

基于多核 Fisher 判别分析的人脸特征提取

王 昕 刘 颖 范九伦

(西安邮电学院通信与信息工程学院 西安 710121)

摘 要 核 Fisher 判别分析法是一种有效的非线性判别分析法。传统的核 Fisher 判别分析仅选用单个核函数,在人脸特征提取方面仍显不足。鉴于此,提出多核 Fisher 判别分析法,即通过将多个单核 Fisher 判别得到的投影进行加权组合得到加权投影,以加权投影为依据进行特征提取和分类。实验表明,在进行人脸特征提取和分类时,多核 Fisher 判别分析法优于单核 Fisher 判别分析法。

关键词 多核学习,核方法,人脸特征提取

Face Feature Extraction Based on Weighted Multiple Kernel Fisher Discriminant Analysis

WANG Xin LIU Ying FAN Jiu-lun

(School of Communication and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China)

Abstract Kernel Fisher discriminant analysis method is an effective nonlinear discriminant analysis method. Tradition kernel Fisher discriminant analysis uses only single kernel function, which makes it insufficient in face feature extraction, therefore we proposed multiple kernel Fisher discriminant analysis. Weighted projections were obtained through weighted combination several projections obtained by single kernel Fisher discriminant, and then feature extraction and classification were made based on the weighted projections. Experimental results show that weighted multiple kernel Fisher discriminant analysis method is superior to single kernel Fisher discriminant analysis for facial feature extraction and classification.

Keywords Multiple kernel learning, Kernel methods, Facial feature extraction

1 引言

人脸特征提取是进行人脸检测的重要环节^[1]。进行人脸检测的主要依据是人脸和非人脸之间存在着差异。由于人脸图像数据的维数较高,如果不进行降维处理,那么所需的计算时间和存储空间将十分巨大,因此进行人脸检测时常常需要进行特征提取。人脸特征提取的目的就是以人脸数据集和非人脸数据集为基础,找出能够区分人脸与非人脸的特征,并以所提取的特征作为判断待测子窗口中是否含有人脸的依据。

Fisher 判别分析法作为一种经典的模式分类算法,从 1936 年 R. A. Fisher 在他的经典论文中提出以来,一直在线性分类和提取线性特征领域中表现优异^[2]。但是,图像数据中还存在非线性特征, Fisher 判别分析对于含有非线性特征的数据的判别效果并不理想。为了将 Fisher 判别分析方法可以应用到非线性数据的处理中, Mika 等人将 Fisher 与 SVM 中的“核技术”相结合,对 Fisher 判别分析进行了非线性推广^[3]。核 Fisher 判别分析的基本思想是:用非线性映射 Φ 将原始训练数据映射到高维甚至是无限维的特征空间 Γ 中,使得原始训练数据在特征空间 Γ 中是线性可分的,然后在特征空间 Γ 中进行 Fisher 线性判别分析,这样间接地在原始空

间中对训练数据进行了非线性判别。

基于单个特征空间的单核方法在特征提取方面仍有不足。核矩阵是原始数据间关系在高维特征空间中的间接反映,不同的核矩阵表示会将原始数据映射到不同的特征空间。选用单核函数,只是考虑将原始数据映射到某一个高维特征空间中,当原始数据的特征含有异构信息,样本规模很大,多维数据不规则或数据在高维特征空间分布不平坦时^[4],在单个特征空间对样本数据进行的处理并不合理。

本文提出一种不同于基本核函数凸组合的多核方法^[4],该方法不先将多个不同核矩阵组合成新的核矩阵,再运用核 Fisher 得到一个投影向量;而是将多个核矩阵先进行核 Fisher 得到多个投影,再将所得到的投影进行加权组合得到加权投影。先计算出投影分量,可以将分类正确率过低的投影去除,因此本文方法可以避免将分类效果不好的核矩阵进行组合。

2 核 Fisher 判别分析法

2.1 单核 Fisher 判别分析法

设 Φ 是将训练样本映射到特征空间 Γ 的非线性映射,则训练样本 $x = \{X_1, X_2, \dots, X_M\} \in R^N$ 经过 Φ 的映射变成:

$$\Phi(X) = \{\Phi(X_1), \Phi(X_2), \dots, \Phi(X_M)\} \in \Gamma \quad (1)$$

到稿日期:2011-11-02 返修日期:2012-03-02

王 昕(1986-),男,硕士生,主要研究方向为图像处理,E-mail:wangxin-bear@163.com;刘 颖(1972-),女,博士后,高级工程师,主要研究方向为语义图像检索、模式识别;范九伦(1964-),男,博士后,教授,博士生导师,主要研究方向为模式识别与图像处理。

