基于 W2ID 准则的 Rich Model 隐写

检测特征选取方法

马媛媛^{1),2)} 徐久成¹⁾ 张祎²⁾ 杨春芳²⁾ 罗向阳^{2,3)}* ¹⁾(河南师范大学 计算机与信息工程学院 河南新乡 453002) ²⁾(中国人民解放军战略支援部队信息工程大学 郑州 450001) ³⁾(数学工程与先进计算国家重点实验室 郑州 450001)

摘 要 数字隐写是信息安全领域一个重要分支,其通过将秘密信息嵌入到数字图像、声音、视频等文件中并通过公开信 道(如: Email 邮箱、微博推文和即时通信等)进行传递,从而实现信息的隐蔽通信。图像自适应隐写是近年来数字隐写技 术的研究热点,而 Rich Model 特征是检测图像自适应隐写的一大类主流高维特征,这类高维特征在实现对图像自适应隐写 较高检测正确率的同时,带来了高额的计算开销和和存储开销,并使得隐写检测中的分类器训练变得极为困难。为此,本文 提出了一种基于加权类间距离和类内距离差异准则(W2ID 准则)的图像 Rich Model 隐写检测特征选取方法(记为 W2ID-α 方法)。首先,在对 Fisher-based 方法这一隐写检测特征经典选取方法进行原理分析的基础上,指出该方法可能存在误删有 用特征分量、保留冗余和冲突特征分量的不足: 然后, 通过将"类内距离差异"原则引入到隐写检测特征分量的可分性度量, 提出了基于类间距离和类内距离差异的特征可分性度量准则(简记为 2ID 准则),给出了类内距离差异的一个相关性质;同 时,为了合理体现"类间距离"的重要性,本文提出了基于频数统计加权法的权重分配算法,为该准则分配合理权重,使得对 特征分量可分性的度量结果相比传统的 Fisher 准则更为准确:最后,依据 W2ID 准则的度量结果,基于决策粗糙集 α-正域 约简方法约简隐写检测特征分量,并在约简特征分量过程中,将每次处理一个特征分量改进为每次处理一组特征分量,以提 升决策粗糙集 α-正域约简的效率。提出的 W2ID-α 方法因无需设置可分性下限,避免了阈值设置不准确可能造成去除有用特 征分量的问题,从而消除了现有 Steganalysis-α 隐写检测特征选取方法依赖经验参数的问题。基于数字隐写领域通用的 BOSSbase-1.01 图像库 10000 幅原始图像和基于经典 SI-UNIWARD 隐写方法生成的多组隐写图像,针对从这些图像组每幅 图像中提取的 35263 维 J+SRM 特征和 17000 维 GFR 特征 (两类典型的图像 Rich Model 隐写检测特征),进行了一系列特征 选取实验,结果表明:本文提出的 W2ID-α方法能够在大幅降低 Rich Model 隐写检测特征维数的同时,基于选取后特征的 隐写检测提高了对隐写图像的检测正确率,与 Fisher-based、Steganalysis-α 和 PCA-based 等现有典型特征选取方法相比具有 显著优势,如对嵌入率为 0.1 的 SI-UNIWARD 隐写图像,基于提出的 W2ID- a 方法将 J+SRM 特征从 35263 维降到 272 维 的同时,还提高了3.63%的检测正确率。

关键词 隐写检测; Rich Model; 特征选取; W2ID 准则; α-正域约简; Fisher-based 方法 中图法分类号 TP391.4

W2ID Criterion-based Rich Model Steganalysis Features Selection

MA Yuanyuan^{1),2)} Xu Jiucheng¹⁾ ZHANG Yi²⁾ YANG Chunfang²⁾ LUO Xiangyang^{2,3)}*

¹⁾(Henan Normal University, Xinxiang, 453002)

²⁾(PLA Strategic Support Force Information Engineering University, Zhengzhou, 450001, China)

²⁾(State Key Laboratory of Mathematical Engineering and Advanced Computing, Zhengzhou, 450001, China)

本课题得到国家自然科学基金(No. U1804263, U1636219, 61772549, 1736214, 61872448), 国家重点研发计划(No.2016YFB0801303, 2016QY01W0105), 河南省科技创新杰出人才项目(No. 184200510018)和河南省科技攻关项目(No. 202102210165)资助.马媛媛, 女, 1981年生, 博士, 讲师, 主要研究方 向为数字隐写分析.E-mail: <u>yuanyuanma821@126.com</u>.徐久成, 男, 1964年生, 博士, 教授, 计算机学会(CCF)会员,主要研究领域为粗糙集、粒计 算.E-mail:<u>xjch3701@sina.com</u>.张祎, 女, 1991年生, 博士研究生, 主要研究方向为图像隐写与分析技术.E-mail: <u>tzyy4001@sina.com</u>.杨春芳, 男, 1983 年生, 博士, 副教授, 主要研究方向为图像隐写与分析技术.E-mail: <u>chunfangyang@126.com</u>.罗向阳(通讯作者), 男, 教授, 博导, 主要研究领域 为网络与信息安全.E-mail: <u>luoxy_ieu@sina.com</u>.

Abstract Digital steganography is an important branch of the information security technology. Digital steganography embeds the secret information into the digital files, which includes image, voice, video and others, and transmits them through public channels (e.g. E-mail, Twitter, Instant messaging, etc.), so as to realize transmitting the information in secret. The image adaptive steganography is a research hotspot in the area of steganography in recent years, while the Rich model steganalysis feature is the mainstream high-dimensional feature for detecting image adaptive steganography. This kind of high dimension steganalysis feature not only achieves high detection accuracy of image adaptive steganography, but also brings the high computational overhead and storage space. Thus, the classifier in steganalysis is very difficult to train. For this reason, this paper proposes a steganalysis feature selection method (W2ID- α) based on the Weight Inter-class Distance and Intra-class distance Difference criterion (W2ID criterion). First, this paper analyzes the principle of the Fisher-based method, which is a classical steganalysis feature selection method. Then, it points out that this method may have the shortcomings of deleting useful feature components, retaining redundant and conflicting feature components by mistake. Second, by introducing the principle of "Intra-class distance Difference" to separability measurement of the steganalysis feature component, this paper proposes a separability measurement criterion based on both Interclasses Distance and Intra-class distance Difference (2ID criterion). The properties of Intra-class aggregation Difference are also given. Meanwhile, in order to highlighting the importance of the "Inter-class Distance", a weight assignment algorithm based on the frequency statistical weighting method is proposed to assign weights to the separability criterion reasonably. This criterion is called W2ID criterion. Thus, the separability result of the steganalysis feature component can be measured by the W2ID criterion more accurate than that of the traditional Fisher criterion. Finally, According to the measurement results based on the W2ID criterion, this method selects the steganalysis feature components based on the decision rough set α -positive region reduction method. In the process of feature component reduction, in order to improve the reduction efficiency, an improved decision rough set α -positive region reduction is proposed. The improved decision rough set α -positive region reduction method, which is deal with one feature component at a time, is changed to deal with one group of feature components at a time. Thus, useful feature components will be remained and the lower limit will not be set, by which the dependency of empirical parameters of the existing Steganalysis-α method can be eliminated. Two kinds of typical Rich Model steaganalysis features (35263-D J+SRM feature and 17000-D GFR feature) are extract from both 10000 original images in the BOSSbase-1.01 image database and multiple groups of stego images generated by classical SI-UNIWARD steganography algorithm. Then, a series of feature selection experiments are carried on the J+SRM feature and the GFR feature. The experimental results show that the proposed W2ID- α method can significantly reduce dimension of Rich Model steaganalysis feature, meanwhile increase the accuracy to detect stego images. Compared with the results of existing typical feature selection methods, i.e. Fisher-based, Steganalysis- α method and PCA-based method, the proposed W2ID- α method has significant advantages. For example, for the stego image with payload 10% generated by SI-UNIWARD steganography, the dimension of J+SRM feature is reduced based on the proposed W2ID- α method from 35263 to 2723, and the detection accuracy is improved by 3.63%.

Key words steganalysis; Rich Model; feature selection; W2ID criterion; α-positive region reduction; Fisher-based method

1 引言

近年来,自适应隐写技术快速发展,对传统隐 写检测方法提出了严峻挑战^{[1][2]}。Rich Model类隐写 检测特征[3][4][5][6]通过提取图像的多类统计属性构建 高维特征,从而刻画隐写图像在信息嵌入前后的失 真,能够有效捕捉到自适应隐写图像在嵌入前后的 细微变化。高维Rich Model隐写检测特征和集成分类 器相结合的方法已经成为当前对自适应隐写检测的 主要手段,对基于HUGO(Highly Undetectable steGO)^[7]、WOW(Wavelet Obtained Weights)^[8]和 SI-UNIWARD (Side-informed Universal Wavelet Relative Distortion)^[9]等自适应隐写得到的图像,都 表现出了较高的检测准确率。然而,尽管Rich Model 特征在检测自适应隐写方面表现出良好的效果,但 这些特征往往高达上万维甚至数万维,给特征提取 以及相应的分类器训练都带来了庞大的计算开销和 存储开销,限制了这类方法的实际应用。如何降低 Rich Model隐写检测特征的维数,从而减少存储空 间、降低计算开销和提高检测效率,已成为自适应 隐写检测中亟待解决的问题之一,本文将聚焦于图 像Rich Model隐写检测特征的选取。

