

基于扩展 CENTRIST 的遥感场景分类

马 瑾¹ 袁宝华^{1*} 王 欢²

¹(南京理工大学泰州科技学院计算机科学与工程学院 江苏 泰州 225300)

²(南京理工大学计算机科学与工程学院 江苏 南京 210094)

摘 要 提出一种基于扩展 CENTRIST 纹理算子的遥感场景分类方法。它由更多邻域规模的三个子方案组成,不仅继承了 CENTRIST 的优点,而且编码了更多不同纹理的局部结构信息。通过三种不同模式的纹理算子来提取多通道图像纹理特征,通过谱回归判别分析进行分类识别。提出能够捕获多通道图像中互补信息的多通道 eCT 融合机制,以获得更高的分类准确率。在 UC Merced 标准数据库上的实验表明,该方法得到的结果比 CENTRIST 效果更好,鲁棒性更高。

关键词 场景分类 CENTRIST 扩展 CENTRIST 多通道描述符 谱回归判别分析

中图分类号 TP391.41

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2021.02.022

REMOTE SENSING SCENE CLASSIFICATION BASED ON EXTENDED CENTRIST

Ma Jin¹ Yuan Baohua^{1*} Wang Huan²

¹(School of Computer Science and Engineering, Taizhou Institute of Sci. & Tech., NJUST., Taizhou 225300, Jiangsu, China)

²(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, Jiangsu, China)

Abstract This paper presents a remote sensing scene classification method based on extended CENTRIST (eCT) texture operator. It consists of three sub-schemes with more neighborhood sizes, and it not only inherits the advantages of CENTRIST, but also encodes the local structure information of more different textures. This method extracted multi-channel image texture features by three different patterns of texture operators, and then used spectral regression discriminant analysis for classification and recognition. In order to obtain higher classification accuracy, a multi-channel eCT fusion mechanism was proposed, which could capture the complementary information in multi-channel images. The experimental results on UC Merced database show that the results obtained by this method are better than CENTRIST, and the robustness is higher.

Keywords Scene classification CENTRIST Extended CENTRIST Multi-channel descriptor Spectral regression discriminant analysis

0 引 言

随着各种卫星传感器的不断发展,获取高分辨率遥感图像数据变得越来越容易,这些高分辨率遥感图像通常具有丰富的空间布局信息和纹理结构,这对识别不同的土地利用场景类别有很大帮助。根据一组语义类别对场景图像进行分类是一个非常具有挑战性的问题,因为给定类别的土地覆盖特征可能表现出很大

的变化,并且物体可能出现在不同的尺度和方向上。

CENTRIST 作为一种描述局部纹理结构的特征,已经在纹理分类、图像检索和人脸图像分析等领域被广泛应用^[1-8]。Chu 等^[8]设计了彩色 CENTRIST (eCENTRIST)描述符,将颜色信息嵌入到 CENTRIST 的框架中,提升了对彩色信息的获取能力。Xiao 等^[7]提出了一种多通道 CENTRIST (mCENTRIST)描述符,用于多通道图像的不同通道互补信息的获取。由于 CENTRIST 中仅涉及局部区域中像素的符号分量,

Meng 等^[5]提出将局部区域像素的差异数值分量和符号分量两个部分,共同组合成局部差分二值模式(LD-BP)。大量研究表明具有几何和光度变换不变性的局部描述符在遥感场景分类中是有效的^[9-11]。近年来,Chen 等^[10]提出多尺度的完整局部二值模式(Multi-scale Completed Local Binary Patterns, MS-CLBP),从多分辨率遥感图像中获得纹理特征,提高场景识别精度;文献[11]提出基于局部二值模式(Local Binary Pattern, LBP)和局部相位量化(Local Phase Quantization, LPQ)描述符的组合对高分辨率遥感图像的纹理进行表征,并将其应用到土地覆盖分类中。