在特征空间中进行 Fisher 判别分析即求下面准则函数的极大值:

$$J(w) = \frac{w^T S_b^{\Phi} w}{w^T S_w^{\Phi} w} \quad (2)$$

式中, $w \in \Gamma$, S_b^{Φ} , S_w^{Φ} 是特征空间中与欧式空间中 S_b , S_w 相对应的矩阵, S_b^{Φ} 是核类间散布矩阵, S_w^{Φ} 是核类内散布矩阵, 其定义如下:

$$S_b^{\Phi} = (m_1^{\Phi} - m_2^{\Phi})(m_1^{\Phi} - m_2^{\Phi})^T \quad (3)$$

$$S_w^{\Phi} = \sum_{i=1,2} \sum_{x \in H_i} (\Phi(x) - m_i^{\Phi})(\Phi(x) - m_i^{\Phi})^T \quad (4)$$

式中, $m_i^{\Phi} = \frac{1}{l_i} \sum_{j=1}^{l_i} \Phi(x_j^i)$.

特征空间 Γ 的维数可能会比较高, 甚至是无限的, 根本无法直接求解出 $J(w)$ 的极大值。借鉴支持向量机中的“核函数” $k(x, z) = (\Phi(x) \cdot \Phi(z))$, 就可以不考虑非线性映射, 而间接地在特征空间中完成 Fisher 判别分析。核函数很多, 本文中选用核函数是高斯核函数:

$$k(x, z) = \exp(-\|x - z\|^2 / \sigma) \quad (5)$$

式中, σ 是核参数。

为了求得特征空间 Γ 中的 Fisher 判别, 需要将式(2)转换成由核函数和输入空间表达的式子。根据再生核理论^[5]可知, 式(2)的任一最优矢量解 $w^* \in \Gamma$ 位于由特征空间 Γ 的所有训练样本 $\Phi(X_i)$ ($i=1, 2, \dots, M$) 张成的空间内, 则 w 可以展开表示为:

$$w = \sum_{i=1}^M \alpha_i \Phi(X_i) \quad (6)$$

由 w 的展开式和 m_i^{Φ} 的定义有:

$$w^T m_i^{\Phi} = \frac{1}{l_i} \sum_{j=1}^M \sum_{k=1}^{l_i} \alpha_j k(x_j, x_k^i) = \alpha^T A_i \quad (7)$$

用 $(A_i)_j$ 表示 A_i 的第 j 个元素, $(A_i)_j = \frac{1}{l_i} \sum_{k=1}^{l_i} k(x_j, x_k^i)$.

A_i 表示 K_i 的列均值, K_i 是核矩阵 K 的第 i 类数据所占列组成的 $N \times l_i$ 维矩阵。考虑式(2)的分子, 利用 S_b^{Φ} 的定义式(3)和式(7), 有:

$$w^T S_b^{\Phi} w = \alpha^T A \alpha \quad (8)$$

式中, $A = (A_1 - A_2)(A_1 - A_2)^T$ 。考虑式(2)的分母, 利用 S_w^{Φ} 的定义式(4)和式(7)有:

$$w^T S_w^{\Phi} w = \alpha^T B \alpha \quad (9)$$

式中, $B = \sum_{i=1,2} K_i (I - 1_{l_i})(I - 1_{l_i})^T K_i^T$, I 是单位阵, 1_{l_i} 是元素全为 $\frac{1}{l_i}$ 的矩阵。由以上推导, 式(2)可以写成:

$$J(\alpha) = \frac{\alpha^T A \alpha}{\alpha^T B \alpha} \quad (10)$$

式中, α 是 N 维非零列矢量, 式(10)是核 Fisher 判别准则函数。

在 B 为非奇异矩阵的条件下, 由 Fisher 线性判别^[2]的结论可知, $\alpha^* = B^{-1}(M_1 - M_2)$ 是使式(10)取到极大值的向量。但是, A, B 均是 $N \times N$ 维矩阵, 它们的秩满足^[2]:

$$\text{rank}(A) \leq C - 1, \text{rank}(B) \leq N - C \quad (11)$$

式中, N 是样本维数, C 是分类类别个数, 所以 B 是奇异矩阵, 无法直接求解核 Fisher 判别准则函数。为了解决 B 的奇异性问题, 一般运用正则化的方法^[6], 对 B 做如下运算, 使 B