目前,研究者们在隐写检测特征的选取和降维 方面已开展了一些研究。典型的有基于PCA (Principal Component Analysis)的隐写检测特征选 取方法^[10](简记为PCA-based方法)和基于Fisher准 则的隐写检测特征选取方法^[11](简记为Fisher-based 方法)。其中, PCA-based方法^[10]的主要思想是:通 过线性变换将原始的特征变换成一组线性无关的新 的特征分量,对变换后的这组特征进行排序,根据 经验选取前若干个特征(这些被选取的特征被称为 主成分),最后依据主成分对隐写图像进行分类检 测。PCA-based方法能够降低特征的维数并在一定程 度上保持了某些特征对隐写图像的检测准确率,然 而大量实验结果表明利用PCA-based方法对非线性 隐写检测特征降维后,约简后的特征对隐写图像的 检测正确率不高。Fisher-based方法^[11]能在降低这些 隐写检测特征维数的同时还能使检测正确率率高于 PCA方法的检测正确率。其主要思想是: 首先基于 Fisher准则度量特征分量的可分性(即*Fscore*值), 然后根据每个特征分量的Fscore值, 计算出使得特征 子集的Fscore值最大的特征分量,最后根据选取得到 的这些特征分量进行隐写检测。该方法计算简单且 对多种隐写检测特征都有较好的效果,如对于SPAM (Subtractive Pixel Adjacency Matrix) 和 CC-PEV (Cartesian Calibrated feature extracted by PEVný) 特 征都既保持了检测正确率又降低了特征维数,提高 了检测效率。然而, Fisher-based方法未能有效删除 冲突的部分特征分量以及Fscore值较大却是冗余的 特征分量,导致特征维数依然较高。在前期工作中, 我们提出了Steganalysis- α 方法^[12],基于决策粗糙集 α - 正域约简对Rich Model隐写检测特征进行降维,该方 法能够较好地降低高维Rich Model隐写检测特征的 维数。然而,在进一步的研究中我们发现,被 Fisher-based方法和Steganalysis-α方法作为"无用"特 征分量删除掉的特征中,有很多特征分量在嵌入秘 密信息前后具有相同的均值,而事实上,它们中的 一些特征分量对于检测隐写图像具有重要作用,删 除这些特征分量会降低对隐写图像的检测正确率。

针对上述问题,本文提出了一种基于"权重类间 距离与类内聚离差异"准则和决策粗糙集α-正域约简 的Rich Model隐写检测特征选取方法(简记为 W2ID-α方法)。利用"权重类间距离与类内距离差异" 准则度量均值相等的特征分量的可分性,并改进了 决策粗糙集α-正域约简,提出了针对Rich Model隐写 特征的选取方法,在进一步降低隐写检测特征维数 并提高检测正确率的同时,达到提高检测效率和减 少对经验参数依赖的目的。

本文余下部分的安排如下:第2节简要介绍 Fisher-based 方法的优点并分析其原理;第3节阐述 本文提出的基于 W2ID 准则的 Rich Model 隐写检测 特征可分性度量算法;第4节给出基于 W2ID 准则 的 Rich Model 隐写检测特征选取方法;第5节给出 实验结果;最后一节对全文进行总结。

2 Fisher-based 方法原理简介与分析

文献[11]将 Fisher 准则作为启发函数,提出了一种基于 Fisher 准则的隐写检测特征选取方法(简记为 Fisher-based 方法),用于隐写检测特征降维。该方法对 CF(特征函数)矩、共生矩阵等多种传统隐写检测特征的选取具有良好效果,但是在特征分量可分性的度量和冗余与冲突特征分量的删除方面还存在不足。本节对 Fisher-based 方法原理进行简单介绍,并指出该方法在对 Rich Model 特征进行选取时存在的缺陷。

2.1 Fisher-based方法的原理简介

Fisher-based 方法的基础是 Fisher 准则。特征分量的 Fisher 值越大,则该特征分量对不同类别图像的可区分性就越好^[11]。设有两类图像集 $X_c \ n X_s$,从中分别提取相应的特征集设为 $\mathbf{F}^{\mathbf{C}} \mathbf{n} \mathbf{F}^{\mathbf{S}}$,特征集中每个元素(特征)的维数均为 N,则第 *i* 维特征分量 f_i 的 Fisher 值为:

 $Fscore(f_i) = (m_+(f_i) - m_-(f_i))^2 / (s_+^2(f_i) + s_-^2(f_i))$ (1) 其中, $m_+(f_i)$ 和 $m_-(f_i)$ 分别表示 X_c 和 X_s 在 f_i 上的 均值, $s_+(f_i)$ 和 $s_-(f_i)$ 分别表示 X_c 和 X_s 在 f_i 上的标 准差。

基于欧式距离度量特征集合的差异,文献[11]又 将 Fisher 准则扩展用于度量多维特征分量的可分性。 特征集合可分性的度量方法如下:设 $\|\mathbf{F}^{c}\| = \|\mathbf{F}^{s}\| = N$, $\|\bullet\|$ 表示集合•中元素的个数,于是

$$Fscore = \frac{\Omega(m_{+}(f_{i}) - m_{-}(f_{i}))^{2}}{\frac{1}{N} \left(\sum_{i=1}^{N} \Omega(s_{+}^{2}(f_{i})) + \sum_{i=1}^{N} \Omega(s_{-}^{2}(f_{i}))\right)}$$
(2)

其中, $\Omega(m_{+}(f_{i})-m_{-}(f_{i}))^{2} = \sqrt{\sum_{i=1}^{N} (m_{+}(f_{i})-m_{-}(f_{i}))^{2}}$ 是两 个特征集合的欧式距离, 两类样本特征集合的方差 分别为 $\frac{1}{N}\sum_{i=1}^{N} \Omega(s_{+}^{2}(f_{i}))$ 和 $\frac{1}{N}\sum_{i=1}^{N} \Omega(s_{-}^{2}(f_{i}))$ 。两个特征集 合的可分性值表示为*Fscore* 。*Fscore* 值越大, 其对 应特征集合的可分性就越好。

Fisher-based 方法选取特征分量的主要过程如下:对给定的图像特征集合,首先基于式(1)度量集合中每个特征分量的 Fscore 值;其次,根据 Fscore 值,对特征分量进行降序排序;然后,按照排序后特征分量的顺序,从第一维开始,依次向候选特征集合中添加一维特征分量,并计算和记录此时候选特征集合的 Fscore 值,直到得到原始特征集合的 Fscore 值;最后,将 Fscore 值最大时的候选特征集合中的元素作为最终选取的特征。

2.2 Fisher-based方法的性能分析

由上述 Fisher-based 的原理可知其具有计算简 单、无需限定隐写检测特征的类型、可有效降低隐 写检测特征维数等优点。然而,Fisher-based 方法在 Rich Model 特征选取时可能存在两方面不足。

(1) Fisher-based 方法不适宜度量 Rich Model 特征分量的可分性

由式(1)可知 Fisher-based 方法在度量隐写检测 特征分量 f_i的可分性时,若载体图像集合和隐写图 像 集 合 在 _{fi} 上 的 类 间 距 离 为 零 , 即 $m_{+}(f_{i})-m_{-}(f_{i})=0$ 时,有*Fscore*(f_{i})=0。事实上,经 过大量的统计,我们发现图像 Rich Model 隐写检测 特征中往往存在大量满足 $Fscore(f_i) \approx 0$ 的特征分量。 图 1 给出了 Bossbase-1.01 图像库 10000 幅图像及隐 写图像(隐写算法: SI-UNIWARD)的 Rich Model 特征对应的 Fscore 值。具体做法:从该原始图像组 和 SI-UNIWARD 隐写图像组中每幅图像提取 Rich Model 隐写检测特征,即 35263 维的 J+SRM 特征和 17000 维的 GFR 特征,分别计算并统计两种隐写检 测特征中满足 $(m_+(f_i)-m_-(f_i))^2 < 10^{-6}$ $s_{+}^{2}(f_{i}) + s_{-}^{2}(f_{i}) > 0.005$ 的特征分量的个数。图 1 中横 轴表示统计的特征分量个数,纵轴表示每个被统计 特 征 分 量 对 应 的 $(m_{+}(f_{i})-m_{-}(f_{i}))^{2}$ 值 和 $s_{+}^{2}(f_{i})+s_{-}^{2}(f_{i})$ 值。图1(a)(b)(c)(d)分别表示嵌入率 0.1 和 0.8bpac (bits per nonzero AC DCT coefficient) 的 J+SRM 和 GFR 特征的统计结果,"o"表示该特征分 量对应的 $(m_{+}(f_{i})-m_{-}(f_{i}))^{2}$ 值, "×"表示该特征分量 对应的 $s_{+}^{2}(f_{i}) + s_{-}^{2}(f_{i})$ 值。

我们由图 1 可知,当嵌入率为 0.1 时,J+SRM 隐 写 检 测 特 征 中 有 近 4000 个 特 征 分 量 的 $(m_{+}(f_{i})-m_{-}(f_{i}))^{2}$ 近似等于零而 $s_{+}^{2}(f_{i})+s_{-}^{2}(f_{i})$ 却较 大的现象,约占 35263 维 J+SRM 特征的 11.3%;类 似地,GFR 隐写检测特征中有近 9000 个特征分量的 $(m_+(f_i)-m_-(f_i))^2$ 近似等于零而 $s_+^2(f_i)+s_-^2(f_i)$ 却较 大的现象,约占 17000 维 GFR 特征的 53.0%。这一 现象表明 Rich Model 隐写检测特征中有相当比例的 特征分量满足在载体和隐写图像集合的类间距离近 似等于零。遗憾的是,Fisher-based 方法计算的此类 特征分量的可分性值为零,从而将这类特征分量作 为冗余特征删除。而模式识别经典理论认为:两个 类别中样本数据分布方差的较大差异也有助于样本 的分类^[13]。



图 1 J+SRM 和 GFR 特征中满足均值相等方差且较大的特征 分量的分布图(嵌入率 0.1 和 0.8)

(2)Fisher-based 方法无法删除一些冗余和冲突的特征分量

对特征分量 $f_i \ partial f_j$, 当 $Fscore(f_i) = Fscore(f_j)$ 时,若删除 $f_i \ partial f_j$ 中任意一个均不影响对图像的分类结果,则 $f_i \ partial f_j$ 中被称为冗余特征分量,二者中删除一个,能够降低特征维数。一个好的特征选取方法应当尽可能地剔除冗余特征分量。

此外,当 *Fscore*(f_i) = *Fscore*(f_j),但 f_i 将图像判断为载体图像,而 f_j 将图像判断为隐写图像,则 f_i 或 f_j 被称为冲突的特征分量。删除冲突分量中错误的那个特征分量,显然能提高对隐写图像的检测正确率,这也是特征选取方法追求的目标。

