

小波域基于分段 Hurst 指数的视频流分类

汤萍萍^{①②} 董育宁^{*①}

^①(南京邮电大学通信与信息工程学院 南京 210003)

^②(安徽师范大学物理与电子信息学院 芜湖 241000)

摘要: 现有的视频流分类方法体现出内容依赖及特征依赖的局限性, 该文引入流量分形理论, 并在小波域内, 提出一种基于 Hurst 指数的 Fractals 分类模型以改进不足。为此, 该文首先描述流的分形性质, 定义流的 Hurst 指数, 推导小波域内 Hurst 指数的估计过程。然后, 基于代价函数优化分段目标, 用聚类差异度方法计算分段 Hurst 指数的总体差异量, 再基于最大类间方差阈值进行分析, 从而实现视频流的细粒度分类。研究表明, 该文提出的分类方法, 以随机数据的变化特性为内容, 突破了内容依赖的局限性, 解决了特征制约的瓶颈, 提高了视频流的分类效果。

关键词: 视频流; 分类; 分形; Hurst 指数; 小波

中图分类号: TN919

文献标识码: A

文章编号: 1009-5896(2017)06-1298-07

DOI: 10.11999/JEIT160745

Classifying Video Flows Based on Segmented Hurst Exponent in Wavelet Domain

TANG Pingping^{①②} DONG Yuning^①

^①(College of Telecommunications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

^②(College of Physics and Electronic Information, Anhui Normal University, Wuhu 241000, China)

Abstract: The existing methods about fine classification of video traffic suffer from a couple of serious limitations: content dependency and feature dependency. Then, theory of fractals is introduced in this paper, and in wavelet domain, a classification model named Fractals is presented based on Hurst exponent. For this purpose, fractal properties of video flows are described, the corresponding Hurst exponent is defined, and the estimated value of Hurst exponent in wavelet domain is derived. Then, the optimum segments based on cost function is analyzed, the statistical differential level is calculated with the method of clustering, and the classification results are deduced with maximum between-cluster variance threshold. The result shows that the classification method with Fractals, which takes data variability as the content, makes up for the defect of content dependency and feature dependency, and demonstrates wonderful performance when classifying video flows.

Key words: Video flow; Classification; Fractals; Hurst exponent; Wavelet

1 引言

随着 4G, 5G 技术的不断革新, 视频成为当前最热门的网络业务之一, 而且正以迅猛的势头向前发展^[1]。视频业务种类繁多, 急需对视频流量进行有效的细粒度分类管理。如视频会议、远程医疗等视频流量, 对网络的实时性要求特别高, 分秒的延迟或

画面丢失可能会导致巨大的经济损失或决策上的重大错误^[2]; 视频点播和视频直播流量所占用的带宽和需要的服务质量是不同的, 运营商希望能够根据业务类型来控制并分配带宽, 实施有区分的服务^[3]。因此, 视频流量的识别与分类成为通信领域的热门研究问题^[1]。

目前流量分类研究的一般过程, 首先是按照流的定义, 将流量分割为流, 然后再基于各种方法对流进行识别并归类^[4]。这里, 流量是单位时间通过网络设备或传输介质的信息总量; 流是具有某种相同属性的包的集合^[5], 通常被定义为一个 5 元组: $\langle \text{Src IP}, \text{Dest IP}, \text{Src Port}, \text{Dest Port}, \text{Protocol} \rangle$ 。因此,

收稿日期: 2016-07-14; 改回日期: 2017-03-01; 网络出版: 2017-04-14

*通信作者: 董育宁 dongyn@njupt.edu.cn

基金项目: 国家自然科学基金(61271233, 60972038, 61401004), 华为 HIRP 创新项目

Foundation Items: The National Natural Science Foundation of China (61271233, 60972038, 61401004), Huawei Innovation Research Program (HIRP)

视频流量分类研究主要是针对视频流的分类研究^[6]。

关于视频流的细粒度分类，当前主要是基于分类检索方法。例如，文献[7]采用基于皮肤纹理的特征分析，通过镜头边界检测以区分广告视频和非广告视频。文献[8]基于空间色彩信息，提出最大球衣颜色比例和球衣色彩比例均值等特征，基于矩阵代数针对足球视频进行分类。然而，随着研究的深入，这类方法在视频流分类时，因分类检索的“内容依赖”性导致各种局限：(1)不适合即时通讯类视频流的细粒度分类。视频的分类检索对象主要是存储在后台数据库中的视频文件，很少涉及即时通讯类视频，如视频电话、远程教学等^[9]，这些视频都是临时发起，数据边产生边发送，因此不具备完整的、稳定的待测内容^[10]。(2)实时性难以保障。分类检索方法以视频文件的实体内容为基础，具有高的时、空间复杂度^[11]，一般作为离线的分类方法，不太适合视频流量的在线检测。