变成非奇异阵:

$$B = B + \mu I \quad (12)$$

式中, μ 是常数, 一般取 $\mu = 10^{-3}$, I 是单位阵。很容易证明, 式(12)是非奇异阵。新的样本 y 投影到 w 的向量可由式(13)计算得到:

$$(W \cdot \Phi(y)) = \sum_{i=1}^M \alpha_i k(X_i, y) \quad (13)$$

2.2 多核 Fisher 判别分析

近来的理论和应用已经证明, 利用多核代替单核能够增强决策函数的可解释性, 并获得优于单核情况的分类性能。因此, 将多个核函数进行组合以获取更优的特征提取效果是一种必然选择^[4]。本文将 SVM 中的多核方法运用到 Fisher 判别分析中, 提出一种新的加权多核 Fisher 判别分析方法。其基本思想为: 选择不同的核参数构造出多个单核函数, 利用单核 Fisher 判别每个核函数均可以得到一个投影映射, 选择一组合适的权值将得到的投影映射进行加权组合得到一个新的投影映射, 称之为加权投影映射, 如图 1 所示。




图 1 加权多核 Fisher 判别示意图

令由多核 Fisher 判别得到的加权投影映射为:

$$W = \sum_{j=1}^L \beta_j W_j \quad (14)$$

式中, β_j 为权值系数, W_j 是由单一核函数得到的投影映射, L 是单核函数得到的投影映射的个数, 一般要求 L 是大于 3 的奇数。令 Y_i 为某个待分类样本, 则:

$$K_i = [\Phi(X_1) \cdot \Phi(Y_i), \Phi(X_2) \cdot \Phi(Y_i), \dots, \Phi(X_M) \cdot \Phi(Y_i)]$$

是样本与训练样本在特征空间的内积表示, 有:

$$W'K_i = \sum_{j=1}^L \beta_j W_j'K_i = \sum_{j=1}^L \beta_j (W_j'K_i) \quad (15)$$

很显然, 用加权投影映射给某个样本分类, 实质上就是多个单核函数的投影映射利用“投票策略”对样本进行分类。运用“投票策略”来确定样本的分类能够减少错分率, 从而提高分类正确率。

3 仿真实验

实验选择 MIT 的人脸库^[5], 其中有 2706 张人脸图像, 4381 张非人脸图像, 所有图像大小均为 20×20 。从人脸图像中随机选择 451 张图像, 非人脸图像中随机选择 731 张图像作为训练样本, 其余的 5905 张图像作为检测样本。

由单核 Fisher 的推导过程可知, 投影映射分类性能的优劣由核函数矩阵决定。因此, 如何选择核参数以获得合适的核函数矩阵是首先要解决的问题。核参数的选择对于核函数矩阵的影响很大, 如果核参数选择过小, 则核函数矩阵会退化成单位阵; 如果核参数选择过大, 则核函数矩阵会退化成全部元素为 1 的矩阵。

图2左图是核函数矩阵为单位阵时用单核Fisher判别分析进行特征提取的分类结果,图2右图是核函数矩阵为全部元素为1的矩阵时的结果。可以看出,核函数矩阵为单位阵时所提取的特征虽然有很好的分类效果,但是没有表现出类内样本的差异。核函数矩阵为全部元素为1的矩阵时,人脸样本和非人脸样本完全混淆在一起。因此,选择的核参数必须要使得核函数矩阵大多数元素值属于(0,1)之间,这样才能很好地反映出样本间的相似性,得到一个既能反映出类内样本的差异,又能将样本完全分类的投影映射。




图2 核参数选择过大或过小的训练样本分类情况

令 $Q_{ij} = \|x_i - x_j\|^2$, 则 Q 是 $M \times M$ 的矩阵, 高斯核函数可表示成:

$$k(x_i, x_j) = \exp(-Q/\sigma) \quad (16)$$

以矩阵 Q 的平均值作为基本核参数, 即 $\sigma = \frac{1}{M \times M} \sum_{i=1}^M \sum_{j=1}^M Q_{ij}$, 对于给定的训练样本集, 矩阵 Q 和基本核参数 σ 是已经确定的。通过给 σ 乘以不同的系数 k 可以得到不同的核参数, 在本文中用核参数系数间接地表示核参数。根据本文所选择训练样本集的实际情况可知, 当 $k=0.01$ 时, 核函数矩阵趋近于单位阵; 当 $k=100$ 时, 核函数矩阵趋近于元素均为1的矩阵。