考虑到 CENTRIST 描述符的邻域仅为 3×3 ,邻域像素个数仅为 8 个,限制了其对空间特征的表达力,因此本文提出一种扩展 CENTRIST(eCT)纹理描述符进行高分辨率遥感场景的识别方法。该描述符由三种不同模式的算子构成,扩展了更大的空间区域,能够获取不同结构的纹理特征。该算子易于实现,无须调整参数并且可以快速运行。通过将三种子模式的算子提取的特征进行融合,形成图像最终的特征向量,然后通过谱回归判别分析进行分类识别。同时为了挖掘不同通道的图像信息,提出一种多通道的扩展 CENTRIST 融合机制(meCT),可以充分利用多通道信息互补的优势,获取图像的不同通道的纹理特征,提高分类结果的准确性。

1 相关知识

1.1 CENTRIST 算子

CENTRIST 是对图像进行 Census 变换的直方图特征,它能够表征图像的局部和全局信息。Census 变换表示 3×3 区域的中心像素及其八邻域像素灰度值之间的大小关系^[4]。将邻域的像素灰度值与中心像素灰度值进行阈值化操作,顺时针方向得到二进制数,最后将其转换为十进制数来作为该像素的 Census 值,如图 1 所示。




图 1 Census 变换

通过图像的单次扫描就能完成 Census 变换的计算,是一种非参数变换。它是一种邻域与中心对比度的映射关系。假定中心像素为 (x_c, y_c) ,则 Census 变换表示为:

$$CT = \sum_{p=0}^{p-1} s(g_c - g_p) \quad (1)$$

式中: g_c 代表区域中心像素的灰度值; g_p 代表区域周围像素的灰度值。 $s(x)$ 函数定义如下:

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2)$$

这些 Census 变换值的统计直方图就形成了该图像的 CENTRIST 特征。

1.2 谱回归判别分析

当样本的个数远大于类别数时, LDA 无法进行求解,为了避免特征分解问题, Cai 等^[12]提出了谱回归判别分析算法,将 LDA 统一到图嵌入框架中求解。SRDA 通过式(3)、式(4)求解。

$$W\mathbf{y} = \lambda\mathbf{y} \quad (3)$$

$$\bar{X}^T \mathbf{a} = \mathbf{y} \quad (4)$$

式中: \bar{X} 是中心化数据集; \mathbf{y} 为训练样本的低维嵌入特征; \mathbf{a} 是相对应的投影向量; W 为描述训练样本间关系的相似度矩阵。SRDA 等价于传统的 LDA。

求解式(3)得到 \mathbf{y} , 找到能够满足式(4)的 \mathbf{a} 。

$$\mathbf{a} = \operatorname{argmax} \sum_{i=1}^m (\mathbf{a}^T x_i - y_i) \quad (5)$$

式中: y_i 是 \mathbf{y} 的第 i 个元素。

当训练样本个数大于样本维数时,通过式(6)求解。

$$\mathbf{a} = (\bar{X} \bar{X}^T + \varepsilon \mathbf{I})^{-1} \bar{X} \mathbf{y} \quad (6)$$

式中: $\varepsilon \geq 0$ 为正则化因子; \mathbf{I} 为单位矩阵。

反之,如果样本个数小于样本维数时,则通过式(7)求解。

$$\mathbf{a} = \bar{X}^T (\bar{X}^T \bar{X} + \varepsilon \mathbf{I})^{-1} \mathbf{y} \quad (7)$$

通常先对 $\bar{X} \bar{X}^T + \varepsilon \mathbf{I}$ 采用 Cholesky 分解得到:

$$\bar{X} \bar{X}^T + \varepsilon \mathbf{I} = \mathbf{L} \mathbf{L}^T \quad (8)$$

式中: \mathbf{L} 为上三角矩阵。假设 SRDA 的投影矩阵为 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d] \in \mathbf{R}^{n \times d}$, 通过变换 $\mathbf{z}_i = \mathbf{A}^T x_i$, 从而使 \mathbf{X} 向量的投影到低维空间 $\mathbf{Z} \in \mathbf{R}^d (d \ll n)$ 。