于是，更多研究者开始基于流量的统计特征实现视频流的细分类。这类方法的大概过程可以描述为：首先对视频流进行观察与统计，得到大小、数据速率、持续时间、包的个数、平均大小等信息，然后根据这些统计信息提取有效特征，再结合支持向量机、决策树、神经网络等方法进行流的分类识别。例如文献[12]使用 SVM 的方法，以特定时间段内交换的数据包个数作为特征，对 P2P-TV 应用进行细粒度的分类，将其分为 PPlive, Sop Cast, TVAnts 和 Joost 4 类。文献[13]以比特率、包间隔时间、包大小等特征，采用主动和被动的技术对 Skype 流量进行深入的分析，区分语音和视频通话产生的流量。文献[14]同样以包大小为特征考察 YouTube 等应用产生的大体量的 HTTP 视频流，基于机器学习方法以及高斯混合模型对卡通，新闻，广告，音乐和体育类视频进行了分类。

然而，这类方法也普遍存在以下局限性：(1)有时甚至需要十多个特征才能辨别有限的几种类别。文献[15]利用基于相关的快速特征选择算法选择出 12 种特征识别 TCP 流。(2)有效识别前一组对象的特征往往不能有效识别后一组对象。文献[16]使用信息熵计算样本特征并基于决策树方法实现分类，因此当特征属性发生变化时需要重新生成决策树，更新计算量大。(3)缺乏对未知流的分类识别能力。文献[17]用 SVM 对已知流进行分类时，也考虑到未知流识别问题，但因为缺乏对未知流有效特征的提取，决策边缘很难确定，因此对未知流的分类性能非常有限。造成这些弊端的原因，主要是基于统计学方法的“特征依赖”性。一般来说，增加特征会获得

更好的分类效果，但是计算开销和存储开销也会指数级增长^[18]。而且特征之间是具有相关性的，特征过多将导致冗余，降低分类的准确率及效率^[19]。

针对上述分类方法因“内容依赖”及“特征依赖”导致的各种局限，本文引入流量分形理论，并提出一种基于 Hurst 指数的 Fractals 分类模型以改进不足。本文提出的分类模型，以随机数据的变化特性为内容，突破了分类检索方法的“内容依赖”性，可进行快速的在线分类检测。另一方面，该模型是基于流的分形特征进行分类，无需特征提取过程，由此解决了统计学方法的“特征依赖”性，在高可变的真实网络环境中动态性能优越。

全文具体安排如下：第 1 节引言；第 2 节给出本文的中心思想，并对 Fractals 分类模型的理论前提进行论证；第 3 节 Fractals 分类模型的建模过程；第 4 节仿真实验；最后是结论。

2 思想、理论依据

2.1 思想

组成部分以某种方式与整体相似的性质叫分形。分形维是用来定量刻画分形特征的参数，以 Hausdorff 维为例，定义：

$$D_H = \lim_{r \rightarrow 0} \frac{\ln N(r)}{\ln(1/r)} \quad (1)$$

其中， $N(r)$ 表示对象在某种尺度下的数量，随着测量尺度变小而不断增大，但对象的总体参数 D_H 保持不变，这个参数可用于表征系统的总体特征。

1993 年 Leland 等人^[20]将上述分形学概念引入网络流量，并逐渐形成流量分形理论，且一般用于流量预测、流量拥塞控制、流量变动性研究、流量过程参数估计等^[21]。

由分形理论在地质勘探、模式识别等方面的应用可知，同一分形物质在不同区域一般具有相同的分形特征，可借助分形特征进行精细的区分^[22]。另一方面，根据流量分形理论，流量在大时间尺度上具有分形特征。因此，我们提出重要推断：流的特征也是时间跨度比较长，如果流也存在分形特征，那么，这些分形特征将有助于流的细粒度分类。这就是本文的中心思想。

2.2 理论依据

流量的分形特性已经被证实^[20]，而流的分形性质此前从未被探讨，为此首先给出流的分形定义。

设 $\{Y(t)\}$ 为某区间上流的随机过程，解析度 $N = 2^n$ ，其增量过程 $\{X(t)\}$ 的取样为

$$X_k = |Y((k+1)2^{-n}) - Y(k2^{-n})| \quad (2)$$

设 $X = \{X_k, k = 0, 1, \dots, N\}$ 为流的离散随机序

列, 将流序列 X 划分成 m 个不相重叠的块, 然后对这些块进行合并操作, 可得到 m 阶聚集序列:

$$X^{(m)} = \left\{ \frac{1}{m} \sum_{i=mm-m+1}^{mn} X_i, n = 0, 1, \dots, \frac{N}{m} \right\} \quad (3)$$