从图3可以看出, 不同的核参数系数对于分类正确率的影响很明显。在单核函数的情况下, 测试数据的分类正确率最高是91.89%。由于选择分类正确率太低的核参数系数对于提升加权投影的分类正确率作用不大, 因此选择分类正确率大于78%的核参数系数, 即 $k \in (0.25, 2.1)$ 。




图3 核参数系数与分类正确率的关系

对于加权分量个数 L , 由图1可知, 需在 $k \in (0.25, 2.1)$ 中选择 L 个互不相同的核参数系数计算出 L 个不同的加权分量。采用两种随机选择的方法来得到 L 个不同的核参数系数: 一种是全局随机选择, 即 L 个核参数系数都在区间 $(0.25, 2.1)$ 内随机选择; 另一种是局部随机选择, 即将区间 $(0.25, 2.1)$ 分成 L 个不重叠的等长区间, 在每一个小区间内随机选择一个核参数系数。

令 $Rl_i (i=1, \dots, L)$ 为第 i 个加权投影分量对测试数据的分类正确率, 记 $Rl = \sum_{i=1}^L Rl_i$, 则单核投影的加权系数设为 $\beta = \frac{Rl_i}{Rl}$ 。

本文的实验平台软件环境为 Windows XP Professional Service Pack 2, Matlab 2007a; 硬件环境为 Intel Core T6570 2.10GHz cpu, 2G 内存。

在本文中, 令加权分量个数 $L=3, 5, 7, 9$ 。在每一个不同 L 值的情况下, 用全局随机法和局部随机法分别随机选取3000组的核参数系数组合。

表1和表2是运用加权多核Fisher判别分析法进行分类的正确率分布情况。从表1和表2可以看出: 本文的方法不会低于所限定的分类正确率下限, 即本文的方法不存在降低分类正确率的可能性; 本文的方法得到的分类正确率能够高于单核情况下最高的分类正确率, 即本文的方法能够提高分类正确率。如果考虑分类正确率的稳定性而不是追求最高的分类正确率, 则加权分量个数越多算法性能越好, 局部随机选择法优于全局随机选择法。随着加权分量个数的增加, 最高分类正确率呈下降趋势, 这是因为“投票策略”具有平均化的思想, 投票个体越多平均化程度越高, 自然会降低最高分类正确率, 提高分类结果的稳定性。

表1 全局随机选择核参数系数的分类正确率情况

| L | 最高分类正确率 | 分类正确率大于94% | | 分类正确率大于91.89% | | 分类正确率大于78% | |
|---|---------|------------|--------|---------------|--------|------------|------|
| | | 个数 | 比例 | 个数 | 比例 | 个数 | 比例 |
| 3 | 95.22% | 241 | 8.03% | 827 | 27.57% | 3000 | 100% |
| 5 | 95.16% | 435 | 14.5% | 1227 | 40.9% | 3000 | 100% |
| 7 | 95.07% | 547 | 18.23% | 1420 | 47.33% | 3000 | 100% |
| 9 | 95.12% | 679 | 22.63% | 1649 | 54.97% | 3000 | 100% |

表2 局部随机选择核参数系数的分类正确率情况

| L | 最高分类正确率 | 分类正确率大于94% | | 分类正确率大于91.89% | | 分类正确率大于78% | |
|---|---------|------------|--------|---------------|--------|------------|------|
| | | 个数 | 比例 | 个数 | 比例 | 个数 | 比例 |
| 3 | 95.28% | 743 | 24.77% | 1153 | 55.1% | 3000 | 100% |
| 5 | 95.07% | 1348 | 44.93% | 1951 | 65.03% | 3000 | 100% |
| 7 | 95.01% | 1489 | 49.63% | 2118 | 70.6% | 3000 | 100% |
| 9 | 94.95% | 1538 | 51.27% | 2428 | 80.93% | 3000 | 100% |

