

(1) 平均分类精度(MAP):准确分类的目标占总数的比例.

(2) 前 1 000 个样本的分类精度(precision of top 1000 returned samples):对所有测试样本寻找其匹配度较高的前 1 000 个训练样本计算其分类精度,再对这些测试样本分类精度取平均值.

(3) 汉明距离在半径为 2 时的分类精度(precision of Hamming distance with radius 2):以汉明距离小于等于 2 为测度,对所有测试样本寻找与其接近的训练样本并计算分类精度,再对这些测试样本的分类精度取平均值.

(4) 各分类精度(AP):各类目标的分类精度.

表 2~表 4 从宏观的角度给出了 7 种哈希方法在多目标分类中的精度对比情况.在哈希字节的选取上,给出了 8 字节、16 字节、32 字节和 64 字节的数据.可以看到,随着哈希字节数的增长,各种哈希方法的增长趋势是一致的,直至 32 字节,而到了 64 字节时,很多哈希方法的精度反而会有所降低.这种情况的发生往往取决于数据集的分布以及过拟合的发生.鉴于此,在表 5 中给出了 32 字节时各目标分类的结果.

Table 2 MAP of different hashing method in 8,16,32,64 bits

表 2 不同哈希方法在 8、16、32、64 字节下的平均分类精度

方法 \ 数据集	NWPU VHR-10				RSOD-Dataset			
	8-bits	16-bits	32-bits	64-bits	8-bits	16-bits	32-bits	64-bits
谱哈希	0.197 2	0.198 5	0.226 8	0.214 1	0.498 6	0.511 3	0.538 6	0.496 2
可扩展图哈希	0.266 8	0.279 7	0.293 6	0.298 2	0.559 8	0.582 0	0.600 0	0.626 2
核监督哈希	0.677 3	0.709 9	0.735 7	0.759 5	0.727 4	0.774 5	0.800 1	0.816 8
列采样监督离散哈希	0.729 8	0.784 5	0.823 7	0.832 0	0.826 0	0.888 4	0.915 0	0.927 8
监督离散哈希	0.708 9	0.847 5	0.910 1	0.914 1	0.760 1	0.897 6	0.938 9	0.958 1
旋转不变离散哈希	0.835 3	0.886 3	0.920 5	0.928 4	0.892 0	0.927 4	0.952 9	0.964 2
旋转&尺度不变离散哈希	0.789 5	0.843 4	0.870 4	0.883 2	0.871 3	0.899 4	0.935 4	0.949 5
仿射不变离散哈希	0.850 5	0.902 0	0.926 3	0.933 8	0.911 1	0.936 4	0.959 0	0.972 9

Table 3 The precision of top 1000 returned samples of different hashing method in 8,16,32,64 bits

表 3 不同哈希方法在 8、16、32、64 字节下的前 1 000 个样本的分类精度

方法 \ 数据集	NWPU VHR-10				RSOD-Dataset			
	8-bits	16-bits	32-bits	64-bits	8-bits	16-bits	32-bits	64-bits
谱哈希	0.259 3	0.284 2	0.341 6	0.328 4	0.514 3	0.516 3	0.536 2	0.502 6
可扩展图哈希	0.392 0	0.400 6	0.410 4	0.423 9	0.659 9	0.681 3	0.721 0	0.755 7
核监督哈希	0.696 2	0.748 7	0.789 0	0.792 0	0.727 8	0.780 5	0.805 0	0.819 7
列采样监督离散哈希	0.683 0	0.730 0	0.764 1	0.774 1	0.766 9	0.819 7	0.869	0.899 4
监督离散哈希	0.744 3	0.868 6	0.915 3	0.918 5	0.763 0	0.900 6	0.944 2	0.949 4
旋转不变离散哈希	0.852 5	0.901 0	0.925 3	0.930 6	0.894 4	0.926 9	0.950 1	0.959 5
旋转&尺度不变离散哈希	0.832 9	0.871 1	0.891 8	0.899 1	0.868 7	0.918 0	0.931 8	0.941 9
仿射不变离散哈希	0.875 9	0.913 8	0.930 0	0.937 4	0.917 9	0.934 5	0.952 7	0.987 8