2 基于扩展 CENTRIST 的场景分类算法

2.1 eCT 算子

CENTRIST 进行图像分类主要依赖于 Census 变换,而 Census 变换仅仅在 3×3 的邻域上进行运算,如此小的空间尺度区域影响其表达能力,因此需提高其

空间尺度,获取更大区域的信息,从而提升 Census 变换的表达能力。

将邻域尺寸扩大到 5 × 5,其邻域像素的个数增加到 24 个,如果按照基本 Census 变换会产生 24 位二进制,转换成十进制则大小范围是[0,2²⁴]。在实际应用中,CENTRIST 的维度将过大,通常是不可接受的。如何既能获取到更多的区域信息,又不增加 CENTRIST 的维度,成为一种挑战。为此,提出扩展的 CENTRIST 算子,其基本思想就是将 5 × 5 区域的 Census 分割成 3 个不同结构的区域,每个区域通过变换的 Census 进行表示,如图 2 所示,每个区域的纹理表示为一种子模式。




图 2 扩展 CENTRIST 的三个不同子模式

将 5 × 5 的区域分成图中所示不同的子模式,每种子模式的结构不同,能够表示不同形式的纹理信息。而三个子模式的像素均为 8 个,这样就能转换到基本的 Census 变换。通过这样的分割,原先 CENTRIST 的维度 2²⁴,就分解为 3 × 2⁸,维度大大减少,即扩展了更大的区域,而维度又没有显著增加。eCT 与 CENTRIST 的不同点在于:(1) 邻域范围不同,eCT 邻域范围更大,大小为 5 × 5,而 CENTRIST 邻域大小为 3 × 3;(2) eCT 三种子模式的结构分别呈现十字形、交叉形、圆形,能够获取不同结构的纹理特征,而 CENTRIST 的结构固定,类似于正方形边缘;(3) eCT 特征维数是 CENTRIST 的三倍。

2.2 meCT 算子

相比于灰度图像,彩色图像包含更多的信息,为了更好地挖掘不同通道信息,提出 meCT 算子。

多通道扩展 Census 变换金字塔包含两层,第 0 层 eCT 被分解为第一层的 3 种子模式 Sub-eCT。每个子模式 Sub-eCT 包括 8 个像素,用阿拉伯数字标号,如图

3 所示。假设 eCT_iⁿ 表示第 n 个通道第 i 个子模式 eCT 中的第 p 部分,p = 1,2,i = 1,2,3。

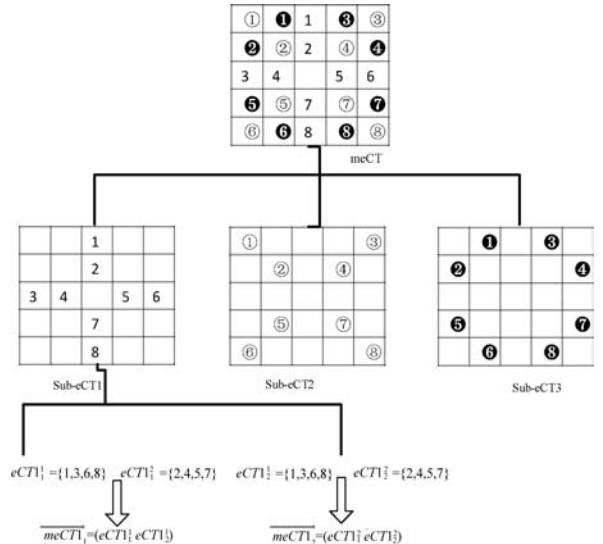
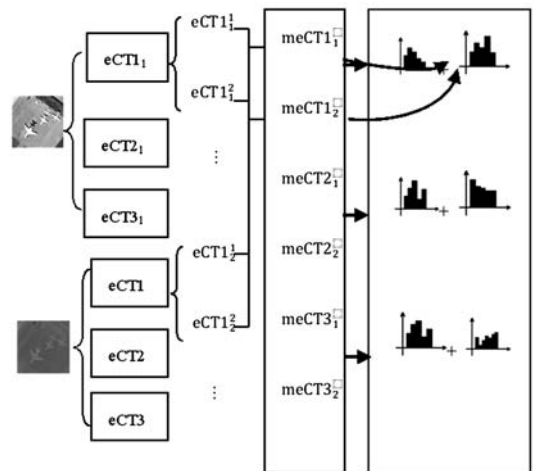