Fisher-based 方法选取认为 *Fscore* 最大的那个特征(分量)最适合于分类。然而,事实上这个观点存在疏漏。分析可知 Fisher-based 方法在隐写检测特征选取过程中可能存在以下三点问题:

问题 1: 有用特征分量可能被误删除。由 Fisher-based 方法选取特征分量的主要过程可知,若 添加某个特征分量后 *Fscore* 值达到最大值,则排在 该分量后面的特征分量都作为冗余特征删除掉。但 如前文所述,Rich Model 特征中可能存在大量 *Fscore* 值较小但可分性较好的特征分量,删除此类特征分 量会导致对隐写图像检测正确率的下降。 问题 2: 冗余特征分量可能被误保留。由 Fisher-based 方法选取特征分量的主要过程可知,在 候选特征集合 *Fscore* 值达到最大之前,所有的特征 分量都会被添加进来,即使是冗余的特征分量。但 如前文所述,Rich Model 特征中可能存在大量 *Fscore* 值较大但冗余的特征分量,添加此类特征分量会导 致不能最大限度地降低特征维数。

问题 3: 冲突特征分量可能被误选取。与问题 2 相似,即使添加冲突特征分量时,对隐写图像的检 测正确率有所下降,但只要后续添加进来的特征分 量,能够使候选特征集合的 *Fscore* 值达到最大,则 该冲突特征分量依然会添加进最终选取特征集合 中。冲突特征分量的添加会导致选取后特征对隐写 图像的检测正确率下降。

因此,我们需要找到更适合隐写检测特征分量 可分性度量准则,并在此基础上设计新的 Rich Model 隐写检测特征选取方法。

3 基于 W2ID 准则的特征可分性度量

在对 Rich Model 隐写检测特征的选取中,可分 性准则作为启发式函数,其基于可分性准则得到的 特征分量的度量结果为隐写检测特征约简提供依 据,故可分性准则的优劣直接关系到对 Rich Model 隐写检测特征进行选取后特征的维数和对隐写图像 检测正确率的高低。为此,在正式给出针对 Rich Model 特征的选取方法之前,本节先阐述用于度量特 征或特征分量的准则。我们先提出基于类间和类内 距离差异的特征可分性准则(2ID 准则),并在此基 础上提出加权的 2ID 准则(W2ID 准则),用以衡量 隐写检测特征分量的可分性。

3.1 2ID准则和W2ID准则

模式识别的经典理论表明可知:载体图像集合 与隐写图像集合在特征分量上的类内距离差异较大 时,该特征分量的可分性也较好^[13]。如图 2 所示, 图中白色三角和黑色矩形分别表示载体图像集合和 隐写图像集合中的图像,白色和黑色圆形分别表示 某一特征分量在载体图像集合和隐写图像集合中的 均值。从图中可知,该特征分量在两类集合的类间 距离近似为零,而其在载体图像集合中分布较集中、 在隐写图像集合中分布较分散,即类内距离差异较 大。此时载体图像集合和隐写图像集合较易被区分 开。



为此,我们考虑:采用标准差的比值来度量两 类图像的类内距离差异。当载体/隐写图像集合的所 有图像在第*i*个特征分量 f_i 的标准差远大于载密/载 体图像集合的所有图像在 f_i 的标准差时, i.e. $s_+(f_i)/s_-(f_i)$ □1或 $s_-(f_i)/s_+(f_i)$ □1;只要 f_i 在载体 图像集合和隐写图像集合中的标准差出现较大差异 时,函数 $d(f_i)=0.5 \times (s_+(f_i)/s_-(f_i)+(s_-(f_i)/s_+(f_i)))$ 都能提供较大值。即:

$$d(f_{i}) = \begin{cases} s_{+}(f_{i})/(2s_{-}(f_{i})) + \varepsilon_{1}, & s_{+}(f_{i}) \Box \ s_{-}(f_{i}) \\ s_{-}(f_{i})/(2s_{+}(f_{i})) + \varepsilon_{2}, & s_{-}(f_{i}) \Box \ s_{+}(f_{i}) \\ 1, & s_{-}(f_{i}) \approx s_{+}(f_{i}) \end{cases}$$
(3)

其中, $s_{+}(f_{i})$ 表示载体图像集合中所有图像在第 *i* 个特征分量 f_{i} 的标准差, $s_{-}(f_{i})$ 表示隐写图像集合 中所有图像第 *i* 个特征分量 f_{i} 的标准差, $\varepsilon_{1} = s_{-}(f_{i})/(2s_{+}(f_{i})) \rightarrow 0, \varepsilon_{2} = s_{+}(f_{i})/(2s_{-}(f_{i})) \rightarrow 0$ 。 则 $\ln d(f_{i})$ 具有以下性质。

性质 1:

又因为自然对数函数是增函数,于是 $\ln d(f_i) > \ln 1 = 0$ 。

(2) 由于,函数 y(x)=x+1/x 在(0,1) 上单调递减,在
 [1,+∞) 上单调递增;

令 $A(f_i) = s_+(f_i)/(s_-(f_i))$, 则 $d(f_i) = (A(f_i)+1/(A(f_i)))/2 \div (0,1) 上单调递减, 在$ $[1,+\infty) 上单调递增, 由于 s_+(f_i) > 0 且 s_-(f_i) > 0, 则$ $A(f_i) = s_+(f_i)/(s_-(f_i)) > 0$ 。

于是当 $0 < A(f_i) < 1$ 时, $s_+(f_i) < s_-(f_i)$, 使得 $|s_+(f_i) - s_-(f_i)|$ 增大, $A(f_i) = s_+(f_i)/(s_-(f_i))$ 減小, 由于 $d(f_i)$ 在(0,1)上单调递减,则 $d(f_i)$ 值随着 $A(f_i)$ 的减小而增大,又由于 $\ln d(f_i)$ 是增函数,因此 $\ln d(f_i)$ 随着 $d(f_i)$ 的增大而增大。

而 当 $1 < A(f_i) < +\infty$ 时, $s_+(f_i) > s_-(f_i)$, $|s_+(f_i) - s_-(f_i)|$ 增大, 则 $A(f_i) = s_+(f_i)/(s_-(f_i))$ 增大, 由于 $d(f_i)$ 在 $[1,+\infty)$ 上单调递增, 则 $d(f_i)$ 值随着 $A(f_i)$ 的增大而增大,又由于 $\ln d(f_i)$ 是增函数,因 此 $\ln d(f_i)$ 随着 $d(f_i)$ 的增大而增大。

由此可知, $|s_{+}(f_{i})-s_{-}(f_{i})|$ 越大, $\ln d(f_{i})$ 越大。

$$(3) \stackrel{\text{tr}}{=} s_{+}(f_{i}) = s_{-}(f_{i}) \qquad \text{tr},$$

$$s_{+}(f_{i})/(s_{-}(f_{i})) = s_{-}(f_{i})/(s_{+}(f_{i})) = 1,$$

$$d(f_{i}) = (s_{+}(f_{i})/(s_{-}(f_{i})) + s_{-}(f_{i})/(s_{+}(f_{i})))/2$$

$$= (1+1)/2$$

$$= 1,$$

所以 $\ln d(f_i) = \ln 1 = 0$ 。

由性质 1 可知,函数 $\ln d(f_i)$ 的值域为 $[0,+\infty)$,并且随着 $s_{+}(f_i) = s_{-}(f_i)$ 之间差异的增加, $\ln d(f_i)$ 值也增大,因而函数 $\ln d(f_i)$ 能够用来度量因为特征 分量在载体图像集合和隐写图像集合的类内距离差 异带来的可分性。

 $ASM(f_i) = |(m_+(f_i) - m_-(f_i))/(s_+(f_i) + s_-(f_i))|$ 能 够度量特征分量的类间距离, $d(f_i)$ 能够度量特征分 量类内距离差异值,于是,我们选择这两个函数构 建可分性准则。虽然 $d(f_i)$ 能够提供特征分量 f_i 在载 体图像集合和隐写图像集合中标准差差异较大时的 可分性值,但是,由式(3)可知,当 $s_+(f_i)$ □ $s_-(f_i)$ 或 者 $s_-(f_i)$ □ $s_+(f_i)$ 时, $d(f_i)$ 的值会过大。为了防止 出现 $d(f_i)$ 值过大湮灭 $ASM(f_i)$ 的值,我们对 $d(f_i)$ 取自然对数,即 $\ln d(f_i)$ 。当 $s_-(f_i) \approx s_+(f_i)$ 时, $d(f_i) \approx 1$, $\ln d(f_i) \approx 0$; 当 $s_+(f_i)$ □ $s_-(f_i)$ 或 $s_-(f_i)$ □ $s_+(f_i)$ 时, $\ln d(f_i)$ 的值不会过大,才能为隐 写检测特征分量 f_i 的可分性提供合理的值。

于是,本文首先基于类间距离和类内距离差异 原则,提出一种隐写检测特征的可分性准则 (inter-inner distance and inner distance difference,简 记为 2ID 准则):

 $Dscore(f_{i}) = \left| \left(m_{+}(f_{i}) - m_{-}(f_{i}) \right) / \left(s_{+}(f_{i}) + s_{-}(f_{i}) \right) \right| + \ln \left(\left(s_{+}^{2}(f_{i}) + s_{-}^{2}(f_{i}) \right) / \left(2s_{+}(f_{i})s_{-}(f_{i}) \right) \right) \right)$ (4)

其中,特征分量的 Dscore 值越大,则该特征分量的可分性越好,对区分隐写图像的贡献越大。

从式(4)可以看出,当特征分量 f_i 在载体图像集 合等于在隐写图像集合的类间距离时, $A S M(_i) = 0$,但只要特征分量 f_i 在载体图像集合和 隐写图像集合中类内距离差别较大时, $\ln d(f_i)$ 仍能 得到较大的度量值,因而2ID准则能够同时兼顾"类 间距离"和"类内距离差异较大"两方面度量 f_i 的可分 性,更全面地度量隐写检测特征分量对区分隐写图 像的贡献。