Table 4 The precision of Hamming distance with radius 2 of different hashing method in 8,16,32,64 bits

表 4 不同哈希方法在 8、16、32、64 字节下的汉明距离在半径为 2 时的分类精度

方法 \ 数据集	NWPU VHR-10				RSOD-Dataset			
	8-bits	16-bits	32-bits	64-bits	8-bits	16-bits	32-bits	64-bits
谱哈希	0.214 4	0.381 8	0.407 3	0.005 5	0.514 9	0.740 2	0.788 3	0.019 7
可扩展图哈希	0.287 1	0.435 9	0.420 0	0.032 0	0.572 1	0.822 3	0.812 9	0.039 3
核监督哈希	0.588 6	0.728 8	0.783 3	0.680 7	0.722 9	0.782 0	0.784 4	0.819 8
列采样监督离散哈希	0.617 8	0.599 0	0.414 0	0.367 0	0.751 0	0.665 1	0.462 7	0.359 0
监督离散哈希	0.431 5	0.837 4	0.881 7	0.821 7	0.661 9	0.904 6	0.933 8	0.902 0
旋转不变离散哈希	0.513 4	0.890 8	0.918 7	0.871 7	0.759 0	0.921 5	0.960 6	0.970 4
旋转&尺度不变离散哈希	0.524 9	0.848 7	0.882 7	0.854 2	0.780 7	0.877 3	0.941 0	0.962 5
仿射不变离散哈希	0.670 1	0.901 3	0.920 7	0.925 0	0.748 7	0.929 4	0.967 3	0.968 1

两个数据集均能有效验证 7 种哈希方法的分类精度.从宏观对比上看,武汉大学 RSOD-Dataset 数据集的分类精度较高于西北工业大学 NWPU VHR-10 数据集的分类精度,究其原因,是武汉大学的数据集虽然样本数很

多,但是数据类型较少(4 个),样本的差异性较大,数据集较为简单,使得分类的精度偏高.而西北工业大学的数据集,包含的数据类型较多(10 个),样本集的多样性增加了准确分类的难度,更能层次化地反映出不同算法在多目标的分类效果.

从监督和无监督哈希方法之间对比上来看,两种无监督哈希方法 SH、SGH 的精度较低,甚至连 30% 都不到,这符合了机器学习中无监督方法在没有先验信息时,即使挖掘更多的数据自身的特征也难以有效提升分类精度的结论.而 6 种监督哈希方法的平均分类精度都达到了至少 65% 以上.而且, KSH 方法在 8 字节处的分类精度就已达到了 67.73% 的精度,说明了哈希方法以较少的字节依然能够很好地区分出不同目标类的语义信息. COSDISH 方法在 8 字节处就取得了高于 KSH、SDH 的分类精度,然而,随着哈希码字节数的增多,分类精度的增长却不如其他方法明显,该方法的优点在于,对样本数目不敏感,两个数据集下分类精度随字节增长的幅度相似,代表着这种算法的稳定性很高.

观察表 2 后 4 行的数据可以发现, RIDISH 相对于 SDH 有更大的提升在于 8 字节处就能获得 8 成以上的分类精度,这主要得益于该方法考虑了样本的旋转多样性.而观察 RIDISH 和 RI&SIDISH 的精度可以发现,在加入原数据的缩放样本后,数据的精度反而有所下降(约为 4%).这个现象表明,数据的尺度性会影响到 RIDISH 的分类精度.而本文方法在考察了样本的仿射变换信息后,精度达到了 93.74%,高于 RI&SIDISH 方法的 89.91%,即说明本文方法在不同尺度目标的语义表达的有效性,达到了改进哈希方法对仿射不变性的要求.同时,本文方法在 MAP 等精度上也略高于 RIDISH 方法,表明本文方法继承并发扬了旋转不变哈希在哈希码约束项上改造的优势.