图 3 多通道的扩展 Census 变换金字塔

第一个子模式第一个通道的 eCT 表示为 eCT₁¹ = {1,3,6,8}, eCT₁² = {2,4,5,7},第二个通道则分别为 eCT₂¹ = {1,3,6,8}, eCT₂² = {2,4,5,7}。两个通道的第一个子模式的融合,则表示为:

$$\begin{aligned} \overrightarrow{meCT1_1} &= (eCT1_1^1 eCT1_2^1) \\ \overrightarrow{meCT1_2} &= (eCT1_1^2 eCT1_2^2) \end{aligned}$$

通过这样的方式,融合两个通道的子模式 meCT1。按照相同的方式,融合第二个子模式 meCT2 和第三个子模式 meCT3,然后将三个子模式的直方图串接成 meCT 直方图。为了降低多通道的特征维数,后续采用降维(例如:PCA)操作。meCT 特征的提取过程如图 4 所示。



(a) 图像不同通道 (b) 从不同通道提取 (c) 三种通道的子模式特征分别融合成 meCT 直方图

图 4 meCT 特征提取

meCT 遥感场景分类算法的主要流程,如图 5 所示。首先将输入图像分解成多通道图像,每个通道表征不同的图像信息;然后通过金字塔匹配核将图像不

断细化成相同大小的图像块,获得图像的多尺度信息;利用 eCT 算子获得每个图像块直方图特征,按照 meCT 方式形成最终的图像全局特征;最后利用分类器进行分类识别。

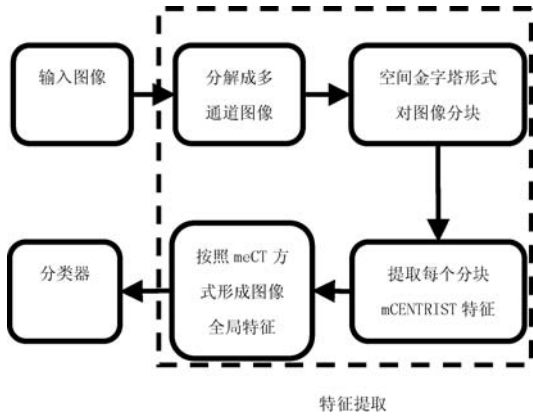


图 5 meCENTRIST 遥感场景分类的主要流程

3 实验

为了验证基于 eCT 遥感场景特征表达方法的有效性,本节在 UC Merced 标准遥感图像库进行场景分类实验。实验比较了 eCT 三种子模式的分类性能,表明三种模式的特征互补性。实验验证多通道下的 meCT 的分类性能并与现有的具有较高分类性能的场景分类方法进行了比较。另外,实验从训练时间、分类效果上比较了 SR-KDA 和 SVM 分类器的性能。

3.1 UC Merced 数据库

UC Merced 数据集是常用的高分辨率遥感图像公共数据集,被广大研究者普遍接受,其共有 2 100 幅图像,分为 21 个场景类别,每个类别有 100 幅图像,每幅图像大小为 256 × 256。图 6 为 UC Merced 部分示例图。