对这些 m 阶聚集序列, 若存在:

$$\sigma^{(m)2} \cong \sigma^2 m^{2H-2}, \quad m \rightarrow \infty \quad (4)$$

则流 X 具有分形特性, 且刻画分形特征的 Hurst 指数为 H 。其中, $\sigma^{(m)2}$ 是 m 阶聚集序列 $X^{(m)}$ 的方差, σ^2 为原始序列方差。

下面, 是关于流分形性质的理论证明过程。

证明 1 已知流 X 的 H_X 和流 Y 的 H_Y , 则聚集流 $Z = X + Y$ 的 $H_Z = \max(H_X, H_Y)$ 。

首先, 假设 $H_X > H_Y$ 。根据流量分形理论, $\sigma_X^{(m)2} = D(X^{(m)}) \cong \sigma_X^2 m^{2H_X-2}$, 且 $\sigma_Y^{(m)2} = D(Y^{(m)}) \cong \sigma_Y^2 m^{2H_Y-2}, m \rightarrow \infty$, 那么可得: $\sigma_Z^{(m)2} = D(Z^{(m)}) = D(X^{(m)} + Y^{(m)}) = D(X^{(m)}) + D(Y^{(m)}) + 2B_{X^{(m)}Y^{(m)}}$ 。对 $\sigma_Z^{(m)2}$ 关于 m^{2H_X-2} 求极限, 可得

$$\begin{aligned} \lim_{m \rightarrow \infty} \frac{\sigma_Z^{(m)2}}{m^{2H_X-2}} &= \lim_{m \rightarrow \infty} \frac{D(X^{(m)}) + D(Y^{(m)}) + 2B_{X^{(m)}Y^{(m)}}}{m^{2H_X-2}} \\ &= \lim_{m \rightarrow \infty} \frac{\sigma_X^2 m^{2H_X-2}}{m^{2H_X-2}} + \lim_{m \rightarrow \infty} \frac{\sigma_Y^2 m^{2H_Y-2}}{m^{2H_X-2}} \\ &\quad + \lim_{m \rightarrow \infty} \frac{2B_{X^{(m)}Y^{(m)}}}{m^{2H_X-2}} \\ &= \sigma_X^2 + \lim_{m \rightarrow \infty} \sigma_Y^2 m^{2H_Y-2H_X} \\ &\quad + \lim_{m \rightarrow \infty} 2m^{2-2H_X} B_{X^{(m)}Y^{(m)}} \end{aligned}$$

注意到, $m \in \mathbb{Z}_+$, 且由流量分形理论可知, Hurst 指数满足 $0.5 < H < 1$; 且对任意独立的两个变量, 其协方差 $B_{XY} = 0$, 因此, 可得 $\lim_{m \rightarrow \infty} \frac{\sigma_Z^{(m)2}}{m^{2H_X-2}} = \sigma_X^2$, 也即 $\sigma_Z^{(m)2} \cong \sigma_X^2 m^{2H_X-2}, m \rightarrow \infty$ 。由 m 阶聚集序列推导公式可知 Hurst 指数与常数项 σ_X^2 无关, 反映的是 m 的指数项 $2H_X - 2$, 因此聚集流的 $H_Z = H_X$ 。

同理可证, 当 $H_X < H_Y$ 时聚集流的 $H_Z = H_Y$ 。

因此 $H_Z = \max(H_X, H_Y)$ 。

此外, 由上述证明过程易得到如下推论: 设 X_1, X_2, \dots, X_N 为 N 个流对应的离散序列, 其 Hurst 指数分别为 H_1, H_2, \dots, H_N , 这 N 个流形成的聚集流的 Hurst 指数 $H_t = \max(H_1, H_2, \dots, H_N)$ 。

证明 2 已知流量具有分形特性, 且其分形特征为 H_t ; 那么流也具有分形特性, 且其分形特征为 H_1, H_2, \dots, H_N 。

在证明 1 的基础上使用数学归纳法:

当 $n = 1$ 时, 即只有一个流的情况。假定此流不具备分形特性, 即对应的 H_1 值是个随机变化的量。那么, 聚合流 $H_t = \max(H_1) = H_1$, 则 H_t 也是随机变化的量, 聚合流不具备分形特性, 与已知条件相违背。因此, 流具备分形特性。