初步统计结果显示,满足条件 $ASM(f_i) > \delta$ 和 $\ln d(f_i) > \delta$ 的特征分量的统计数量差异较大。于是, 我们考虑这可能意味着 $ASM(f_i)$ 和 $\ln d(f_i)$ 在度量 隐写检测特征分量可分性时所起的作用也会有差 异。在度量隐写检测特征分量可分性时,为了使度 量结果更加准确,将满足 $ASM(f_i) > \delta$ 和 $\ln d(f_i) > \delta$ 的特征分量的统计个数作为 2ID 可分性准则中 ASM(f)和 $\ln d(f_i)$ 这两项合理分配权重的依据。

综合上述,我们提出基于加权的 2ID 准则(简 记为 W2ID 准则),用于度量隐写检测特征分量的可 分性,具体形式如下:

 $Wscore(f_{i}) = w_{1} \times \left| \left(m_{+}(f_{i}) - m_{-}(f_{i}) \right) / \left(s_{+}(f_{i}) + s_{-}(f_{i}) \right) \right| + w_{2} \times \ln \left(\left(s_{+}^{2}(f_{i}) + s_{-}^{2}(f_{i}) \right) / \left(2s_{+}(f_{i})s_{-}(f_{i}) \right) \right) \right|$ (5)

其中, $w_1 \exists w_2 \notin ASM(f_i) \exists \ln d(f_i)$ 的待定权值, $0 \le w_1, w_2 \le 1$, $w_1 + w_2 = 1$ 。 *Wscore*(f_i) 度量值越大, 该隐写检测特征分量的可分性越好,其对区分载密 图像的贡献越大。

3.2 权重分配算法

频数统计加权法是一种通过频数(又称次数) 来确定权重的方法。该方法首先需要明确准则中需 要确定权重的项;其次给出各项需要满足的条件; 再确定各项中满足条件的特征分量出现的频数;然 后将各项的频数之和作为总频数;最后将各项的频 数与总频数的比值作为该项的权重。考虑到符合 $ASM(f_i) > \delta 和 \ln d(f_i) > \delta$ 的隐写检测特征分量在 数量上存在的差距,于是,我们提出基于频数统计 加权法确定 W2ID 准则中权重 $w_1 和 w_2$,并给出相应 的权重确定算法,如算法1所示:

算法 1: W2ID 准则中权重的确定算法
输入: 隐写检测特征 (<i>n</i> 个不同嵌入率);
输出: 各项的权重值;
步骤1:确定W2ID准则中的权重项。
明确 W2ID 准则中需要确定权重的项是 $ASMig(f_iig)$ 和
$\ln d(f_i)$.
步骤 2:确定 W2ID 准则中各项需要满足的条件。
$ASM(f_i) > \delta$ 和 $\ln d(f_i) > \delta$,其中 δ 为阈值,这
里需要将无用信息排除。
步骤 3:统计满足步骤 2 中确定的条件的特征分量的频数。
在 n 个嵌入率下,统计满足 $ASM\left(f_{i} ight) > \delta$ 和的特征
分量的个数为 $\left(r_{1},\cdots,r_{n} ight)$,统计满足 $\ln d\left(f_{i} ight)$ > δ 的
特征分量的频数为 (r_1', \cdots, r_n') ,则

$$r = \sum_{j=1}^{n} r_j , \qquad (6)$$

$$r' = \sum_{i=1}^{n} r'_{j} \ . \tag{7}$$

步骤4:计算统计频数的总和—总频数。

$$R = r + r' = \sum_{j=1}^{n} \left(r_j + r'_j \right) .$$
(8)

步骤 5: 根据公式确定各项权重。 $w_1 = r/(R), (0 \le w_1 \le 1)$

利用式(9), 计算出
$$ASM(f_i)$$
 的权重 w_1 ,

$$v_2 = r'/(R), \quad (0 \le w_2 \le 1)$$
 (10)

利用式(10),计算出
$$\ln d(f_i)$$
 的权重 w_2 。

由于 $w_2 = r'/(R) = r'/(r+r') = 1 - r/(r+r') = 1 - w_1$, 因此 $w_2 = 1 - w_1$ 。

3.3 基于W2ID准则的Rich Model特征分量度量算法

设 $U = \{X_c, X_s\}$ 是一个图像集合,其中载体图像 集 合 $X_c = \{x_{c_1}, x_{c_2}, \dots, x_{c_M}\}$, 第 *j* 个载体图像是 $c_j(i=1,2,\dots,M)$,隐写图像集合 $X_s = \{x_{s_1}, x_{s_2},\dots, x_{s_M}\}$, 第 *j* 个隐写图像是 $s_j(i=1,2,\dots,M)$, ||U|| = 2M, $||X_c|| = ||X_s|| = M$, $||\bullet||$ 表示集合•中元素的个数。隐写 检 测 特 征 集 合 $H = \{f_1, f_2, \dots, f_i, \dots, f_N\}$, 这 里 f_i (1≤*i*≤*N* 表示*H*中的第*i*个隐写检测特征分量, ||*H*||=*N*。*v*_{*c*_{*j*},*i*} (1≤*j*≤*M*) 表示载体图像 *x*_{*c*_{*j*}} 对应的隐 写检测特征分量 *f*_{*i*} 的值; *v*_{*s*_{*j*},*i*</sup> (1≤*j*≤*M*) 表示隐写图 像 *x*_{*s*_{*j*}} 对应的隐写特征分量 *f*_{*i*} 的值。对*v*_{*c*_{*j*},*i* 和*v*_{*s*_{*j*},*i*} 除以 绝对值最大的特征分量的值,得到*v*'_{*c*_{*j*},*i*} 和*v*'_{*s*_{*j*},*i*}, 即 *v*'_{*c*_{*j*},*i*} = *v*_{*c*_{*j*},*i*</sup>/(max(|*v*_{*c*₁,1},...,|*v*_{*c*_{*M*},*N*}|,|*v*_{*s*₁,1},...,|*v*_{*s*_{*M*},*N*}])) 和 *v*'_{*s*_{*j*},*i*} ∈ [-1,1], *v*'_{*s*_{*j*},*i*} ∈ [-1,1], 将载体图像预处理后的特 征值放在前*M* 行,隐写图像预处理后的特征值放在 后*M* 行,得到矩阵*T*。}}}}}}}

$$T_{(2M\times N)} = \begin{pmatrix} v'_{c_{1},1} & v'_{c_{1},2} & \cdots & v'_{c_{1},N} \\ v'_{c_{2},1} & v'_{c_{2},2} & \cdots & v'_{c_{2},N} \\ \vdots & \vdots & \vdots & \vdots \\ v'_{c_{M},1} & v'_{c_{M},2} & \cdots & v'_{c_{M},N} \\ v'_{s_{1},1} & v'_{s_{1},2} & \cdots & v'_{s_{1},N} \\ v'_{s_{2},1} & v'_{s_{2},2} & \cdots & v'_{s_{2},N} \\ \vdots & \vdots & \vdots & \vdots \\ v'_{s_{M},1} & v'_{s_{M},2} & \cdots & v'_{s_{M},N} \end{pmatrix},$$
(11)

其中, $1 \le i \le N, 1 \le j \le M$ 。

基于本文所提 W2ID 准则度量矩阵 *T* 中各隐写 检测特征分量可分性,具体如算法 2 所示:

算法 2: 基于 W2ID 准则的 Rich Model 隐写检测特征分量可	•
分性的度量算法	

输入:构建好的隐写检测特征矩阵T;

输出:每个特征分量的Wscore 值;

For $(i = 1; i \le N; i + +)$

(9)

步骤 1: 计算隐写检测特征分量的 $m_+(f_i) \oplus m_-(f_i)$ 。根据 矩阵 T 中的值,计算特征分量 f_i 在载体图像集合和 隐写图像集合中的均值 $m_+(f_i) \oplus m_-(f_i)$,其中 $\|X_c\| = \|X_s\| = M$:

$$m_{+}(f_{i}) = \sum_{j=1}^{M} v'_{c_{j},i} / (M)$$
(12)

$$m_{-}(f_{i}) = \sum_{j=1}^{M} v'_{s_{j},i} / (M)$$
(13)

步骤 2: 计算隐写检测特征分量的 $s_{+}(f_{i})$ 和 $s_{-}(f_{i})$ 。根据 矩阵 T 中各分量的值和步骤 1 中的计算结果,计算 f_{i} 在载体图像集合和隐写图像集合中的标准差 $s_{+}(f_{i})$ 和 $s_{-}(f_{i})$:

$$s_{+}(f_{i}) = \sqrt{\sum_{j=1}^{M} \left(v_{c_{j},i}' - m_{+}(f_{i}) \right)^{2} / (M)}$$
(14)

$$s_{-}(f_{i}) = \sqrt{\sum_{j=1}^{M} \left(v_{s_{j},i}' - m_{-}(f_{i}) \right)^{2} / (M)}$$
(15)

载体图像集合

步骤 3: 计算隐写检测特征分量的 $ASM(f_i)$ 值。根据步骤
1 和步骤 2 中的计算结果,计算 $ASMig(f_iig)$ 的值:
$ASM(f_{i}) = \left \left(m_{+} \left(f_{i} \right) - m_{-} \left(f_{i} \right) \right) / \left(s_{+} \left(f_{i} \right) + s_{-} \left(f_{i} \right) \right) \right (16)$
步骤 4: 计算隐写检测特征分量的 $g(f_i)$ 值。根据步骤 2 中
的结果,计算 $g(f_i)$ 的值:
$g(f_i) = \left(s_+^2(f_i) + s^2(f_i)\right) / \left(2s_+(f_i)s(f_i)\right) (17)$
步骤 5: 计算并输出隐写检测特征分量的 Wscore 值。根据
步骤 3 和步骤 4 的计算结果,计算并输出 f _i 的
Wscore 值:
$Wscore(f_{i}) = \omega_{1} \times \left \left(m_{+}(f_{i}) - m_{-}(f_{i}) \right) / \left(s_{+}(f_{i}) + s_{-}(f_{i}) \right) \right $ (18)
$+\omega_{2} \times \ln\left(\left(s_{+}^{2}\left(f_{i}\right)+s_{-}^{2}\left(f_{i}\right)\right)/\left(2s_{+}\left(f_{i}\right)s_{-}\left(f_{i}\right)\right)\right)$

End.