图 3 和图 4 直观地给出了两个数据集下 7 种哈希方法在不同字节数时的 3 种分类精度指标.




Fig.3 The diagram of three precision indexes varied with bits in NWPU VHR-10 dataset

图 3 NWPU VHR-10 数据集的 3 个精度指标随字节变化示意图

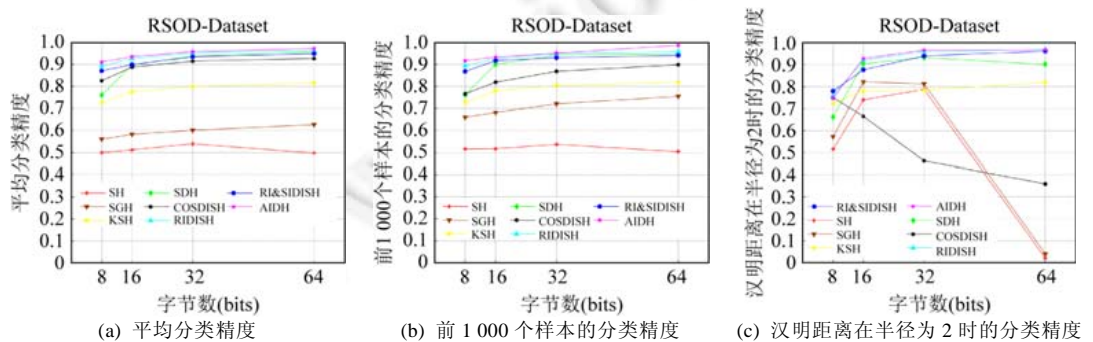


Fig.4 The diagram of three precision indexes varied with bits in RSOD-Dataset

图 4 RSOD-Dataset 数据集的 3 个精度指标随字节变化示意图

不难看出,SH、SGH 方法的分类精度偏低,32 字节之后精度不再提升甚至会有所下降,尤其是汉明半径在 2

以内的分类精度在 64 字节处极低,表明汉明半径以 2 为测度时加入进了过多的误判样本.而 KSH、COSDISH、SDH 则高于两种无监督哈希方法,这一方面得益于类标签信息的引入,另一方面则是核学习方法的优势.然而,这两种方法在 8 字节处的精度还是偏低于后 3 种方法,毕竟字节数过少难以准确地表达出样本的特征.而 RISDH、RI&SIDISH 和本文方法在各字节下均保持着较高的精度,而且分类效果相对稳定,这主要得益于样本集扩充和算法的有效性,以样本点的成倍增加弥补了特征维数低的不足.

表 5 给出了两个数据集中不同哈希方法在 32 字节下,各目标的分类精度以及总体分类精度(MAP).从纵向对比可以看到,NWPU VHR-10 数据集在飞机、油桶、车辆等小目标的分类精度上均较高,而篮球场、桥梁、足球场等大目标的精度则偏低.这种现象的出现原因有两个:(1) 小目标的分辨率都较高,辨识度高,降低了分类的难度;反之,大目标覆盖范围广,分辨率较低,又包含了很多有用信息,无形中提高了分类的难度.(2) 从数据集的构成上看,小目标的样本数较多,而大目标的样本数较少.这一点无疑更加重要,从“网球场”这一类来看,同样是大目标数据,在样本数足够多的情况下依然取得了不错的效果.同样地,对于 RSOD-Dataset 而言,立交桥和操场的分类精度要低于飞机和油桶.而从横向对比不同方法在各目标分类精度的结果来看,本文方法虽然在个别目标类的分类精度与 RIDISH 不相上下(表格中加粗显示),但是,整体分类精度的提高,尤其是篮球场和桥梁两个“短板”精度上的提高,反映出仿射不变离散哈希在多目标分类上的优势.