当 $n = K$ 时, 假定成立, 即流具有分形特性, 其分形特征为 H_1, H_2, \dots, H_K , 那么由证明 1 的推论可知: $H_t = \max(H_1, H_2, \dots, H_K) = H$, 是一个确切的量。

当 $n = K + 1$ 时, 假定新增流不具备分形特性, 即对应的 H_{K+1} 是个随机变化量, 由证明 1 的推论可知: $H_t = \max(H_1, H_2, \dots, H_K, H_{K+1}) = \max(H, H_{K+1})$, 则 H_t 是随机变化的量, 聚合流不具备分形特性, 与已知条件相违背。证毕

因此流具备分形特性, 且其分形特征为 H_1, H_2, \dots, H_N 。

3 Fractals 分类模型

通过 2.2 节的理论证明, 已经充分说明流具备分形性(在实验 1 中有进一步的实验验证)。因此, 我们将借助流的分形特征进行流的细粒度分类, 并形成 Fractals 分类模型如下所述。

3.1 Hurst 指数估计

在分形理论中, 用 Hurst 指数来刻画事物的分形特征。依据式(4), 在理论上要求流序列无限长, 因此在现实中只能用数值分析的方法得到其估计值。Hurst 指数的估计方法有很多种, 因为本文对流的细分类直接依赖 H 值, 于是采用 H 值相对精确的 AV 小波估计法, 下面给出其推导过程。

对于分形的流过程 $Y(t)$, 存在:

$$Y(\lambda t) = \lambda^H Y(t) \quad (5)$$

令 J 为 DWT 小波分解级数, 在特定小波级数 $j \in J$ 下, 由式(5)可以得到:

$$Y(2^j t) = 2^{jH} Y(t) \quad (6)$$

另外, 流的小波系数由式(7)定义:

$$W_{j,k} = \int Y(t) 2^{\frac{j}{2}} \psi(2^j t - k) dt \quad (7)$$

结合式(5)和式(6), 可推出流的小波系数满足:

$$W_{j,k} = 2^{\left\{j\left(H-\frac{1}{2}\right)\right\}} W_{0,k} \quad (8)$$

由此可得:

$$E|W_{j,k}|^2 = 2^{j(2H-1)} E|W_{0,k}|^2 \quad (9)$$

两端取对数:

$$\log_2 E|W_{j,k}|^2 = \log_2 c + (2H - 1)j \quad (10)$$

根据式(10), 用 LSM 方法作出 $\log_2 E|W_{j,k}|^2$ 与 j 的拟合直线, 由直线斜率 k_s 得到 Hurst 指数的估计

值 H ，两者的关系即 $k_s = 2H - 1$ 。这里，有以下几点需要特别强调：

(1)这里的推导过程是基于流的连续函数 $Y(t)$ ，在后续实验中，小波系数 $W_{j,k}$ 是用 Mallat 算法对流序列 $\{X(k)\}$ 计算得到。

(2)在小波分解级数优化理论中，最优分解级数 $J^* \leq \lg N$ ， N 为待分解采样序列的点数。而在本文中， J 越大，可供直线拟合的点越多， H 值单次计算越精确，因此二者关系为 $J = \lg N$ 。

(3)精确的含义，并不代表估计值无限逼近真实值，而是单次的 H 值计算结果趋于稳定(见后文实验 1 部分)；事实上，无论 J 怎样设置，对众多同类型的流序列计算时， H 值都存在浮动性。

3.2 分段 Hurst 指数

流序列的 Hurst 指数只能通过数值分析的方法估计得到，即使用相对精确的 AV 小波估计法，对众多同类型的流序列计算，Hurst 指数仍存在明显的浮动性。这种浮动性在某些特殊情况下将造成分类结果的不稳定(见后文实验 2 部分)。因此本文的做法是：对流序列分段求解 Hurst 指数。分段将减轻因单次计算造成的随机性，得到统计性的差异量，使得分类计算结果趋于稳定。

对流序列 $\{X(k)\}$ 划分 L 段：

$$X^l = \{X_{i+Ni/L}, X_{i+1+Ni/L}, \dots, X_{i+N(l+1)/L-1}\} \quad (11)$$

分段后，流序列长度 N ，分段数 L 和分解级数 J 之间存在关系：

$$J = \sup \left\{ \lg \left(\frac{N}{L} \right) \right\} \quad (12)$$

取样的流序列长度 N 是固定的，理想情况下 L 和 J 越大越好， L 越大分类结果越趋于稳定， J 越大 Hurst 指数单次计算越精确，然而根据式(12)，两者不可兼顾，需要在统计稳定性与计算精确性之间做适当平衡。