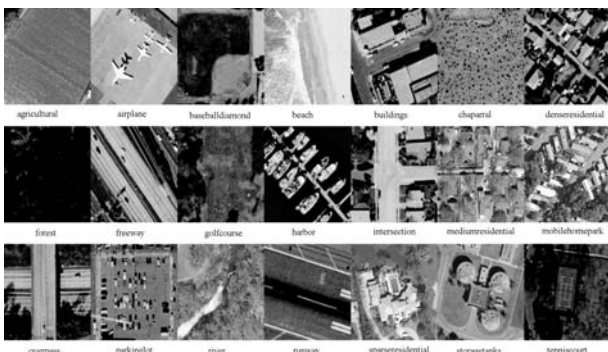


图 6 UC Merced 数据集示例图

3.2 实验设置

实验中采用从数据集中随机选择训练和测试样本集,将每类 100 幅图像分为五等份,四份作为训练样本,其余的作为测试样本。实验中采用 5 次交叉验证

方法,所有实验的识别率的平均值作为最后的分类性能。实验中采用空间金字塔模型如 2.2 节所述。

为了评估提出的 eCT 算子的有效性,将其与另外两个算子进行比较。一个是 CENTRIST;另一个是 LD-BP^[5],是 CT 的扩展版本,采用了符号和幅度信息。此外还比较了不同分类器对于实验的影响。在 SR-KDA 分类器中采用多项式核函数,参数 $d = 9$,L2 正则参数设为 0.001。SVM 分类器采用公开的机器学习包 (LIBSVM)^[6]。SR-KDA 则采用公开的谱回归判别分析包。实验环境如下:15 Quadcore (3.1 GHz),内存 8 GB, MATLAB 编程环境。

为了评估 meCT 的性能,比较了 5 个多通道描述符:(1) mCENTRIST^[7],场景分类中的多通道的特征生成机制。(2) cCENTRIST^[8],一种适用于 HSV 颜色空间的扩展 CENTRIST。(3) mGISTs^[13],直接从多通道获取场景的串联 GIST 特征。(4) mSIFT^[13],从多通道直接串联 SIFT 特征。(5) msSIFT^[14],从多通道串联 SIFT 特征,后续通过 PCA 降维处理。

3.3 实验分析

3.3.1 eCT 有效性

为了验证 eCT 描述符的有效性,首先验证分别采用三个独立的子模式描述符进行遥感场景分类识别实验。实验表明三种不同的子模式能够获取不同的区域信息,三种独立子模式分别为 sub-eCT1、sub-eCT2 和 sub-eCT3,分类器采用 SR-KDA。UC Merced 数据集中图像是彩色图像,首先将图像的颜色空间进行转换 RGB → YCbCr,然后采用 Y 分量(亮度)作为灰度图像。

由表 1 发现 sub-eCT2 相比于其他两个描述符能够获得较好的识别率。图 7 为三种模式的描述符在每类上的识别率。在大多数类上,三种子模式描述符有相似的结果。在“丛林”类上,sub-eCT1 能获得较高的识别率。而在“沙滩”“网球场”“移动家庭公园”“高尔夫球场”sub-eCT2 获得最好的结果。在“建筑物”“中密度住宅区”“停车场”“河流”类中,sub-eCT3 获得最好的结果。每种 sub-eCT 描述符在不同的类别上都各有所长,单纯地依靠其中一个算子并不能在所有类别上都能表现很好。三个子描述符之间相互独立且包含互补信息,因此通过融合这三个特征,能够获得更好的识别率。

表 1 三种子模式的识别率

%

通道	Sub-eCT1	Sub-eCT2	Sub-eCT3
Y	74.67	78.76	77.95




图7 三种子描述符在每个类别上的识别率

3.3.2 与 CENTRIST 和 LDBP 算子的分析比较

在直方图的空间金字塔中,从三个不同的层次级别上描述了场景:eCT 包含关于像素级别的信息;区域直方图产生区域级的信息;将区域直方图串联以构建场景的全局描述。实验结果见表 2, eCT 能获得比 CENTRIST 和其他算子更高的识别率,达到 84.52%。这也进一步表明,eCT 算子相比其他算子能够获得更多的纹理特征,从而获得较好的识别效果。采用 SR-KDA 分类器相比 SVM,识别率能够提高 3 个百分点。