表3 权值系数列表(5个分量, 全局随机法)

| 权值系数 | std | W |
|--|--------|--------|
| (0.2031, 0.2012, 0.1996, 0.1983, 0.1979) | 0.0021 | 0.8000 |
| (0.1990, 0.1985, 0.1973, 0.2014, 0.2038) | 0.0026 | 0.8147 |
| (0.1898, 0.1945, 0.1940, 0.2138, 0.2079) | 0.0103 | 0.8200 |
| (0.1880, 0.1957, 0.2118, 0.2094, 0.1951) | 0.0102 | 0.8212 |
| (0.1964, 0.2045, 0.1957, 0.2011, 0.2024) | 0.0038 | 0.8213 |
| (0.2057, 0.1903, 0.1949, 0.2082, 0.1982) | 0.0067 | 0.9504 |
| (0.2042, 0.1897, 0.1963, 0.1982, 0.2115) | 0.0083 | 0.9504 |
| (0.1913, 0.2213, 0.1917, 0.2013, 0.1944) | 0.0081 | 0.9507 |
| (0.1993, 0.1912, 0.1977, 0.2085, 0.2034) | 0.0065 | 0.9511 |
| (0.1973, 0.1877, 0.2009, 0.2053, 0.2089) | 0.0081 | 0.9516 |

表4 权值系数列表(5个分量, 局部随机法)

| 权值系数 | std | W |
|--|--------|--------|
| (0.1863, 0.2155, 0.1903, 0.1985, 0.2094) | 0.0124 | 0.8384 |
| (0.1896, 0.2193, 0.1937, 0.1969, 0.2006) | 0.0115 | 0.8384 |
| (0.1887, 0.2175, 0.1915, 0.1980, 0.2043) | 0.0115 | 0.8386 |
| (0.1913, 0.2213, 0.1917, 0.2013, 0.1944) | 0.0125 | 0.8388 |
| (0.1887, 0.2195, 0.1916, 0.1986, 0.2016) | 0.0121 | 0.8389 |
| (0.2016, 0.1982, 0.1925, 0.1960, 0.2118) | 0.0074 | 0.9494 |
| (0.2021, 0.2034, 0.1893, 0.1960, 0.2091) | 0.0076 | 0.9494 |
| (0.2027, 0.1965, 0.1908, 0.2022, 0.2077) | 0.0065 | 0.9495 |
| (0.2000, 0.2129, 0.1878, 0.1959, 0.2035) | 0.0093 | 0.9497 |
| (0.1993, 0.2123, 0.1872, 0.2013, 0.1999) | 0.0089 | 0.9507 |

表3、表4是 $L=5$ 时的部分权值系数列表, 选择了最小

和最大的 5 个分类正确率所对应的权值系数,其中表 3 是采用全局随机法的情况,表 4 是采用局部随机法的情况, std 表示权值系数的标准差, W 是最终分类正确率。从表 3、表 4 可以看出:分类正确率较小的权值系数标准差过大(大于 0.01)或过小(小于 0.005),而分类正确率较大的权值系数标准差集中在区间(0.005, 0.01)内,当 $L=3, 7, 9$ 时此规律也基本符合。也就是说,权值系数既不能过于集中也不能过于分散,必须在一定的离散范围内。其原因在于,权值系数是根据每个加权分量对测试数据的分类正确率决定的,权值的大小和分类正确率成正比关系。权值系数过于集中,则说明所有加权分量的分类正确率都比较接近,而相近分类正确率在“投票策略”中贡献相近,可以认为只有一份贡献,变相地降低了加权分量的个数;权值系数过于分散,则说明有一个加权分量的分类正确率过低,它在“投票”过程中所能起的作用十分有限,甚至可能起负作用。

结束语 核 Fisher 判别分析法是一种有效的提取非线性特征的方法。本文提出一种加权多核 Fisher 判别分析方法。所提方法通过将多个由单核 Fisher 得到的投影映射进行加权组合,得到一个加权投影映射,以加权投影来提取测试数据的特征并进行分类。实验结果表明,加权多核 Fisher 判别具有优于单核 Fisher 判别的分类正确率。

在加权多核 Fisher 判别的实现中,核参数系数组合的选择是关键。本文中,在限定的不重叠区间内随机选择核参数系数进行加权多核 Fisher 判别得到的分类正确率有很大几

率高于单核 Fisher 判别的最高分类正确率。是否能够进一步细化限定区间,使得从细化的限定区间内随机选择核参数系数进行加权多核 Fisher 判别得到的分类正确率一定高于单核 Fisher 的最高分类正确率,是要进一步研究的问题。另外,选择不同形式的核函数计算投影分量能否提高分类正确率,也是需要进一步研究的问题。