根据流量分形理论，式(4)有式(13)等价定义：

$$\rho(k) = \frac{\sigma^2}{2} \left((k+1)^{2H} - 2k^{2H} + (k-1)^{2H} \right) \quad (13)$$

将序列 X 分割成 L 段，那么第 n 段的自相关函数为

$$\rho(k; H_J(n)) = \frac{\sigma^2(n)}{2} \left((k+1)^{2H_J(n)} - 2k^{2H_J(n)} + (k-1)^{2H_J(n)} \right) \quad (14)$$

其中， $H_J(n)$ 是在分解级数 J 下，第 n 段的 Hurst 指数。

构造基于相关信息的代价函数：

$$J(H_J(n)) = E \|\rho_J - \gamma\rho\|^2 \quad (15)$$

其中， ρ 是 $\rho(k)$ 的向量表示形式， ρ_J 是 $\rho(k; H_J(n))$ 的向量表示形式， γ 是调节因子，在数学上的含义就是表征分段前后序列所含信息的一致性程度，目标是希望在足够大的分段数量下，各分段的代价函数总量越小越好：

$$H_J(n) \equiv \operatorname{argmin}_n \sum_n^{\max(L)} J(H_J(n)) \quad (16)$$

式(16)使用最小最大目标函数用于平衡最大分解级数 J 和最优分段数 L ，以保证计算精确度和分类稳定性。

3.3 总体差异量分析

根据式(16)确定最优分段数之后，求出流序列 X_a 和 X_b 的各段 H 值 $H_{a_j}(n)$ 和 $H_{b_j}(n)$ ，再计算两者间统计的总体差异量。这里，本文采用聚类算法中常用的差异度表示方法。

数据集 $\{H_{a_j}(n), H_{b_j}(n)\}$ 内任意 2 个对象组成的差异度 $d(i, j) = |H_{a_j}(i) - H_{b_j}(j)|$ 是随机的，且每个 $d(i, j)$ 对分类结果的作用是平等的，从而定义统计的总体差异量：

$$\Delta H = \frac{1}{L^2} \sum_{i=1}^L \sum_{j=1}^L |H_{a_j}(i) - H_{b_j}(j)| \quad (17)$$

如若差异量 ΔH 小于系统阈值 T^* ，则那么认为两个流是同类；如若累积差异大于系统阈值 T^* ，认为两个流是异类。这里，阈值的设定是影响整个系统性能的重要指标。过窄的阈值将使分辨率过高，不利于归类；而过宽的阈值将使分辨率过低，不利于识别。本文以最大类间方差为基础，建立全局最优阈值调整机制：

$$T^* = \operatorname{argmax}_{t \neq j} \sum \sigma_B^2(t; i \leftrightarrow j) \quad (18)$$

其中 $\sigma_B^2(t; i \leftrightarrow j)$ 是阈值为 t 时的 i 与 j 两类之间的类间方差。根据自适应阈值确定方法 OTSU，类间方差最大意味着错分概率最小。

4 实验

本实验使用的视频流样本集通过 wireshark 在校园网内获取，其他实验在 MATLAB 中完成。

实验 1 验证单条流的分形特性

分多次截取 QQ 视频流和 PPlive 视频流，每次持续时间均设置为 1000 ms，解析度 $N = 2^{14} = 16384$ 个点。

在 MATLAB 中基于离散序列的 Mallat 算法，设置小波基为 harr 函数。因为本文不涉及信号重构，且需要尽量小的计算量，因此 harr 小波是最佳选择。

小波级数 j 从 1 到 14，逐级分解得到小波系数 $W_{j,k}$ ，并通过 LSM 作出其对应的 $\log_2 E |W_{j,k}|^2$ 与 j

的拟合直线,如图 1 所示.再根据式(10)计算出 Hurst 指数: QQ 视频流在 0.9132 到 0.9136 之间, PPlive 在 0.8814 到 0.8819 之间。

这个实验结果表明:

(1)流在大时间尺度上表现出分形特性;若不存
在这一系列的近似直线,说明不具备分形特性。

(2)不同类型的流对应的 Hurst 指数存在明显差异。

(3)因为 Hurst 指数是估计值,无论 J 设置多大,对众多同类型的流序列估算其 Hurst 指数时,都存在浮动性。

实验 2 序列分段问题

在实验 1 的基础上,重新计算 QQ 视频流在不分段和分段情况下的 ΔH , 以及由此得到的分类效果(为简化计算,设定阈值 $T = 0.122$, 分段数 $L = 8$)。