表 2 不同算子分类性能的比较 %

通道	分类器	CENTRIST	LDBP	eCT
Y	SR-KDA	82.14	83.21	84.52
	SVM	77.00	79.30	81.52

CENTRIST 和 eCT 的每类识别率如图 8 所示。在大多数类中,eCT 能够获得比 CENTRIST 更高的识别率。




图 8 CENTRIST 和 eCENTRIST 在每个类别上的识别率

3.3.3 meCT 有效性

本节实验设置采用与文献[8-9]中相同的设置保证实验的公平性。如表 3 所示,meCT 在多通道情况下都能够获得最好的识别率。通过增加通道信息,能够提高分类性能,这是因为通道的增多必然能够从更多的角度去获取场景特征。实验结果表明,由于 eCT 算子能够获得丰富的纹理特征,同样在多通道的融合中,meCT 也能在不同的通道信息融合过程中获得不同通道互补的纹理信息,融合后其效果比其他算子表现

更好。

表 3 不同多通道描述符在 UC Merced 数据集上的分类结果 %

Channels	mCENTRIST	mSIFT	msSIFT	mGIST	meCT
O1O2O3	87.3	83.6	80.0	63.0	87.62
O1O2O3S	89.9	85.0	82.2	72.0	91.24
cCENTRIST (HSV)	75.2				

mCT 和 meCT 在每个类别上的识别率如图 9 所示。可以看出 meCT 在 17 个类别中性能优于 mCT,表明多通道的图像对大部分类别的识别率提高是有益的。总体上 meCT 方法能获得较好的结果,特别在沙滩、丛林和森林,这些类别中能够 100% 识别。




图 9 mCENTRIST 和 meCT 在每个类别上的识别率

meCT 的混淆矩阵如图 10 所示,在这些类别对中会有混淆,如建筑物和密集居民区、密集居民区和中密度居民区、建筑物和油罐。除此之外,有些类别有明显的形状特征,比如:建筑物和油罐,将来可以考虑利用这些形状特征来进行识别。




图 10 meCT 在 UC Merced 数据集上的混淆矩阵

不同描述符特征提取的时间如表 4 所示。可以看出,meCT 执行效率要高于 mSIFT、msSIFT 和 mGIST,低于 mCT。在这些方法中,meCT 能够兼顾计算效率和鉴别能力。

表 4 不同的多通道描述符特征提取时间的比较

描述符	时间/ms
mCT	153
mSIFT	1 025
msSIFT	967
mGIST	621
meCT	459

为了验证所提出 meCT 的有效性,将其在 UC Merced数据集上的分类性能与在类似实验设置下文献中报告的方法进行比较(即将每个类别 80% 的图像用作训练,剩余的 20% 图像用作测试)。meCT 模型优于其他方法,如表 5 所示。meCT 的精度比基于 BOW 框架的最好方法(PSR)还高 2 个百分点。使用多尺度 CLBP(MS-CLBP1)描述符^[10]的特征提取方法的精度比 meCT 低 1 个百分点。采用四种图像特征进行融合的方法^[20]精度比 meCT 低 1.7 个百分点。meCT 仅采用 eCT 特征,并且没有融合其他特征,如果考虑更多特征,精度可能会更高。

表 5 不同方法在 UC Merced 数据集上的分类精度 (mean ± SD) 比较

方法	识别率/%
BOVW ^[15]	76.8
SPM ^[15]	75.3
BOVW + spatial co-occurrence kernel ^[15]	77.7
Concentric circle-structure BOVW ^[16]	86.6 ± 0.8
Wavelet BOVW ^[17]	87.4 ± 1.3
Pyramid-of-spatial-relatons ^[18]	89.1
Unsupervised feature learning ^[19]	81.7 ± 1.2
Multifeature concatenation ^[20]	89.5 ± 0.8
CLBP ^[10]	85.5 ± 1.9
MS-CLBP1 ^[10]	90.6 ± 1.4
cCENTRIST(HSV) ^[8]	75.2 ± 2.4
mCENTRIST ^[7]	89.9 ± 1.2
meCT	91.24 ± 0.78