Table 5 AP and MAP of different hashing methods in 32 bits

表 5 不同哈希方法在 32 字节下各目标的分类精度和总体分类精度

数据集	方法	谱哈希	可扩展图哈希	核监督哈希	采样监督离散哈希	监督离散哈希	旋转不变离散哈希	旋转&尺度不变离散哈希	仿射不变离散哈希
NWPU VHR-10	飞机	0.267 9	0.337 3	0.931 1	0.896 5	0.976 0	0.980 4	0.969 9	0.975 3
	轮船	0.149 2	0.194 7	0.493 3	0.712 9	0.841 0	0.866 1	0.826 0	0.869 4
	油桶	0.382 9	0.503 2	0.975 5	0.970 2	0.991 6	0.993 8	0.985 3	0.990 4
	棒球场	0.204 7	0.242 6	0.702 4	0.833 7	0.918 9	0.910 2	0.911 4	0.947 6
	网球场	0.226 4	0.309 1	0.845 2	0.905 4	0.958 5	0.976 7	0.950 4	0.971 9
	篮球场	0.064 1	0.097 5	0.185 3	0.435 1	0.677 6	0.592 7	0.527 0	0.606 9
	足球场	0.078 5	0.184 3	0.472 0	0.677 8	0.777 5	0.874 7	0.774 0	0.863 5
	港口	0.102 1	0.140 6	0.214 0	0.672 8	0.834 4	0.872 4	0.799 5	0.860 8
	桥梁	0.053 3	0.087 4	0.172 4	0.364 9	0.463 1	0.656 0	0.603 2	0.716 7
	车辆	0.222 6	0.251 2	0.819 4	0.848 1	0.950 7	0.921 6	0.916 6	0.941 6
MAP	0.226 8	0.293 6	0.735 7	0.823 7	0.910 1	0.920 5	0.896 4	0.926 3	
RSOD-Dataset	飞机	0.565 4	0.714 8	0.898 7	0.884 2	0.998 3	0.998 7	0.997 2	0.997 5
	油桶	0.593 2	0.630 0	0.870 5	0.971 9	0.979 6	0.986 5	0.982 6	0.987 4
	立交桥	0.381 9	0.329 5	0.589 2	0.838 3	0.887 5	0.860 5	0.846 7	0.844 1
	操场	0.444 5	0.419 8	0.468 1	0.918 8	0.642 3	0.741 3	0.656 3	0.823 7
	MAP	0.538 6	0.600 0	0.800 1	0.915 0	0.938 9	0.952 9	0.935 4	0.959 0

最后,我们给出各参数对本文方法的影响.AIDH 主要有 3 个参数(R 、 S 、 m),分别是旋转系数、缩放系数以及锚点数.下面通过变化其中一个参数、固定另外两个参数来分析各参数对算法精度的影响.旋转系数对算法的影响是以旋转间隔角的变化来体现的,通过变换旋转间隔角以分析其对分类精度的影响.缩放系数方面,可以通过缩放尺度变化以分析其对分类精度的影响.而锚点数,则通过增加哈希模型中改变锚点的个数来分析其对分类精度的影响.下面以 NWPU VHR-10 为例,图 5 给出了本文方法在哈希码为 8 字节、32 字节时 MAP 随参数变化的影响情况,其中旋转间隔角以 15、30、45、90、180、360 完成实验;缩放比例按照 0.75、0.5、0.25、(0.5,0.75)、(0.25,0.75)、(0.25,0.5)作对比(不作旋转);锚点数则给出了 500、1 000、1 500、2 000、4 000 个锚点作为对比参数.

图 5 所示实验结果表明,当算法的 3 个参数在 32 字节时对 MAP 的提升幅度小于 8 字节时,其中不同字节下锚点数的增长对算法的精度都有稳定性提升,这是来源于 SDH 方法引入嵌入学习对算法精度提升的效果.在 8 字节时,随着旋转间隔角的减小,算法的精度不断提升,直至 15°后($R=12$)趋于平稳;而在缩放系数方面,在 0.5 和 0.75 这两个尺度下,达到算法精度的极值点;当缩放系数小于 0.5 时,算法精度则有所降低.为此,本文选取(0.5, 0.75)两个尺度相结合作为缩放系数;而从锚点数的影响上来看,当锚点数小于 2 000 时,随着锚点数的增加,分类

精度稳步提升,而大于 2 000 后,分类精度则基本不发生变化,因此实验中选取 2 000 作为锚点数.从定量上来看,锚点数可以对分类精度带来 10%~15%的稳步提升,而旋转系数和缩放系数在 8 字节下对算法精度影响更大,有 5%~10%的提升.分析这种现象的原因在于,本文算法能够在低字节下更充分地挖掘样本信息并做出更有效的哈希码表达,而随着字节数的增大,哈希码承载的维度越高,表达信息就越多,算法的优势也就不再明显,从而 MAP 的提升有限.