如表 1 所示,在不分段情况下, Hurst 指数的估算每次会有微量起伏,并呈随机性的变化,使得分类结果不稳定,有时判别为同类 Y, 有时判别为异类 N; 而在分段情况下,因为是对 ΔH 计算统计差异量,因此结果比较稳定。

表 1 不分段与分段情况下的分类效果

实验序号	不分段的 ΔH	分类结果	分段的平均 ΔH	分类结果
1	0.1223	N	0.1222	Y
2	0.1221	N	0.1221	Y
3	0.1219	Y	0.1221	Y
4	0.1222	N	0.1221	Y
5	0.1224	N	0.1222	Y
6	0.1223	N	0.1222	Y
7	0.1222	N	0.1221	Y
8	0.1219	Y	0.1221	Y
9	0.1222	N	0.1222	Y
10	0.1221	N	0.1221	Y

这里,有以下两点需要说明:

(1)上述实验,预先设定阈值 $T = 0.122$, 如果设定阈值 $T = 0.1$ 或 $T = 0.2$, 可见分段与否对于分类结果并无区别.因此,分段对于 Hurst 指数的差异量 ΔH 正好落在阈值 T 附近时,意义非常重大。

(2)这里设定分段数 $L = 8$, 由统计学可知,分段越多,统计差异量越平稳,但因为式(12)的约束条件 L 与 J 呈反比关系,因此过多的分段会影响 Hurst 指数估算精确度,所以接下来考察分段对 Hurst 指数估算的影响。

设置解析度 $N = 2^{14} = 16384$, 对时长 1000 ms 的 QQ 流序列分段.如图 2(a)所示,这是将序列分成 10 段后分别计算每段的 H 值,可见有微弱起伏,将序列分成 20 段后 Hurst 指数震荡比较剧烈.因此,不能片面追求大的分段数。

图 2(b)显示的是不同分段数对应的 Hurst 指数变异系数,当分段 L 在 16 之后,随着分段数量的增加, Hurst 指数的变异系数呈指数级增长。

本文通过最大最小目标函数得到的计算结果是 $L = 8$. 如图 2(b)所示,由此对应 Hurst 指数的变异系数是 0.02 左右,这个分段数是比较合适的,即可以得到比较稳定的统计差异量,在单次计算中可以获得相对精确的 H 值。

实验 3 测试分类效果

在样本集上随机选择其中 3000 条流,包括 QQ 视频流、PPlive 流、GAME 流、TVAnt 流、Tudou 视频流、Skype 视频流;然后用本文提出的分类方法对数据集进行十折交叉验证,并建立混淆矩阵如表 2 所示。

通过对表 2 的计算验证,不难发现 QQ 视频流、PPlive 流、GAME 流、TVAnt 流、Tudou 视频流、Skype 视频流的 far 分别为 2.06%, 2.24%, 2.46%, 2.18%, 2.34%, 2.18%; frr 分别为 2.32%, 2.32%, 2.16%, 2.24%, 2.16%, 2.26%。这个结果与本文选取的 OTSU 全局最优结论相一致,并且维持 frr 与 far 相近,不至于发生局部最差的情况。




图 1 $\log_2 E|W_{j,k}|^2$ 与 j 的拟合直线图

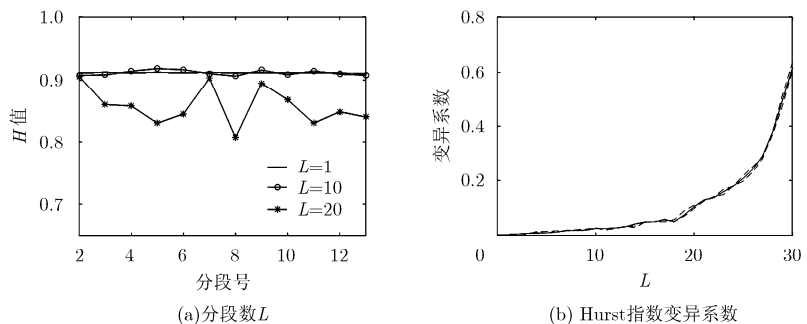


图 2 分段的 Hurst 指数

表 2 混淆矩阵

	QQ	PPlive	GAME	Tudou	TVAnt	Skype
QQ	0.794	0.040	0.034	0.036	0.038	0.058
PPlive	0.036	0.776	0.044	0.048	0.058	0.038
GAME	0.052	0.050	0.754	0.054	0.044	0.046
Tudou	0.048	0.046	0.052	0.766	0.040	0.048
TVAnt	0.040	0.054	0.046	0.042	0.782	0.036
Skype	0.056	0.042	0.040	0.036	0.044	0.782