4 隐写检测特征选取

20世纪九十年代,里贾纳大学的Yao等提出了决 策粗糙集理论。由于可以用来删除冗余特征和冲突 特征分量,决策粗糙集α-正域约简成为特征约简研究 的热点^[15]。本文以决策粗糙集α-正域约简约简作为 Rich Model隐写检测特征选取方法,以W2ID准则的 度量结果作为特征约简的依据,给出一种基于W2ID 准则和决策粗糙集α-正域约简相结合的Rich Model 隐写检测特征选取方法(W2ID-α方法)。

4.1 特征选取基本原理与主要步骤

决策粗糙集 α-正域约简是在决策系统中寻找最 优子集的过程,可以考虑用来约简隐写检测特征^[14]。 目前已知求决策粗糙集 α-正域约简子集是一个 NP 难问题,为了解决这个问题,大多数求最优子集的 方法采用启发函数进行求解。本文提出基于决策粗 糙集 α-正域约简对高维 Rich Model 隐写检测特征进 行约简,将W2ID准则的度量结果作为约简的依据, 提出 W2ID-α 方法。图 3 给出了 W2ID-α 方法的原理 框架:





图 3 W2ID-α 方法原理框架 W2ID-α 方法的主要步骤具体如下:

(1) 生成归一化的隐写检测特征矩阵T'。首先将 隐写检测特征生成一个特征矩阵T,其次对特征矩阵 T中的各隐写检测特征分量进行归一化,得到T', 具体过程见 3.2 节。

(2) 度量隐写检测特征分量的Wscore值。基于 W2ID 准则度量矩阵T'中各特征分量的Wscore 值。

(3) 构建决策表T。将决策属性加在特征矩阵T' 的最后一列,并根据图像类别进行填写,载体图像 填"0",隐写图像填"1",构建成决策表T。具体过程, 将在 4.2 节中进行描述。

(4) 特征约简。采用每次考察一组特征分量的策 略,对隐写检测特征进行约简,首先计算划分步长 值 λ,其次根据 Wscore 值对 H 中的特征分量进行升 序排序,再根据λ值,将排序后的特征分量划分为若 干个候选特征子集; 然后根据阈值 α, 利用决策粗糙 集 α-正域约简对隐写检测特征进行约简,并输出决 策粗糙集α-正域约简子集。详细过程见4.2节。

(5) 选取特征子集。从(4)中得到的决策粗糙集α-正域约简子集中,选取分类效果最好的作为最终选 取特征子集。

在上述主要步骤中,第(1)~(2)步的原理已在第3 节中进行了阐述,本节重点阐述第(3)~(4)步"特征约 简。

4.2 特征选取基本原理与主要步骤

本文基于决策粗糙集 α-正域约简约简隐写检测 特征。首先,需要在式(6)隐写检测特征矩阵*T*'的基 础上,构建一个决策表*T*。将决策属性加在*T*'的最 后一列上,并根据每个图像对应的图像类别填写对 应的决策属性值,其中载体图像的决策属性值对应 "0",隐写图像的决策属性值对应"1"。*T*具体形式如 下所示:

$$T_{(2M\times(N+1))} = \begin{pmatrix} v'_{c_{1},1} & v'_{c_{1},2} & \cdots & v'_{c_{1},N} & 0\\ v'_{c_{2},1} & v'_{c_{2},2} & \cdots & v'_{c_{2},N} & 0\\ \vdots & \vdots & \vdots & \vdots & 0\\ v'_{c_{M},1} & v'_{c_{M},2} & \cdots & v'_{c_{M},N} & 0\\ v'_{s_{1},1} & v'_{s_{1},2} & \cdots & v'_{s_{1},N} & 1\\ \vdots & \vdots & \vdots & \vdots & 1\\ v'_{s_{2},1} & v'_{s_{2},2} & \cdots & v'_{s_{2},N} & 1\\ \vdots & \vdots & \vdots & \vdots & 1\\ v'_{s_{M},1} & v'_{s_{M},2} & \cdots & v'_{s_{M},N} & 1 \end{pmatrix},$$
(19)

其中, $(1 \le i \le N, 1 \le j \le M)$, 前M 行表示M 幅载体图 像, 后M 行表示M 幅隐写图像。

文献[12]提出的 Steganalysis-α 方法首先根据经 验设置可分性的下限,删除可分性值低于该下限的 特征分量后再进行后续计算。但若可分性下限设置 过高,会造成有用的特征分量被删除,最终会降低 约简后特征对隐写图像的检测正确率;而如果可分 性下限设置的过低,造成较多的冗余特征分量没有 被删除,最终导致在约简时的计算量过大。

鉴于 Rich Model 隐写检测特征具有维数高和约 简时计算量大的问题,我们对 Steganalysis-α 方法进 行一定的改进。改进的关键在于:从每次删除一维 特征分量改为每次删除一个候选特征子集。每个候 选特征子集中包含若干维特征分量,减少了处理的 次数,达到减少计算量的目的,并且无需设置可分 性下限。具体如下:首先根据计算得到的Wscore 值, 计算划分步长 λ,再对特征分量进行升序排序。然后 根据Wscore 值和 λ,将特征集合划分成若干子集。最 后在基于决策粗糙集 α-正域约简时,按从小到大的 顺序每次删除一维Wscore 值最小的隐写检测特征候 选子集,并测试其正域非减性和属性独立性,判断 其是否是决策粗糙集 α-正域约简子集。

设T 为一个决策表,论域 $U = \{x_1, x_2, \dots, x_{2m}\}$, H 和 Q 分别是论域 U 上的条件属性集和决策属性集, X 为论域 U 的子集, $\alpha \in [0,1]$,若属性子集 $B \subseteq H$ 满 足以下两个条件:

(1) 正域非减性, $\|\text{POS}^{\alpha}_{B}(Q)\| \ge \|\text{POS}^{\alpha}_{H}(Q)\|$;

(2) 属性独立性,对任意 $f_i \in B$,

 $\left\| \operatorname{POS}_{B-\{f_i\}}^{\alpha}(Q) \right\| < \left\| \operatorname{POS}_{B}^{\alpha}(Q) \right\|,$

则称属性子集 B 为属性全集 H 的一个决策粗糙

集 α -正域约简。这里, $\operatorname{POS}_{H}^{\alpha}(Q) = \bigcup_{x \in U/Q} R_{-H}^{\alpha}(X)$, $R_{-H}^{\alpha}(X) = \{x \in U \mid P(X \mid [x]_{H}) \ge \alpha\}$, 阈值 α 为预先设定的 对象的分类正确率, $R_{-H}^{\alpha}(X)$ 为 x 的 α -下近似集, $[x]_{H}$ 表示 x 在 属 性 集 H 下 的 等 价 类 , $P(X \mid [x]_{H}) = \|X \cap [x]_{H}\| / (\|[x]_{H}\|)$, $\|\bullet\|$ 表示 \bullet 中对象的 个数。

将 W2ID 作为启发函数,本文提出了基于决策 粗糙集 α-正域约简的 Rich Model 隐写检测特征选取 算法,具体如下:

A, 7,11,25,1.
算法 3: 基于改进的决策粗糙集 α-正域约简的 Rich Model 隐写检测特征选取算法
输入:决策表 T ,每个特征分量 f 的 $Wscore$ 值及其
相应的标号] , 阈值 α (设 α 是 Rich Model
隐写检测特征未约简的分类正确率);
输出:约简后的隐写检测特征子集 B 及其相应标号
□ ' 和检测正确率;
步骤 1: 计算划分步长。划分步长的计算公式为
$\lambda = \max(Wscore) - \min(Wscore)/(n), \mp$
中, λ 为划分步长, m 为期望特征子集的个
致。根据以公式,计算划分步长; 先瞭 2. 划分候选子集 根据管注2 得到的Wecorg 值
少禄2 : 划刀陕远了亲。秋始异位2 侍到的 WSCOPE 值, 将 H 中的特征分量讲行升序排序.并根据
Step1 中得到的入,将排序后的特征分量划分
成 $H' = \{h_1, h_2, \dots, h_m\}$, $h_i = \{f_{i_1}, f_{i_2}, \dots, f_{i_n}\}$ 表示
第 <i>i</i> 个候选子集, <i>t</i> 表示 h_i 中特征分量的个数;
步骤 3:约简特征。
初始化。令 $B = H'$, $\Box' = \Box(H')$,其中
$\Box(\bullet)$ 表示•在原始集合 H 中的标号;
$for(i = 1; i \le m; i + +)$
{测试一个候选子集 h_i 。
^{h} 将 $h_i \cup B$ 中删除(若 $h_i = \emptyset$,则停止),
$B=B-ig\{h_iig\}$;
将 \Box '= \Box '- $\left\{\Box$ (h_i) $\right\}$;
计算 $\left\ \operatorname{POS}^{lpha}_{\scriptscriptstyle B}\left(Q ight)\right\ ,$
if $\left\ \operatorname{POS}_{B}^{\alpha}\left(Q \right) \right\ \geq \left\ \operatorname{POS}_{H}^{\alpha}\left(Q \right) \right\ $,
{则 B 符合正域非减性原则,则删除 h_i ;
否则保留 h _i ,此时 B 仍然符合正域非
减性原则,
对 h _i 中特征分量进行属性独立
性测试:
$if(t \ge 2)//t$ 为 h_i 中特征分量个数
$\{ for(j = 1; j \le t; j + +) \}$
如果
$\left(\left\ \operatorname{POS}_{B-\{f_j\}}^{\alpha}(Q) \right\ < \left\ \operatorname{POS}_{B}^{\alpha}(Q) \right\ \right), 则 B$ 符合属性
独立性原则,
<i>B</i> 就是 <i>H</i> 的一个决策粗糙集 α-正域约简子集; }