Fig.5 MAP of the proposed method affected by the parameter in 8, 32 bits

图 5 在 8 字节、32 字节下本文方法参数变化对 MAP 的影响

3.2.2 不同分类器方法的性能对比

为了验证仿射不变哈希方法在分类方法上的优越性,本文选取了 K -NN^[12]、RF^[13]、SVM^[14]、SRC^[15]作为对比方法以验证算法的精度,以 MAP 和运算用时作为评价标准.表 6 给出几种分类方法的对比情况,其中,稀疏表示分类器采用 L1 范数的 L1-SRC 测试,本文方法给出了 32 字节的数据.

Table 6 MAP and time consuming comparison of different classification methods

表 6 不同分类方法的平均分类精度和用时对比

方法	数据集	NWPU VHR-10		RSOD-Dataset	
		平均分类精度	时间(s)	平均分类精度	时间(s)
K 近邻分类法(512-Gist)		0.761 2	23.45	0.854 3	40.61
随机森林(512-Gist)		0.794 5	84.52	0.845 6	185.48
支持向量机(512-Gist)		0.849 3	59.74	0.926 4	112.82
L1 范数稀疏表示(512-Gist)		0.927 0	136.88	0.964 5	295.29
仿射不变离散哈希(32 bits)		0.926 3	8.35	0.959 0	15.13

表 6 给出了 5 种方法在两个数据集下的 MAP 和所用时间对比情况.首先看 MAP 数据,稀疏表示分类器方法的分类精度与本文方法不相上下,而其余的经典分类方法的精度都低于这两种方法;而在 RSOD-Dataset 数据集上,这种精度优势则有所缩小. K 近邻分类方法和 RF 方法精度相近, K -NN 在样本数较多的 RSOD-Dataset 数据集上精度略高于 RF 的算法精度.SVM 方法以其小样本学习的优势具有较好的分类精度,在几种方法中排在中间的位置,换到类别数较少的 RSOD-Dataset 数据集上,也很接近于 SRC 和 AIDH.

再比较一下几种方法运行耗时情况.比较两个数据集后发现,RSOD-Dataset 数据集比 NWPU VHR-10 数据集的用时要多出一倍左右,这是因为 RSOD-Dataset 的样本数比 NWPU VHR-10 的样本数要多出一倍;而各种方法随着样本数的增加,所消耗的时间也随之成倍增加.再比较各分类算法, K -NN 方法虽然精度较低,但是运行时间却是很快的,在 NWPU VHR-10 数据集下只需要 20 多秒即完成了运算,并且两个数据集下都很稳定.综合考虑,在样本数适当提高的情况下, K -NN 方法在效率上是可观的.SVM 和 RF 都是比较耗时的方法,在小数据集上也花去了 1 分钟左右的时间.而在精度上有优势的 L1-SRC 方法,由于算法随样本数增长时运算量过大同时也更占用内存,因而运行时间也增加很多,在大数据集下花掉了将近 5 分钟的时间.本文方法只在式(3)的锚点计算以及式(5)的约束平均项计算上消耗了一点时间,哈希码迭代的次数也仅在 6 次之内完成,而且哈希码的存储单位

只在 32 字位上,因此,算法的运行时间很短,大约是 10s 左右。

此外,再比较几种方法的机器存储类型.几种对比方法的特征都是 512 维的特征,在 RSOD-Dataset 数据集下,它们占用的存储空间达到了 15MB.即使由于仿射变换扩大了数据集构成,32 位的 AIDH 方法的样本存储量也只有 767KB.以 32 位的二值码代替 512 维的浮点型数据,哈希方法的优势是大幅降低算法用时的主要原因。