实验 4 与其他方法横向比较

在上述实验中，本文提出的 Fractals 分类模型 的分类效果已初步可见。为进一步显示其性能，这里使用公开的专用于流分类识别的 Moore 数据集，对多种方法分别进行训练、测试，并做横向比较。这些方法包括贝叶斯 Bayes、支持向量机 SVM、隐马尔科夫过程 HMM、决策树 Decision Tree (DT)。

由表 3 可见，大多数方法在训练测试阶段，通过所获信息调节参数到最优性能，因此都表现为稳定的分类识别能力。所以接下来，继训练测试阶段

结束后，进行动态性能测试，也就是在实际的复杂网络在线环境下，面对多变的应用场景，测试这些系统面对未知的应变能力。

实验 5 动态性能测试

这里，使用 ITA 数据集进行测试。每次随机选取 500 条视频流供系统进行测试，其中包括 e Donkey, Direct Connect, Gnutella, Fast Track, AOL Messenger, Kazaa, Lime Wire 等 15 种应用的视频流。图 3 中横坐标是这 15 种类别的标号，纵坐标是分类方法对此类型的辨识度。

表 3 横向识别率统计(%)

方法	QQ	PPlive	GAME	Tudou	TVAnt	Skype
Bayes	71.4	72.3	68.5	67.5	71.5	69.1
SVM	78.8	78.5	77.7	79.7	76.7	78.5
HMM	68.4	69.3	72.1	72.3	68.6	74.6
DT	72.7	78.4	72.9	73.7	69.8	68.9
本文	79.4	77.6	75.4	76.6	78.2	78.2

由图 3 可见，Bayes, SVM, HMM, DT 方法总是对某些视频流缺乏辨识度，如第 3 号流的辨识度普遍只有 20%左右，第 9 号流的辨识度普遍在 40%以下；而有些方法对某些流则表现的相当敏感，如 Bayes 对第 4 号流的辨识度达到近 65%，HMM 对第 11 号流的辨识度达到 70%。原因在于这些方法所训练好的有效特征总是对于部分有效，当面对另外一部分未知情况时，效果不佳；尤其是在线时，这些影响识别性能的关键特征不能实时更新，因此制约了在线识别的应用。

本文提出的 Fractals 分类模型，是基于流的分形特性实现流的细粒度分类，不依赖于统计特征，因此该方法对于未知视频流的辨识能力与已知流相当，在图中的表现即是相对平缓的曲线，对任意类型的视频流，其辨识率都保持在 65%左右，可见这种不依赖特征提取的分类方法，当实验环境变化或进行在线分类时，具有较强的适应能力。

4 结论

目前主流的视频流细分类技术有两条路线：基于分类检索方法，以及基于统计学方法，然而这两类方法分别体现出“内容依赖”、“特征依赖”的局限性，并严重制约了视频流的分类效果。为此引入分形的思想，建立以随机数据的变化特性为内容的视频流细粒度分类的新方法，文中实验也很好地表