与 UC Merced 数据集中其他方法的对比结果,证明了本文模型对遥感土地利用分类的有效性。这可能是因为遥感场景比自然场景具有更多的规则结构体,并且擅长捕捉场景的结构属性。最重要的是,该方法保留了 CENTRIST 的优点,例如更快的速度和更容易实现。

4 结 语

针对目前 CENTRIST 算子的邻域 3×3 范围较小,不能充分表达主要区域特征,提出一种扩展 CENTRIST 纹理算子用于场景识别的全局图像特征的方法。eCT 由三个独立的子模式运算符组成,三个子模式结构不同,捕获的纹理信息也不相同,它们之间包含补充信息,满足了遥感场景分类所需的特性,实现了较好的分类性能。此外,本文方法保留了 CENTRIST 的优点,易于实现,几乎没有参数可以调整,并且可以快速运行。最后,为了能够从多个通道图像中获得互补信息,提出 meCT 多通道融合机制,相比于传统的多通道串接方法,其能够获得良好的分类性能。

参 考 文 献

- [1] 李云峰,张澎悦. 基于 GLCM 和 Gabor 纹理特征的手势识别算法[J]. 计算机应用与软件,2019,36(7):183-191.
- [2] 薛宾田,张建伟,刘博. 基于 LBP 纹理特征和 Canny 算子的视频分割方法研究[J]. 计算机应用与软件,2019,36(5):112-118.
- [3] 冯丽琦,赵亚琴,孙一超,等. 一种基于多尺度局部纹理特征和 CART 决策树的野外火灾火焰图像识别算法[J]. 计算机应用与软件,2019,36(5):194-198.
- [4] Wu J, Rehg J M. CENTRIST: A visual descriptor for scene categorization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2011,33(8):1489-1501.
- [5] Meng X, Wang Z, Wu L. Building global image features for scene recognition[J]. Pattern Recognition,2012,45(1):373-380.
- [6] Chang C C, Lin C J. LIBSVM: A library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology (TIST),2011,2(3):27.
- [7] Xiao Y, Wu J, Yuan J. mCENTRIST: A multi-channel feature generation mechanism for scene categorization[J]. IEEE Transactions on Image Processing,2014,23(2):823-836.
- [8] Chu W T, Chen C H, Hsu H N. Color CENTRIST: Embedding color information in scene categorization[J]. Journal of Visual Communication and Image Representation,2014,25(5):840-854.
- [9] Ahmad S, Cheong L F. Robust detection and affine rectification of planar homogeneous texture for scene understanding[J]. International Journal of Computer Vision,2018,126(8):822-854.
- [10] Chen C, Zhang B, Su H, et al. Land-use scene classification using multi-scale completed local binary patterns[J]. Signal, Image and Video Processing,2016,10(4):745-752.

- [17] 陈江昀. 一种基于深度学习的新型小目标检测方法[J]. 计算机应用与软件, 2017, 34(10): 227-231, 247.
- [18] Zhang J, He L, Karkee M, et al. Branch detection with apple trees trained in fruiting wall architecture using stereo vision and regions-convolutional neural network (R-CNN) [C]//ASABE Annual International Meeting. Spokane; American Society of Agricultural and Biological Engineers, 2017: 2-11.
- [19] Shah U, Khawad R, Krishna K M. Detecting, localizing, and recognizing trees with a monocular MAV: Towards preventing deforestation [C]//2017 IEEE International Conference on Robotics and Automation. IEEE, 2017: 1982-1987.
- [20] 陆维娜, 胡瑜, 叶靖, 等. 面向卷积神经网络加速器吞吐量优化的 FPGA 自动化设计方法[J]. 计算机辅助设计与图形学学报, 2018, 30(11): 2164-2173.
- [21] 张洋硕, 苗壮, 王家宝, 等. 基于 Movius 神经计算棒的行人检测方法[J]. 计算机应用, 2019, 39(8): 2230-2234.
- [22] 张雲轲, 刘丹. 基于小型 Zynq SoC 硬件加速的改进 TINY YOLO 实时车辆检测算法实现[J]. 计算机应用, 2019, 39(1): 192-198.
- [23] Rachel H, Jonathan P, Cuixian C. Yolo-LITE: A real-time object detection algorithm optimized for non-gpu computers [EB]. arXiv:1811.05588v1, 2018.