综上所述,相比于其他几种分类方法,本文方法以其数据存储和编码优化的优势,在较短的运算时间内获得了更高的分类精度。

4 结 论

本文首先回顾了经典分类方法在遥感图像处理中的优势与不足,将兼具低存储和高效性的哈希方法引入到遥感多目标分类领域中.为解决哈希方法在仿射变换数据监测的有效性,构建仿射不变离散哈希模型.通过在监督离散哈希方法中,加入仿射不变项约束,迫使同型号目标分享相同的二值码,增加同类目标哈希码的相似性,实现哈希方法的仿射不变性.为了验证算法的有效性,本文采用 NWPU VHR-10 和 RSOD-Dataset 数据集作为样本库进行了实验.实验中,以 6 种不同的哈希方法以及 4 种不同的分类方法作对比,并以平均分类精度、运算用时等作为定量指标评价.实验结果表明,相比于各对比方法,本文方法改善了几个样本类别数较少的目标类的精度,从而取得了更高的总体分类精度.此外,哈希方法低存储的优势使得本文方法相较于经典分类方法在速度上得到了提升。

References:

- [1] Zhang NJ, Zhang J, Zhang X, Lang HT. Task distribution balancing for parallel two-parameter CFAR ship detection. *Journal of Remote Sensing*, 2016,2:344–351 (in Chinese with English abstract).
- [2] Zhen JX, Fu J, Fu X. Aircraft target recognition in remote sensing images based on distribution of the feature points and invariant moments. *Journal of Image and Graphics*, 2014,4:592–602 (in Chinese with English abstract).
- [3] Chen Z, Ma HC, Zhang L. Cloverleaf interchange boundary extraction from airborne LiDAR data based on advanced neighborhood structure and contour analysis. *Journal of Remote Sensing*, 2013,17(5):1146–1157 (in Chinese with English abstract).
- [4] Cheng G, Han JW, Zhou PC, Guo L. Multi-class geospatial object detection and geographic image classification based on collection of part detectors. *ISPRS Journal of Photogrammetry & Remote Sensing*, 2014,98(1):119–132.
- [5] Cheng G, Zhou PC, Yao XW, Yao C, Zhang YB, Han JW. Object detection in VHR optical remote sensing images via learning rotation-invariant HOG feature. In: *Proc. of the Int'l Workshop on EORSA*. 2016. 433–436.
- [6] Chen XM. The study of disaster target automatic classification based on high-resolution remote sensing images [Ph.D. Thesis]. Beijing: China University of Geosciences, 2016 (in Chinese with English abstract).
- [7] Hou YT, Peng JY, Hao LW, Wang R. Research of classification method for natural images based on adaptive feature-weighted K -nearest neighbors. *Application Research of Computers*, 2014,31(3):957–960 (in Chinese with English abstract).
- [8] Bosch A, Zisserman A, Munoz X. Image classification using random forests and ferns. In: *Proc. of the IEEE Int'l Conf. on Computer Vision*. 2007. 14–21.
- [9] Wu W, Nie JY, Gao GL. Improved SVM multiple classifiers for image annotation. *Computer Engineering & Science*, 2015,37(7): 1338–1343 (in Chinese with English abstract).
- [10] Wright J, Yang AY, Ganesh A, Sastry SS, Ma Y. Robust face recognition via sparse representation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2009,31(2):210–227.
- [11] Zhao LJ, Tang P. Scalability analysis of typical remote sensing data classification methods: A case of remote sensing image scene. *Journal of Remote Sensing*, 2016,20(2):157–171 (in Chinese with English abstract).
- [12] Wang XM, Zhang HL. Hyperspectral remote sensing image classification using geodesic-based KNN. *Journal of Shanxi Coalmining Administrators College*, 2013,26(4):135–137 (in Chinese with English abstract).
- [13] Pal M. Random forest classifier for remote sensing classification. *Int'l Journal of Remote Sensing*, 2005,26(1):217–222.
- [14] Zhao CH, Liu W, Xu Y, Wen JH. A spectral-spatial SVM-based multi-layer learning algorithm for hyperspectral image classification. *Remote Sensing Letters*, 2018,9(3):218–227.