图 3 动态性能测试

明了该方法在视频流分类方面的有效性, 以及与其他方法相比较而体现的优越性。

参 考 文 献

- [1] QAHHAR Muhammad Qadir. Mechanisms for QoE optimisation of video traffic: A review paper[J]. *Analytical Biochemistry*, 2015, 1(1): 40-42. doi: 10.17972/ajcta2015117.
 - [2] KHAN N and MARTINI M G. Hysteresis based rate adaptation for scalable video traffic over an LTE downlink[C]. IEEE International Conference on Communication Workshop, London, UK, 2015: 1434-1439. doi: 10.1109/ICCW.2015.7247380.
 - [3] WANG Zaijian, DONG Yuning, SHI Haixian, *et al.* Internet video traffic classification using QoS features[C]. IEEE International Conference on Computing, Networking and Communications, Kauai, HI, USA, 2016: 1-5. doi: 10.1109/ICCNC.2016.7440599.
 - [4] MOHD A B and NOR S B M. Towards a flow-based internet traffic classification for bandwidth optimization[J]. *International Journal of Computer Science & Security*, 2014, 3(2): 146-153.
 - [5] BARAKAT C, THIRAN P, IANNACCONE G, *et al.* Modeling internet backbone traffic at the flow level[J]. *IEEE Transactions on Signal Processing Special Issue on Networking*, 2003, 51(8): 2111-2124. doi: 10.1109/TSP.2003.814521.
 - [6] LI W and YU X. An online flow-level packet classification method on multi-core network processor[C]. IEEE International Conference on Computational Intelligence and Security, Shenzhen, China 2015: 407-411. doi: 10.1109/CIS.2015.104.
 - [7] ZHANG D, ZHOU D, and JIN X. A content-adaptive video quality assessment method for online media service[J]. *Multimedia Tools & Applications*, 2016: 1-21. doi: 10.1007/s11042-016-3359-5.
 - [8] SUN S B and CUI R Y. Player classification algorithm based on digraph in soccer video[C]. IEEE Conference on Information Technology and Artificial Intelligence, Chongqing, China, 2014: 459-463. doi: 10.1109/ITAIC.2014.7065092.
 - [9] LIM J D, LEE C H, CHOI B C, *et al.* Implementation of automatic x-rated video classification and management system based on multimodal features[J]. *International Journal of Advancements in Computing Technology*, 2012, 4(23): 178-186. doi: 10.4156/ijact.vol4.issue23.21.
 - [10] YU J, WANG M, and TAO D. Semisupervised multiview distance metric learning for cartoon synthesis[J]. *IEEE Transactions on Image Processing*, 2012, 21(11): 4636-4648. doi: 10.1109/TIP.2012.2207395.
 - [11] NG Y H, HAUSKNECHT M, VIJAYANARASIMHAN S, *et al.* Beyond short snippets: Deep networks for video classification[C]. IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 2015: 4694-4702. doi: 10.1109/CVPR.2015.7299101.
 - [12] JENNINGS C, PETERSON J, TERRIBERRY T, *et al.* Multiplexing of real-time transport protocol (RTP) traffic for browser based real-time communications (RTC)[J]. *Communications and Informatics*, 2011, 24 (6): 1-28.
 - [13] ZENG C and CHEN J. Analysis and design based on DPI streaming media of traffic detection system[J]. *Video Engineering*, 2014, 36(5): 94-102.
 - [14] KHEIR N, HAN X, and WOLLEY C. Behavioral fine-grained detection and classification of P2P bots[J]. *Journal of Computer Virology & Hacking Techniques*, 2015, 11(4): 217-233. doi: 10.1007/s11416-014-0228-5.
 - [15] WU Z, JIANG Y G, WANG J, *et al.* Exploring inter-feature and inter-class relationships with deep neural networks for video classification[C]. Proceedings of the ACM International Conference on Multimedia, Chengdu, China, 2014: 1-6. doi: 10.1109/ICMEW.2014.6890609.
 - [16] KARPATHY A, TODERICI G, SHETTY S, *et al.* Large-scale video classification with convolutional neural networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, USA, 2014: 1725-1732. doi: 10.1109/CVPR.2014.223.
 - [17] NOSSENSON R and POLACHEK S. On-line flows classification of video streaming applications[C]. IEEE International Symposium on Network Computing and Applications, Cambridge, MA, USA, 2015: 251-258. doi: 10.1109/NCA.2015.51.
 - [18] GANDHI V R, QU Y R, and PRASANNA V K. High-throughput hash-based online traffic classification engines on FPGA[C]. IEEE International Conference on Reconfigurable Computing and FPGAs, Cancun, Mexico, 2015: 1-6. doi: 10.1109/ReConFig.2014.7032530.
 - [19] MANE A S and KAMDE P M. Video classification using SVM[J]. *International Journal of Recent Technology & Engineering*, 2013, 2(3): 34-47.
 - [20] LELAND W E, TAQQU M S, Willinger W, *et al.* On the self-similar nature of Ethernet traffic (extended version)[J]. *IEEE/ACM Transactions on Networking*, 1994, 2(1): 1-15. doi: 10.1109/90.282603.
 - [21] HE H, WANG J, WEI H, *et al.* Fractal behavior of traffic volume on urban expressway through adaptive fractal analysis[J]. *Physica A Statistical Mechanics & Its Applications*, 2015, 443(7): 518-525.
 - [22] ALVAREZRAMIREZ J, IBARRAVALDEZ C, and RODRIGUEZ E. Fractal analysis of Jackson Pollock's painting evolution[J]. *Chaos Solitons & Fractals*, 2016, 83(1): 97-104. doi:10.1016/j.chaos.2015.11.034.
- 汤萍萍: 女, 1981年生, 博士生, 讲师, 研究方向为网络流量、分类识别、QoS保证技术等。
- 董育宁: 男, 1955年生, 博士生导师, 教授, 主要研究方向为流媒体技术、视频流传输技术等。