输出约简子集 B 及其相应标号□′和检 测正确率; }}

步骤 4: 选取特征。从决策粗糙集 α-正域约简子集 中选取出维数较少且检测正确率较高的子集作为最 终的选取特征。

最后基于最终的选取特征检测隐写图像。由于 W2ID-α方法采用决策粗糙集α-正域约简对Rich Model隐写检测特征进行约简,由于将处理单维特征 分量改为处理一组特征分量,与Steganalysis-α方法相 比大大降低了计算量,并且W2ID-α方法在约简前不 需要依靠经验设置最小阈值来排除无关特征,减少 了设置阈值的盲目性和对经验的依赖性,增加了约 简方法的通用性。

最终选取得到特征子集 B。特征子集 B 中元素的 个数往往显著低于原始特征的维数,从而节省了隐 写检测特征的存储空间。虽然处理隐写检测特征的 过程是繁琐的,但是这个过程离线进行,一旦确定 了特征子集,也就确定了相应的那些维特征分量组 合的特征向量用于检测图像是否为隐写图像,而不 需要每次检测图像时在线进行特征选取。对待检测 图像进行检测时,我们只需提取和选取得到的序号 相对应的 Rich Model 特征分量对待检测图像进行检 测即可,从而减少了提取特征所需的时间和存储特 征所需的存储空间,而且低维的特征相比高维特征 能明显减轻分类器的压力,缩短分类器处理的时间, 故基于选取特征进行隐写检测能够在不影响或者提 高检测正确率的同时显著提高检测效率。

4.3 W2ID-α方法的性能分析

W2ID-α 方法采用 W2ID 准则度量隐写检测特征 分量的可分性,为后续约简提供依据,又基于改进 的决策粗糙集 α-正域约简对 Rich Model 隐写检测特 征进行约简。该方法能够大幅降低 Rich Model 隐写 检测特征的同时,提高对隐写图像的检测正确率。 这主要是因为以下两点:

(1) W2ID-α 方法能够处理冗余和冲突的 Rich Model 隐写检测特征

W2ID-α方法基于决策粗糙集α-正域约简对特征 进行降维。由于决策粗糙集α-正域约简正域的非减 性原则能够在约简时找到并删除冲突的特征分量, 使得W2ID-α方法选取后的Rich Model 隐写检测特 征,不仅能够降低特征的维数的同时,还能够保持 甚至提高隐写图像的检测正确率。决策粗糙集α-正 域约简的属性独立性原则能够在约简时找到并删除 冗余的特征分量,从而进一步降低隐写检测特征的 维数。

(2) W2ID 准则对 Rich Model 隐写检测特征分量可分性度量得更准确

W2ID 准则能够同时兼顾类间距离和类内距离 差异两方面。在度量隐写检测特征分量的可分性时, 即使 $m_{+}(f_i) - m_{-}(f_i) = 0$,只要类内聚合度的差异足够 大,就有 $\ln((s_{+}^2(f_i) + s_{-}^2(f_i))/(2s_{+}(f_i)s_{-}(f_i))) > 0$,又 充分考虑了类间分散在可分性度量中的主导作用。 W2ID 准则的 Wscore 值大于零,认为该特征分量的可 分性较大。而由图 1 可知,Rich Model 特征中存在 大量类间距离相等而类内距离差异较大的特征分 量。于是,在 W2ID 准则中这些特征分量会被认为 是有用的特征分量被保留下来,使得选取后特征能 够保持甚至提高对隐写图像的检测正确率。

由上述可知, W2ID-α 方法适用于 Rich Model 隐写检测特征的选取。

5 实验结果与分析

为了验证所提 W2ID-α 方法的性能,本文利用 MatlabR2010b 软件,对一些经典 Rich Model 隐写检 测特征进行了一系列选取实验。

5.1 实验设置

	表1 实验设置
图像来源	BOSSbase 1.01 database
图像大小	512×512
图像颜色	灰度图像
提取算法	J+SRM ^[5] / GFR ^[6]
隐写算法	SI-UNIWARD
图像格式	JPEG
质量因子	95
原始图像数量	10000
隐写图像数量	10000×5
嵌入率	0.1; 0.25; 0.5; 0.8; 1.0
训练特征	5000 对
测试特征	5000 对
对比方法	PCA-based ^{Error!} Reference source not
	found. Fisher-based ^{Error! Reference}
	source not found. Steganalysis-α ^{Error!}
	Reference source not found.

共计特征(组) 10000×(5×2+2)=120000

实验中所使用的原始图像均来自于 BOSSbase-1.01^[16]图像库,共10000幅尺寸为512×512 的灰度图像。首先,将其转换成质量因子95的JEPG 载体图像;然后,采用当前抗检测性能较好的经典 SI-UNIWARD 隐写算法,分别构建嵌入率为0.1, 0.25,0.5,0.8和1.0 bpac(bits per nonzero AC DCT coefficient)的隐写图像,共得到1组载体图像和5 组隐写图像的图像库。接着,对该图像组中的每幅 图像提取J+SRM^[5](35263 维)和GFR^[6](17000 维) 隐写检测特征。综上,共有2组载体图像的隐写检 测特征和2×5=10组隐写图像的隐写检测特征,得到 包括10000×(5×2+2)=120000幅图像的Rich Model隐 写检测特征库,具体如表1所示。

在对隐写检测特征进行实验测试时,与原始的 基于 J+SRM 特征和 GFR 特征的隐写检测实验一样, 本文继续沿用集成分类器对样本数据进行训练和测试,从每组图像样本中随机选取 5000 幅载体图像和 对应的不同嵌入率的 5000 幅隐写图像作为训练集, 剩余的 5000 幅载体图像和对应的不同嵌入率的 5000 幅隐写图像作为测试集。该集成分类器中的错误率 由虚警率和误报率组成: $P_E = \min_{P_{FA}} [P_{FA} + P_{MD}(P_{FA})]/2$, 这里, P_{FA} 代表虚警率, P_{MD} 代表误报率。重复实验 10 次,计算 10 次结果平均值作为最终比较结果, $\bar{P}_A = 1 - \bar{P}_E$,这里 \bar{P}_E 代表平均检测错误率, \bar{P}_A 代表平均检测正确率。实验中将期望特征子集数 *m* 设为 100。然后,对特征选取过程中特征维数与检测正确 率的关系进行实验分析。实验主要包括 7 个方面:

- 1) 2ID 准则的可行性实验
- 2) 权重的分配

- 3) J+SRM^[5]隐写检测特征的选取实验
- 4) GFR^[6]隐写检测特征的选取实验
- 5) W2ID-α 方法与 Fisher-based 方法的对比实验
- 6) W2ID-α 方法与 PCA-based 方法的对比实验
- 7) W2ID-α 方法与 Steganalysis-α 方法的对比实验

5.2 2ID准则的可行性验证

为了验证均值相等时, 2ID 准则依然能够区分隐 写检测特征分量的可分性, 我们根据 5.1 中相同的实 验设置,统计嵌入率0.1,0.25,0.5,0.8 和 1.0 的 J+SRM 和 GFR 隐写检测特征中满足 $ASM(f_i) \approx 0$ 且 $\ln d(f_i) > 0.005$ 的特征分量个数。不同嵌入率下, J+SRM 和 GFR 隐写检测特征的统计结果如表 2 所 示。

					嵌入	、率				
隐写检测特征	0.1		0.25		0.5		0.8		1.0	
	个数	比率	个数	比率	个数	比率	个数	比率	个数	比率
J+SRM(35263-D)	9735	0.28	13698	0.39	16573	0.47	17029	0.48	17146	0.49
GFR(17000-D)	4093	0.24	4093	0.24	5426	0.32	4776	0.28	4218	0.12

在表 2 中,个数表示满足条件的特征分量的个 数;比率表示个数与原始特征维数的比值。我们不 难发现:在不同嵌入率下,GFR和J+SRM特征中都 存在大量 ASM (f_i) ≈ 0 且 ln d(f_i) □ 0 的特征分量,说 明在载体图像集合和隐写图像集合中存在大量均值 相等而类内标准差差异较大的特征分量。尽管这类 特征分量的 $ASM(f_i) \approx 0$, 但是由于 $\ln d(f_i) \square 0$, 且 $Dscore(f_i) = ASM(f_i) + \ln d(f_i), \quad \exists E Dscore(f_i) \square 0.$ 由此可知,在均值相同的情况下,和经典的 Fisher 准 则不同,本文提出的 2ID 准则能够度量出类内标准 差较大差异带给特征分量的可分性,进一步验证了 2.2 节 中 的 结 论 由 于 0 $Wscore(f_i) = w_1 \times ASM(f_i) + w_2 \times \ln d(f_i)$, 这也为 W2ID 准则的可行性提供了依据。

5.3 权重的分配

在 W2ID 准则的权重分配过程中,根据上述 5.1 节的实验设置,以 GFR^[6]特征为例,我们使用 5.1 节

 5426
 0.32
 4776
 0.28
 4218
 0.12

 基于频数统计加权法的权重分配算法来确定
 W2ID

 准则中权重 w_1 和 w_2 的具体值。参数 τ 的具体选取过

 程如下:
 由于当 $\delta < 1 \times 10^4$ 时,所有特征分量均满足

 条件 ASM $(f_i) < 10^{-4}$,而当 $\delta > 1 \times 10^{-3}$ 时,没有特征分量

 量满足条件 $\ln d(f_i) > 10^{-3}$,排除这些无效的条件后,

 确定 δ 的取值为:
 $10^{-4} \le \delta \le 10^{-3}$ 且步长为10⁻⁴。根据

 算法1中的Step3,统计GFR特征中满足 ASM $(f_i) > \delta$

 和 $\ln g(f_i) > \delta$ 的特征分量的个数,统计结果如图 4

 所示。最终得到 $w_i = z/(Z) = 667068/944522 \approx 0.75$,

 $w_2 = 1 - w_1 = 0.25$ 。实验数据如图 3 所示,横轴表示

 参数 δ 的取值,纵轴表示满足条件的特征分量的个数;方块表示满足条件 $ASM(f_i) > \delta$

 角形表示满足条件 $\ln d(f_i) > \delta$ 的特征分量。



从图 3 中我们可以看出,在 GFR 特征中,满足 $ASM(f_i) > \delta 和 \ln g(f_i) > \delta$ 的特征分量的个数并不 相同,且个数差异较大。同样地,我们对 J+SRM 等 特征也进行了统计,根据频数统计加权法可得 $ASM(f) 和 \ln d(f_i)$ 的权重遵循 $w_1 \approx 0.75$, $w_2 \approx 0.25$ 。 于是 W2ID 准则具体为