- [15] Wu SL, Chen HD, Bai Y, Zhu GK. A remote sensing image classification method based on sparse representation. *Multimedia Tools and Applications*, 2016,75(19):12137–12154.
- [16] Bulley H, Bishop MP, Shroder JF. Integration of classification tree analyses and spatial metrics to assess changes in supraglacial lakes in the Karakoram Himalaya. *Int'l Journal of Remote Sensing*, 2012,34(2):387–411.
- [17] Sisodia PS, Tiwari V, Kumar A. Analysis of supervised maximum likelihood classification for remote sensing image. In: *Recent Advances & Innovations in Engineering*. 2014. 1–4.
- [18] Cheng G, Zhou PC, Han JW. Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images. *IEEE Trans. on Geoscience and Remote Sensing*, 2016,54(12):7405–7415.
- [19] Meher Sk. Knowledge-encoded granular neural networks for hyperspectral remote sensing image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015,8(6):2439–2446.
- [20] Wang JD, Shen HT, Song JK, Ji JQ. Hashing for similarity search: A survey. *Computer Science*, 2014, 1–29.
- [21] Gionis A, Indyk P, Motwani R. Similarity search in high dimensions via hashing. In: *Proc. of the 25th VLDB Conf.* 1999,8(2): 518–529.
- [22] Weiss Y, Torralba A, Fergus R. Spectral hashing. In: *Proc. of the Int'l Conf. on Neural Information Processing Systems (NIPS)*. 2008,282(3):1753–1760.
- [23] Jiang QY, Li WJ. Scalable graph hashing with feature transformation. In: *Proc. of the Int'l Conf. on Artificial Intelligence (ICAI)*. 2015,9(3):2248–2254.
- [24] Shen FM, Shen CH, Shi QF, Hengel AVD, Tang ZM. Inductive hashing on manifolds. In: *Proc. of the Computer Vision and Pattern Recognition (CVPR)*. 2013. 1562–1569.
- [25] Liu W, Wang J, Ji RR, *et al.* Supervised hashing with kernels. In: *Proc. of the Computer Vision and Pattern Recognition (CVPR)*. 2012. 2074–2081.
- [26] Norouzi M, Blei DM. Minimal loss hashing for compact binary codes. In: *Proc. of the Int'l Conf. on Machine Learning (ICML)*. 2011. 353–360.
- [27] Shen FM, Shen CH, Liu W, Shen HT. Supervised discrete hashing. In: *Proc. of the Computer Vision and Pattern Recognition (CVPR)*. 2015. 37–45.
- [28] Kang WC, Li WJ, Zhou ZH. Column sampling based discrete supervised hashing. In: *American Association for Artificial Intelligence (AAAI)*. 2016. http://cs.nju.edu.cn/lwj/paper/AAAI16_COSDISH.pdf
- [29] Xu H, Liu YZ, Sun QS. Object classification of remote sensing images based on rotation-invariant discrete hashing. In: *Proc. of the Pacific RIM Conf. on Multimedia*. 2017. 264–274.
- [30] Shen XB. Study of multi-view embedding learning techniques with applications [Ph.D. Thesis]. Nanjing: Nanjing University of Science and Technology, 2017 (in Chinese with English abstract).
- [31] Tang T. Affine invariant feature and its application to target recognition in remote sensing images [Ph.D. Thesis]. Changsha: National University of Defense Technology, 2006 (in Chinese with English abstract).
- [32] Wang FG, Feng XC, Zhang XB. Stationary wavelet transform for affine invariant image object recognition. *Computer Engineering and Applications*, 2007,43(21):239–241 (in Chinese with English abstract).
- [33] Zhang JY, Chen Q, Bai XJ, Sun QS, Xia DS. Affine invariant feature extraction algorithm based on generalized canonical correlation analysis. *Journal of Electronics & Information Technology*, 2009,31(10):2465–2469 (in Chinese with English abstract).
- [34] Gao F, Wen XJ. A new method for affine invariants extraction based on affine geometry. *Journal of Image and Graphics*, 2011, 16(3):389–397 (in Chinese with English abstract).
- [35] Kong J, Sun QS, Ji ZX, Liu YZ. A novel fast object detection method in remote sensing image based on affine-invariant supervised discrete hashing. *Journal of Nanjing University Natural Science*, 2019,55(1):49–60 (in Chinese with English abstract).
- [36] Long Y, Gong YP, Xiao ZF, Liu Q. Accurate object localization in remote sensing images based on convolutional neural networks. *IEEE Trans. on Geosciences and Remote Sensing*, 2017,55(5):2486–2498.
- [37] Liu J, Guo J, He ZL. Scene classification based on gist and PHOG feature. *Computer Engineering*, 2015,41(4):232–235 (in Chinese with English abstract).

