式相比, NSCT 同时具有多尺度, 多方向和移位不变的特性, 能实现图像更加全面的表达, 是提取高质量光照不变量特征的前提。光照不变量提取方法 LNSCT-N 和 LNSCT-B 基于 NSCT 多尺度分解, 但其舍去了包含目标轮廓信息和光照信息的低频子带。MLNSCT 通过多重 NSCT 分解将低频分量中目标信息分离到更多高频方向子带上, 将光照信息限制到更高层的低频子带中, 进而保证从原被舍弃的低频子带中提取更多的目标信息以改善光照不变量特征的质量。MLNSCT 的性能与 NSCT 分解次数有直接关系, 理论上 MLNSCT 的分解次数越多, 光照不变量提取的效果越好, 但考虑到计算成本和实际需求通常只考虑有限次数的分解, 本文对

MLNSCT 在两次和三次分解下进行了相应的仿真实验,实验结果也证明了 MLNSCT 随着分解重数的增加,提取的光照不变量特征质量越好.

卷积神经网络除定量评价提取光照不变量方法外,同样能实现地面目标的检测和识别,但受光照等级不同的影响势必会干扰高层特征的生成,降低数据区分能力.光照不变量的提取主要是降低光照等级不同对目标识别带来的干扰,是图像目标的本质的描述,但从现行的光照不变量提取方法考虑,光照分量是不可能从图像中完全消除的,而且在消除光照信息的同时图像目标的相关信息也一同被丢弃.原始图像虽然受不同光照的影响,但保证了目标信息的完整性. Dual Lenet 通过对原始图像和光照不变量特征逐层的非线性变换,得到两组更高层次的、更加抽象的特征表达,二者的融合实现地面目标信息的互补和纠正,进而获得了更高的地面目标识别精度. Raw + Raw 并没有因为数据的增加而提高分类准确率,可见完全冗余的信息并不能提高 Dual Lenet 的性能.

## 5 结论

光照不变量特征能有效降低光照对目标识别的干扰,本文提出了一种新的光照不变量提取方法 MLNSCT, MLNSCT 有效改善了 LNSCT 光照不变量提取方法对低频分量中目标轮廓信息提取不足的问题,并经理论分析和仿真实验证明了 MLNSCT 的有效性.同时对光照不变量特征和原始图像之间的关系做了深入的研究,并针对地面目标识别问题,设计 Dual Lenet 来融合原始图像和光照不变量特征的高层特征实现了地面目标识别准确率的提升.

下一步的研究重点包括:(1)研究 MLNSCT 的停止机制,根据输入的光照图像自适应的选取分解重数  $n$ ;(2)进一步优化 Dual Lenet 的模型结构,提高模型的收敛速度.

## 参考文献

- [1] DENG H, HIMED B, WICKS M C. Image feature-based space-time processing for ground moving target detection [J]. IEEE Signal Processing Letters, 2006, 13(4): 216-219.
- [2] YORK G, PACK D J. Ground target detection using cooperative unmanned aerial systems [J]. Journal of Intelligent & Robotic Systems, 2012, 6(1-4): 473-478.
- [3] SHAN S J, et al. Illumination normalization for robust face recognition against varying illumination conditions [A]. The IEEE International Workshop on Analysis and Modeling of Faces and Gestures (AMFG) [C]. USA: IEEE Press, 2003. DOI:10.1109/AMFG.2003.1240838.
- [4] GEORGHIDEORS A S, et al. From few to many: illumination cone models for face recognition under variable illumination and pose [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(6): 630-660.
- [5] 柯圣财, 赵永威, 李弼程, 彭天强. 基于卷积神经网络和监督核哈希的图像检索方法 [J]. 电子学报, 2017, 45(1): 157-163.  
KE Sheng-cai, ZHAO Yong-wei, LI Bi-cheng, PENG Tian-qiang. Image retrieval based on convolutional neural network and kernel-based supervised hashing [J]. Acta Electronica Sinica, 2017, 45(1): 157-163. (in Chinese)
- [6] BASRI R, JACOBS D W. Lambertian reflectance and linear subspaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(2): 218-233.
- [7] JOBSON D J, et al. A multi-scale retinex for bridging the gap between color images and the human observation of scenes [J]. IEEE Transactions on Image Processing, 1997, 6(7): 965-976.
- [8] CHEN C P, CHEN C S. Lighting normalization with generic intrinsic illumination subspace for face recognition [A]. The Tenth IEEE International Conference on Computer Vision (ICCV) [C]. USA: IEEE Press, 2005. DOI:10.1109/ICCV.2005.144.
- [9] CHEN T, COMANICIU D, HUANG T S, et al. Total variation models for variable lighting face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(9): 1519-1524.
- [10] GOH Y Z, et al. Wavelet-based illumination invariant pre-processing in face recognition [J]. Journal of Electronic Imaging, 2009, 18(2): 421-425.
- [11] MANDAL T, et al. Face recognition by curvelet based feature extraction [A]. Proceedings of the 4th International Conference on Image Analysis and Recognition (ICIAR) [C]. Berlin, Heidelberg: Springer-Verlag, 2007. 806-817.
- [12] DO M H, et al. The contourlet transform: an efficient directional multiresolution image representation [J]. IEEE Transactions on Image Processing, 2005, 14(12): 2011-2015.
- [13] BOUKABOU W R, BOURIDANE A. Contourlet-based feature extraction with PCA for face recognition [A]. NASA/ESA Conference on Adaptive Hardware and Systems (AHS) [C]. USA: IEEE Press, 2008. DOI: 10.1109/AHS.2008.11.
- [14] CUNHA A L D, et al. The nonsubsampled contourlet transform: theory, design, and applications [J]. IEEE Transactions on Image Processing, 2006, 15(10): 3089-3101.
- [15] CHENG Y, et al. Robust face recognition based on illumi-

nation invariant in nonsubsamped contourlet transform domain [J]. Neurocomputing, 2010, 73 ( 10-12 ): 2217 - 2224.

- [ 16 ] XIE X H, et al. Extraction of illumination invariant facial features from a single image using nonsubsamped contourlet transform [ J ]. Pattern Recognition, 2010, 43 ( 12 ): 4177 - 4189.
- [ 17 ] 潘泓, 朱亚平, 夏思宇, 金立左. 基于上下文信息和核熵成分分析的目标分类算法 [ J ]. 电子学报, 2016, 44 ( 3 ): 580 - 586.  
PAN Hong, ZHU Ya-ping, XIA Si-yu, JIN Li-zuo. Object classification using context cue and kernel entropy component analysis [ J ]. Acta Electronica Sinica, 2016, 44 ( 3 ): 580 - 586. ( in Chinese )
- [ 18 ] LECUN Y, BENGIO Y, HINTON G E. Deep learning [ J ]. Nature, 2015, 521 ( 7553 ): 436 - 444.

### 作者简介



**李宝奇 ( 通信作者 )** 男, 1985 年 12 月生, 天津宝坻人. 现于西北工业大学航海学院攻读博士学位, 研究方向为目标检测、识别和跟踪, 深度学习理论.

E-mail: bqli@mail.nwpu.edu.cn



**贺昱曜** 男, 1956 年生, 陕西富平人. 教授, 西北工业大学博士生导师. 主要研究方向为精确制导与仿真, 智能控制与智能优化理论, 图像处理理论与算法.

E-mail: heyyao@nwpu.edu.cn



**陈立柱** 男, 1992 年 3 月生, 安徽宿州人. 现于西北工业大学航海学院攻读硕士学位, 研究方向为目标检测.

E-mail: lzchen@mail.nwpu.edu.cn