 $Wscore(f_{i}) = 0.75 \times \left| \left(m_{+}(f_{i}) - m_{-}(f_{i}) \right) / \left(s_{+}(f_{i}) + s_{-}(f_{i}) \right) \right| + 0.25 \times \ln \left(\left(s_{+}^{2}(f_{i}) + s_{-}^{2}(f_{i}) \right) / \left(2s_{+}(f_{i}) s_{-}(f_{i}) \right) \right)$ (19)

其中, $m_{+}(f_{i})$ 和 $m_{-}(f_{i})$ 分别表示特征分量 f_{i} 在载体图 像集合和隐写图像集合中的平均值, $s_{+}(f_{i})$ 和 $s_{-}(f_{i})$ 分别表示特征分量 f_{i} 在载体图像集合和隐写图像集 合中的标准差。J+SRM 隐写检测特征的选取实验

5.4 J+SRM隐写检测特征的选取实验

文献[5]提出的 J+SRM 算法提取的 J+SRM 隐写 检测特征的总维数是 35263,并且嵌入率较大时 J+SRM 特征性能表现得更好,因此,首先从载体和 隐写图像中提取质量因子 95 嵌入率 0.8 的 J+SRM 隐 写检测特征,并构建相应的隐写检测特征矩阵。其 次利用算法 2 度量集合中特征分量的*Wscore*值,并 按降序对特征分量进行排序。然后根据隐写检测特 征矩阵构建决策表,利用算法 3 对 J+SRM 隐写检测 特征进行约简,得到相应特征子集。最后,从测试 集中提取与特征子集中序号对应的特征分量,将其 放在训练好的集成分类器中进行测试,得到相应的 检测准确率。结果如图 5 所示。





图 6 基于 W2ID-α 方法约简前后存储空间的对比结果(J+SRM 特征)

图 5 中横轴代表特征维数,纵轴代表对隐写图 像的平均检测正确率。图中"●"表示选取后不同维数 对应的检测正确率,图中"□"表示该嵌入率下未选取 前特征的检测正确率,图中"Δ"表示选取后检测正确 率最高的特征维数的正确率。由图 5 可知,当嵌入 率=0.1 时,特征维数由 35263 降到 2723,其对隐写 图像的检测正确率从 0.5268 提高到 0.5531;当嵌入 率=0.80 时,特征维数由 35263 降到 21215,其对隐 写图像的检测正确率从 0.9115 提高到 0.9146;由此 可知,本文方法在显著降低 J+SRM 特征维数的情况 下,依然能够提高对隐写图像的检测准确率

存储 10000 幅图像一个嵌入率的 35263 维 J+SRM 隐写检测特征,就需 1G 多的存储空间。下 面我们对比了基于 W2ID-α 方法选取 J+SRM 隐写检 测特征前后的存储空间。当选取前后的特征对隐写 图像的检测正确率相当时,所需存储空间的对比结 果如下图 6 所示。图中,横轴表示嵌入率,纵轴表 示占用的存储空间, 表示原始特征, 。表示选取后的

从图 6 可知,10000 幅隐写图像的 J+SRM 特征 共占用了 6G 多的存储空间(包括五个不同嵌入率); 选取后,每个嵌入率下特征的存储空间都大幅度地 降低了。例如:当嵌入率=0.25 时,选取后的 J+SRM 特征 需要的存储空间从 1.1479G 直接下降到 0.0210G,比选取前节省了 1.1269G 的存储空间。由 此可知,基于 W2ID-α 方法约简后能够大幅度降低 J+SRM 隐写检测特征所需的存储空间。

5.5 GFR隐写检测特征的选取实验

为了捕捉信息嵌入给图像统计特征带来的变化, 文献[6]采用 2D Gabor 滤波器提取 GFR^{Error!} Reference source not found.隐写检测特征,分别从 5 种不同角 度提取特征子集, 5 个子集共提取特征的维数高达 17000 维。与 5.4 相同,基于 W2ID-α 方法对质量因 子 95 的 0.1, 0.25, 0.5, 0.8 和 1.0 等五种嵌入率的 GFR 特征进行特征选取实验。

图 7 为嵌入率分别是 0.1, 0.25, 0.5, 0.8 和 1.0 下的 GFR 隐写检测特征选取前后对隐写图像的检测 效果,图中符号含义与图 5 相同。由图 7 可知,当 嵌入率=0.1 时,特征维数从 17000 维降到 12848,检 测正确率从 0.5182 提高到 0.5220;当嵌入率=1.0 时, 特征维数从 17000 维降到 9157,检测正确率从 0.9661 提高到 0.97。由此可知,本文方法在显著降低 GFR 特征维数的情况下,依然能够提高对隐写图像的检 测准确率。



图 8 基于 W2ID-α 方法约简前后存储空间的对比结果(GFR 特征)

存储5个嵌入率下10000幅图像的17000维GFR 隐写检测特征,需2G多的存储空间。下面我们对比 了基于 W2ID-α 方法选取 GFR 隐写检测特征前后的 存储空间。当选取前后的特征对隐写图像的检测正 确率相当时,所需存储空间的对比结果如下图 8 所 示,图中符号表达含义与图6相同。

从图 8 可知, 基于 W2ID-α 方法选取后,每个嵌入 率下特征的存储空间都大幅度地降低了。例如:当 嵌入率=0.1 时,选取后的 J+SRM 特征需要的存储空 间从 0.4621G 直接下降到 0.1123G,比选取前节省了 0.3498G 的存储空间。由此可知,基于 W2ID-α 方法 约简后能够大幅度降低 GFR 隐写检测特征所需的存 储空间。

5.6 W2ID-α方法与Fisher-based方法的比较实验

与 5.1 节的实验设置相同,根据第 2 节中描述 Fisher-based 方法的过程,基于 W2ID-α 方法与 Fisher-based 方法对 17000 维的 GFR 隐写检测特征进 行对比实验。本文方法与 Fisher-based 方法在不同嵌 入率时特征维数及相应的检测正确率如表 3 所示:

表 3 本文方法与	i Fisher-based	方法的对比实验结果
-----------	----------------	-----------

嵌ノ	、率	0.1	0.25	0.5	0.8	1.0
Fisher-	维数	16998	16998	16998	12748	12748
based 方法	$\overline{P_A}$	0.5210	0.5207	0.6576	0.9153	0.9695

W2ID-	维数	15816	12999	13485	9533	9157
α方法	$\overline{P_A}$	0.5214	0.5226	0.6582	0.9158	0.9700
h	人表 3	可以看	出,当日	嵌入率さ	勺 0.8 目	时,与
Fisher	-based 🕽	方法相比	, W2II)-α 方法	将特征	维数从
	<u>ун</u> - ь	## * .1	14)*		>	

12748 进一步降到 9533, 检测正确率还能从 0.9153 进一步提高到 0.9158。由此可知, 虽然 Fisher-based 方法和 W2ID-α 方法都能降低 GFR 特征的维数, 但 W2ID-α 方法在更进一步降低特征的维数得同时, 还 能进一步提高对隐写图像的检测正确率。

5.7 W2ID-α方法与PCA-based方法的比较实验

与 5.1 节的实验设置相同,基于 W2ID-α 方法与 PCA-based 方法^[10]对 J+SRM 和 GFR 两种 Rich Model 隐写检测特征进行对比实验。首先,根据 W2ID-α 方 法选取后的特征维数 *n* 确定 PCA-based 方法中主成 分的个数;其次,基于 PCA^{[12][17]}对原始特征进行线 性变换得到一组新的特征分量;然后,选取排名靠 前的 *n* 个特征分量作为被选取的特征子集,并依据 这 *n* 个特征分量对隐写图像进行分类检测。本文方 法与 PCA-based 方法在不同嵌入率时特征维数及相 应的检测正确率如图 9(a)和(b)所示:

图中,横轴表示特征的维数,纵轴表示检测正 确率,●表示原始特征维数对应的检测正确率,■表 示 PCA-based 方法约简后特征维数对应的检测正确 率,▲表示 W2ID-α 方法约简后维数对应的检测正确 率。从图 9(a)可知,嵌入率=0.5 时,基于 PCA-based 方法降维后的特征对隐写图像的检测正确率从 0.6436 下降到 0.4923; 基于 W2ID-α 方法选取后的特 征对隐写图像的检测正确率从 0.6436 上升到 0.64825。嵌入率=0.8时,基于 PCA-based 方法降维 后的特征对隐写图像的检测正确率从 0.9115 下降到 0.5055; 而基于 W2ID-α 方法选取后的特征对隐写图 像的检测正确率从 0.9115 上升到 0.9146。由此可知, PCA-based 方法在降低特征维数的时候也降低了特 征对隐写图像的检测正确率,而 W2ID- α 方法既降低 了维数又提高了检测正确率。相似地,对 GFR 特征 具有同样结论,如图 9(b)所示。

5.8 W2ID-α方法与Steganalysis-α方法的比较实验

与 5.1 节的实验设置相同, 基于 W2ID-α 方法与 Steganalysis-α 方法^[12]对 J+SRM 和 GFR 两种 Rich Model 隐写检测特征进行对比实验。

基于两种方法选取后,基于选取的特征集合对 隐写图像进行检测。对不同嵌入率下的 J+SRM 和 GFR 隐写检测特征, 以 Steganalysis-α 方法选取后特 征对隐写图像检测正确率最高时为参照对象, W2ID-α 方法与 Steganalysis-α 方法的检测效果如图 10(a)和(b)所示。