(上接第 113 页)

负责转发流程和四层负载均衡, 服务器负责七层负载均衡, 将原有 F5 负载均衡的能力分布到了交换机与服务器集群中。同时, 还充分利用加密卡、25 Gbit 智能网卡等硬件设备的加速特性以提升整体集群的性能。

参 考 文 献

- [1] 李伟. 银行业金融机构实施分布式架构的思考[J]. 金融电子化, 2016(12): 19-21.
- [2] 瞿秋平. 分布式架构在证券业信息化建设中的规划思考[J]. 金融电子化, 2016(12): 17-18.
- [3] 王和. 分布式, 未来的必然选项——中国人保财险的思考与实践[J]. 金融电子化, 2016(12): 14-16.
- [4] 柴洪峰. 中国银联专用云的探索与实践[EB/OL]. 第七届中国云计算大会演讲实录. (2015-06-03). <https://www.csdn.net/article/2015-06-03/2824858>.
- [5] McKeown N. Software-defined networking [C]//International Conference on Computer Communications, 2009.
- [6] Bosshart P, Daly D, Gibb G, et al. P4: Programming protocol-independent packet processors [J]. ACM SIGCOMM Computer Communication Review, 2014, 44(3): 87-95.
- [7] Lee J, Miao R, Kim C, et al. Stateful layer-4 load balancing in switching ASICs [C]//SIGCOMM Posters and Demos,

2017: 133-135.

- [8] 徐敏. 从阿里金融云的实践看金融上云的意义和路径[J]. 清华金融评论, 2016(11): 104-106.
- [9] 陈磊. 5.0V—基于 SDN 的腾讯次世代数据中心网络架构[EB/OL]. (2018-01-30). <https://cloud.tencent.com/developer/article/1032288>.
- [10] 闫浩. SDN 网络与传统网络对比分析[EB/OL]. (2017-03-16). <https://www.sdnlab.com/18725.html>.

(上接第 131 页)

- [11] Musci M, Feitosa R Q, Costa G A O P, et al. Assessment of binary coding techniques for texture characterization in remote sensing imagery [J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(6): 1607-1611.
- [12] Cai D, He X, Han J. Speed up kernel discriminant analysis [J]. The VLDB Journal—The International Journal on Very Large Data Bases, 2011, 20(1): 21-33.
- [13] Brown M, Süssstrunk S. Multi-spectral SIFT for scene category recognition [C]//Computer Vision and Pattern Recognition (CVPR), 2011: 177-184.
- [14] Sande K V D, Gevers T, Snoek C. Evaluating color descriptors for object and scene recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1582-1596.
- [15] Yang Y, Newsam S. Bag-of-visual-words and spatial extensions for land-use classification [C]//18th SIGSPATIAL International Conference on Advances in Geographic Information Systems, 2010: 270-279.
- [16] Zhao L J, Tang P, Huo L Z. Land-use scene classification using a concentric circle-structured multiscale bag-of-visual-words model [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(12): 4620-4631.
- [17] Zhao L, Tang P, Huo L. A 2-D wavelet decomposition-based bag-of-visual-words model for land-use scene classification [J]. International Journal of Remote Sensing, 2014, 35(6): 2296-2310.
- [18] Chen S, Tian Y L. Pyramid of spatial relations for scene-level land use classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(4): 1947-1957.
- [19] Cheryadat A M. Unsupervised feature learning for aerial scene classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 439-451.
- [20] Shao W, Yang W, Xia G S, et al. A hierarchical scheme of multiple feature fusion for high-resolution satellite scene categorization [C]//9th International Conference on Computer Vision Systems, 2013: 324-333.