参 考 文 献

- [1] 葛薇,程宇奇,刘春香,等. 基于子空间的人脸识别算法研究[J]. 中国光学和应用光学, 2009, 2(5): 377-387
- [2] 边肇祺,张学工. 模式识别(第 2 版)[M]. 北京:清华大学出版社, 2000
- [3] Mika S, Ratsch G, Weston J, et al. Fisher discriminant analysis with kernels[C]//Proceedings of IEEE International Workshop on Neural Networks for Signal Processing. Madison, Wisconsin: IEEE, 1999: 41-48
- [4] 汪洪桥,张富春,蔡艳宁,等. 多核学习方法[J]. 自动化学报, 2010, 36(8): 1037-1050
- [5] John S T, Nnello C. Kerenl methods for pattern anlysis[M]. Beijing: China Machine Press, 2005
- [6] 李映,焦李成. 基于核 Fisher 判别分析的目标识别[J]. 西安电子科技大学学报, 2003, 30(2): 180-182
- [7] MIT-CBC. MIT-CBCL Face Data [DB/OL]. <http://cbcl.mit.edu/cbcl/software-datasets/FaceData2.html>, 2000

(上接第 256 页)

图 14 中横坐标为 0 点的速度是未嵌入本系统时的测试文件写入速度。可以看出,写入速度并不完全与被保护文件的大小呈简单关系,反复测试结果与图示大体是一致的。但总体上写入速度随被保护文件的增大而降低,上述测试点的平均速度约降低了 4%,对用户影响不大。

横坐标为 0 点的速度是未嵌入本系统时的测试文件的读取速度。与写入时情况有些类似,读取速度也不是与被保护文件的大小呈简单关系,反复测试结果与图示大体是一致的。但总体上读取速度随被保护文件的增大而降低,上述测试点的平均速度约降低 10%左右,数据反映出其对系统具有一定的影响,但在用户使用中感觉并不明显。

对于读写速度未呈现设想的变化,可能的原因是虚拟机所建造的环境是基于宿主机之上的,非完全预期的结果尚不能确定是否来自于虚拟机的运行机制以及 iozone 测试工具的原因。但总体的测试数据显示基于虚拟机监控器的文件完整性监控系统对性能的影响在可以接受的范围之内。

结束语 本文提出了一种基于虚拟机监控器的文件完整性监控方法,并设计了代码来加以实现。通过实验可知,该系统能够对用户所配置的访问控制列表中的文件提供预期的、可靠的保护,并且解决了基于主机的文件完整性监控系统 and 基于虚拟机的完整性监控系统自身受到恶意代码攻击的问题,是一种为用户重要的敏感文件提供安全保护的可靠工具。其缺点是,对新加入的保护文件,系统需要重新启动才能生效,这是系统下一步需要改进的地方。同时,系统性能上也可以进一步进行优化。

参 考 文 献

- [1] 冯力. TripWire 在入侵检测系统中的应用[J]. 信息安全与通信保密, 2002(5)
- [2] Kim G H, Spafford E H. The design and implementation of tripwire: A file system integrity checker[C]//2nd ACM Conference on Computer and Communications Security. Fairfax: ACM, 1994: 18-29
- [3] Quynh N A, TakeFuji Y. A real-time integrity monitor for Xen virtual machine[C]//Proceedings of the 1st ACM Workshop on Virtual Machine Security. New York: ACM, 2009: 1-10
- [4] Quynh N A, Takefuji Y. A novel approach for a file-system integrity monitor tool of Xen virtual machine[C]// 2nd ACM Symposium on Information. Computer and Communications Security. Singapore: ACM, 2007: 194-203
- [5] Jin Hai, Xiang Guo-fu, Zou De-qing, et al. A guest-transparent-file integrity monitoring method in virtualization environment [C]//Computers and Mathematics with Applications. 2010: 18-29
- [6] Riley R, Jiang X, Xu D. Guest-transparent prevention of kernel rootkits with VMM-based memory shadowing[C]//11th International Symposium on Recent Advances in Intrusion Detection. Massachusetts: Springer, 2008: 1-20
- [7] Payne B D, Carbone M, Sharif M, et al. Lares: An architecture for secure active monitoring using virtualization[C]//2008 IEEE Symposium on Security and Privacy. California: IEEE, 2008: 233-247