附中文参考文献:

- [1] 张临杰,张杰,张晰,郎海涛.任务分配均衡的双参数 CFAR 舰船检测并行算法.遥感学报,2016,2:344-351.
- [2] 曾接贤,付俊,符祥.特征点和不变矩结合的遥感图像飞机目标识别.中国图像图形学报,2014,4:592-602.
- [3] 陈卓,马洪超,张良.改进邻域结构与轮廓分析的 LiDAR 点云立交桥提取.遥感学报,2013,17(5):1146-1157.
- [6] 程希萌.基于高分遥感影像的灾害目标自动分类技术[博士学位论文].北京:中国地质大学,2016.
- [7] 侯玉婷,彭进业,郝露微,王瑞.基于 KNN 的特征自适应加权自然图像分类研究.计算机应用研究,2014,31(3):957-960.
- [9] 吴伟,聂建云,高光米.一种基于改进的支持向量机多分类器图像标方法.计算机工程与科学,2015,37(7):1338-1343.
- [11] 赵理君,唐姆.典型遥感数据分类方法的适用性分析——以遥感图像场景分类为例.遥感学报,2016,20(2):157-171.
- [12] 王小美,张红利.基于测地距离的 KNN 高光谱遥感图像分类.山西煤炭管理干部学院学报,2013,26(4):135-137.
- [30] 沈肖波.多视图嵌入学习方法及其应用研究[博士学位论文].南京:南京理工大学,2017.
- [31] 唐涛.图像仿射不变特征及其在遥感图像目标识别中的应用[博士学位论文].长沙:国防科技大学,2006.
- [32] 王凤国,冯象初,张小波.平稳小波变换在仿射不变性目标识别中的应用.计算机工程与应用,2007,43(21):239-241.
- [33] 张洁玉,陈强,白小晶,孙权森,夏德深.基于广义典型相关分析的仿射不变特征提取方法.电子与信息学报,2009,31(10):2465-2469.
- [34] 高峰,文项坚.利用仿射几何的仿射不变特征提取方法.中国图像图形学报,2011,16(3):389-397.
- [35] 孔颖,孙权森,纪则轩,刘亚洲.基于仿射不变离散哈希的遥感图像快速目标检测新方法.南京大学学报(自然科学),2019,55(1):49-60.
- [37] 刘静,郭建,贺遵亮.基于 Gist 和 PHOG 特征的场景分类.计算机工程,2015,41(4):232-235.



孔颖(1985—),男,安徽舒城人,硕士,主要研究领域为遥感图像处理,机器学习与应用.



刘亚洲(1979—),男,博士,副教授,主要研究领域为计算机视觉,模式识别.



孙权森(1963—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为模式识别,机器学习,遥感信息处理.



纪则轩(1984—),男,博士,副教授,CCF 专业会员,主要研究领域为模式识别,图像处理,医学影像学.



徐晖(1992—),女,硕士,主要研究领域为模式识别,图像处理.