图中, 横轴表示特征的维数, 纵轴表示检测正 确率,●表示原始特征维数对应的检测正确率,■表 示 Steganalysis-α 方法约简后特征维数对应的检测正 确率,▲表示 W2ID-α 方法约简后特征维数对应的检 测正确率。从图 10(a)可知,当嵌入率=0.1 时,基于 Steganalysis-α 方法选取后, J+SRM 特征从 35263 降

到 2294, 检测正确率从 0.5268 提升到 0.5520; 而在 维数相当的情况下,基于 W2ID-α 方法选取后的检测 正确率又进一步提升到 0.5531。当嵌入率=1.0 时, 基于 Steganalysis-α方法选取后, J+SRM 特征从 35263 维降到 24153, 检测正确率从 0.9764 提高到 0.9768; 在维数更低的情况下,基于 W2ID-α 方法选取后特征 对隐写图像的检测正确率进一步提高到 0.9774。从 图 10(b)可知,当嵌入率=0.1 时,基于 Steganalysis-a 方法选取后, GFR 特征从 17000 维降到 15493, 检测 正确率提高到 0.5169; 维数相当的情况下, 基于 W2ID-α 方法选取后,特征对后的检测正确率提高到 0.5214。当嵌入率=1.0 时, 基于 Steganalysis-α 方法 选取后, GFR 特征的维数降到 10092, 检测正确率提 高到 0.9697; 在维数降得更低后, 基于 W2ID-α 方法 选取后特征对隐写图像的检测正确率进一步提高到 0.97。由图 10 可知,对于 J+SRM 和 GFR 特征, Steganalysis-α 方法和 W2ID-α 方法都能够降低特征 维数并提高特征对隐写图像的检测正确率,但 W2ID-α 方法的效果更好。造成两种方法最终效果不 同的主要原因在于:

(1) 采用的可分性度量准则的不同, $W2ID-\alpha$ 采用的准则是 W2ID 准则, Steganalysis-α 方法采用 的是ASM准则。W2ID准则比ASM准则度量的更加 准确,为约简提供了更加准确的方向;

(2) 采用的策略不同。Steganalysis-α 方法采用 一次删除一个特征分量,并需要根据经验设置阈值, 删除无用特征; 而 W2ID-α 方法一次处理一组特征分 量,无需设置经验阈值,不会因阈值设置不当造成 有用特征分量被删除而导致检测正确率下降。



图 9 本文方法与 PCA-based 方法的对比实验结果



图 10 本文方法与 Steganalysis-α 方法的对比实验结果

6 结束语

为了降低图像 Rich Model 隐写检测特征维数, 提高隐写检测效率并降低存储开销,本文在分析现 有 Fisher-based 特征选取方法原理及不足的基础上, 提出了一种基于 W2ID 准则的隐写检测特征选取方 法。该方法利用加权的类间距离和类内距离差异构 造了 W2ID 准则来区分在载体和隐写图像集合中具 有相同平均值的隐写检测特征分量的可分性。同时, 给出了频数统计加权法为 W2ID 分配合理权重。然 后,依据 W2ID 准则的度量结果,基于改进的决策 粗糙集 α-正域约简隐写检测特征对隐写检测特征分

参 考 文 献

- A. D. Ker, P. Bas, S. Craver, and J. Fridrich. Moving steganography and steganalysis from the laboratory into the real world. //Proceedings of the ACM Workshop on Information Hiding and Multimedia Security, Montpellier, USA, 2013: 45-58.
- [2] X. Y. Luo, F. L. Liu, S Lian, et al. On the typical statistic features for image blind steganalysis, *IEEE Journal on Selected Areas in Communications*, 29(7):1404-1422, 2011.
- [3] J. Fridrich and J. Kodovský. Rich Models for steganalysis of digital images, *IEEE Transactions on Information Forensics and Security*,7(3),2011:868-882.
- [4] V. Holub, J. Fridrich. Random projections of residuals for digital images steganalysis, *IEEE Transactions on Information Forensics and Security*, 8(12), 2013:1996-2006
- [5] J. Kodovský and J. Fridrich. Steganalysis of JPEG images using Rich Models, //Proceedings of the SPIE Electronic Imaging. International Society for Optics and Photonics, Burlingame, USA, 2012: 1-13.
- [6] X. F. Song, F. L. Liu, X. Y. Luo and Y Zhang. Steganalysis of adaptive JPEG steganography using 2D gabor filters,"//Proceedings of the ACM Workshop on Information Hiding and Multimedia Security, New York, USA, 2015:15-23.
- [7] T. Filler, J. Fridrich. Gibbs construction in steganography, *IEEE Transactions on Information Forensics and Security*, 5(4),2010:705-720
- [8] V. Holub, J. Fridrich. Designing steganographic distortion using directional filters, //Proceedings of the IEEE

量进行选取。基于两类典型的图像 Rich Model 隐写 检测特征(35263-D J+SRM 特征和 17000-D GFR 特 征)进行的一系列特征选取实验,验证了所提方法 的有效性,如:对嵌入率 0.1 的 SI-UNIWARD 隐写 图像,基于本文提出的 W2ID-α 方法将 J+SRM 特征 从 35263 维降到 272 维,节省了 1G 以上的存储空间, 同时提高了 3.63%的检测正确率。实验结果还表明, 该方法在提高检测精度和降低特征维数方面优于传 统 Fisher-based 方法、现有的 PCA-based 方法和 Steganalysis-α 方法。

在今后的工作中,我们将继续研究如何度量隐写 检测特征的相关性和如何进一步提高特征提取和载 体图像检测的效率。

Workshop on Information Forensic and Security. Costa Adeje, Tenerife, Spain, 2012: 234-239.

- [9] V. Holub, J. Fridrich, T.Denemark. Universal distortion function for steganography in an arbitrary domain, *EURASIP Journal on Information* Security,11(1),2014:1-13
- [10] J. H. Qin, X. M. Sun, X. Y. Xiang, et al. Principal feature selection and fusion method for image steganalysis, *Journal of Electronic Imaging*, 18(3),2009: 033009
- [11] J. C. Lu, F. L. Liu, X. Y. Luo. Selection of image features for steganalysis based on the fisher criterion, *Digital Investigation*, 11(1),2014: 57-66
- [12] Y. Y. Ma, X. Y. Luo, X. L. Li, Z. K. Bao, and Y. Zhang. Selection of Rich Model Steganalysis Features Based on Decision Rough Set -Positive Region Reduction, IEEE Transactions on Circuits and Systems for Video Technology, DOI 10.1109/TCSVT.2018.2799243.
- [13] S. Theodoridis, K. Koutroumbas. Pattern Recognition, 2nd ed. New York: Academic Press, 2003. pp. 177-179.
- [14] X. Y. Jia, L. Shang, B. Zhou, Y. Y. Yao. Generalized attribute reduct in rough set theory, *Knowledge-Based Systems*, 91(c) ,2016:204-218
- [15] Y. Y. Yao, X. Y. Zhang. Class-specific attribute reducts in rough set theory, *Information Sciences*, 41(8), 2017: 601-618
- [16] P. Bas, T. Filler, T. Pevn ý. Break Our Steganographic System: The Ins and Outs of Organizing BOSS, Journal of the American Statistical Association, 96(454),2011: 488-499.
- [17] E. Oja. Principal components, minor components, and linear neural network. *Neural Networks*, 5(6), 1992: 927-935.

Ma Yuanyuan, born in 1981, Ph. D., lecturer. Her research interests include is image steganalysis technique.

Xu Jiucheng, born in 1964, Ph. D., professor. His research interests are rough set and granular calculation.

Background

Steganalysis features selection is an important reseach direction in information security, which can help to detect secret information quickly and effectively.

Steganography technique is also easy to be used by lawbreakers, engaging in illegal activities that undermine social stability and national security. Steganalysis technique concentrates on the detection and extraction of secret messages embedded in digital media and transmitted through a public channel. It maintains network information security and social security and stability.

In recent years, steganalysis technology based on high-dimensional Rich Model features are proposed to improve the detection accuracy on stego images generated by adaptive steganography, and achieves excellent detection performance. However, the dimensions of Rich Model steganalysis features are always very high. And it often takes about over weeks to finish a group of steganalysis experiments. This restricts



the development and application of image steganography detection technology. Reducing the dimensions of the existing Rich Model features without affecting the detection efficiency is valuable for steganalysis. Therefore, it has become an urgent

problem for the steganalysis field to reduce the dimension of Rich Model features and maintain detection efficiency.

Recently. researchers have proposed some techniques to reduce the dimensions of steganalysis features. However, there are still some problems existing typical steganalysis feature selection methods, e.g. conflicting steganalysis feature components cannot removed, inaccuracy of measuring separability, dependency of empirical parameters, the feature dimension is still high and the detection accuracy is not high. To this end, this paper proposes a steganalysis feature selection method based on W2ID criterion. This method would solve the problems of existing typical steganalysis feature selection methods.

Zhang Yi, born in 1991, Ph. D. candidate. Her research interests are image steganography and steganalysis technique.

Yang Chunfang, born in 1983, Ph. D., associate professor. His research interests are image steganography and steganalysis technique.

Luo Xiangyang, born in 1978, Ph. D., professor. His research interests are network information security.

This research group mainly study image steganography, steganalysis and steganalysis feature selection. And publishing a large number of papers in related fields, such as: "selection of Rich Model steganalysis features based on decision rough set α -positive region reduction", "selection of image features for steganalysis based on the fisher criterion", "on the typical statistic features for image blind steganalysis", "a review on blind detection for image steganography" and so on. And the paper of "selection of Rich Model steganalysis features based on decision rough set α -positive region reduction" is selected into ESI "highly cited paper" and "hot paper".

This work was supported by the National Natural Science Foundation of China (No. U1804263, U1636219, 61772549, 1736214, 61872448), the National Key R&D Program of China (No.2016YFB0801303, 2016QY01W0105) the Outstanding Talent Support Program of Henan Province (No. 184200510018), the Key Scientific and Technological Project of Henan Province (No. 202102210165).