

带有特征感知的D2D内容缓存策略

杨 静 李金科*

(重庆邮电大学 通信与信息工程学院 重庆 400065)
(重庆高校市级光通信与网络重点实验室 重庆 400065)
(泛在感知与互联重庆市重点实验室 重庆 400065)

摘 要: 设备到设备通信(D2D)可以有效地卸载基站流量,在D2D网络中不仅需要共享大众化内容还需要个性化内容缓存。该文对缓存内容选择问题进行了深入研究,提出一种结合特征感知的内容社交价值预测(CSVP)方法。价值预测不仅可以降低时延也可以减少缓存替换次数降低缓存成本。首先结合用户特征和内容特征计算内容当前价值,然后通过用户社交关系计算未来价值。微基站根据内容的价值为用户提供个性化内容缓存服务,宏基站则在每个微基站的缓存内容中选择价值较大部分的内容。仿真结果表明,该文提出的缓存策略可以有效缓解基站流量,与其他方法相比降低时延约20%~40%。

关键词: 边缘网络; D2D通信; 内容缓存; 探索-利用; 价值预测

中图分类号: TN919

文献标识码: A

文章编号: 1009-5896(2020)09-2201-07

DOI: [10.11999/JEIT190691](https://doi.org/10.11999/JEIT190691)

Feature-Aware D2D Content Caching Strategy

YANG Jing LI Jinke

(School of Communication and Information Engineering,
Chongqing University of Posts and Telecommunications, Chongqing 400065, China)
(Optical Communication and Networks Key Laboratory of Chongqing, Chongqing 400065, China)
(Ubiquitous Sensing and Networking Key Laboratory of Chongqing, Chongqing 400065, China)

Abstract: Device to Device (D2D) communications can effectively offload base station traffic. In D2D networks, the popular content is not only needs to be shared, but also the individual content is needs to be cached. In this paper, the problem of cache content selection is researched. A Content Social Value Prediction(CSVP) method based on feature perception is proposed. Value prediction can not only reduce latency, but also reduce the number of cache replacements and reduce cache costs. Firstly, the current value of content is calculated by combining user features and content features, and then future value is calculated through user social relationships. The small base station provides the user with a personalized content caching service according to the value of the content, and the base station selects a content with a larger value in the individual cache content of each small base station as popular content. Simulation results show that the caching strategy based on the proposed method can alleviate the base station traffic effectively, and reduce the delay by about 20%~40%.

Key words: Edge network; D2D communication; Content caching; Exploration - exploitation; Value prediction

1 引言

移动设备以及社交多媒体应用数量的增加促使

蜂窝流量日益增加,导致了基站资源的匮乏。根据思科报告指出,到2022年每月蜂窝流量将会达77 EB,移动设备总量和连接将增长到1.23 T^[1]。如何高效处理这些庞大的流量请求是未来蜂窝网络核心问题,为了有效地将流量卸载到本地,在第5代移动通信系统中提出了设备到设备通信,通过该技术可以降低时延^[2,3]。D2D通信使用端到端的通信方式,使数据可不经基站而在用户之间传输,用户可以共享资源,从而降低网络负载、减少时延。

在缓存节点中,内容在动态变化,如何快速地

收稿日期: 2019-09-05; 改回日期: 2020-05-03; 网络出版: 2020-05-17

*通信作者: 李金科 s170131104@stu.cqupt.edu.cn

基金项目: 国家自然科学基金(61871062, 61771082), 重庆市高校创新团队建设计划项目(CXTDX201601020)

Foundation Items: The National Natural Science Foundation of China (61871062, 61771082), The Program for Innovation Team Building at Institutions of Higher Education in Chongqing (CXTDX201601020)

识别用户兴趣,并预测流行程度具有重要价值。在文献[4]中作者分析4周内用户请求数据,认为内容受欢迎程度的衰减与齐夫分布相比更符合Weibull分布;在文献[5]提出分层网络缓存系统分析模型,研究边缘网络不同位置缓存内容的性能;文献[6]提出了一种分布式加权流行度算法,从最佳缓存模型中导出不同参数并制定了PACC缓存算法;文献[7,8]研究了合作缓存机制,文献[8]提出通过簇头进行内容共享。比较常用内容缓存办法还有LFU, LRU和自适应替换缓存(ARC)[9,10]。其他方法还将缓存与编码结合来降低时延[11]。如何准确预测内容未来的流行程度并在此基础结合D2D制定高效缓存策略,这是本文主要研究问题。现有研究主要根据请求总数或用户偏好推断内容在未来被请求概率来选择缓存内容。由于内容流行度随时间变化,只考虑单方面因素具有局限性。因此本文考虑内容特征及用户社交对内容流行度的影响。

基于以上分析,本文在D2D网络中,针对内容选择问题提出基于内容特征和用户特征内容价值预测算法。通过特征感知分析内容对用户的当前价值和潜在流行价值,通过提出内容社交价值预测(Content Social Value Prediction, CSVP)算法计算每个内容总流行价值来选择内容,根据每个微基站的高价值内容列表,选择公共部分的高价值内容缓存在宏基站缓存单元。

2 网络模型

本节将主要介绍网络架构、用户模型和内容模型。内容的价值主要由用户和内容属性共同决定。

2.1 网络架构

在5G中内容从服务器到用户设备的传输路径上存在较多路由器,由于距离较远,传输时延较高,需将内容继续下沉到边缘网络。将边缘网络分为3层,在宏基站、微基站以及用户设备上都配备空间大小不同的缓存单元。

如图1所示,在一个宏基站(Base Station, BS)覆盖范围内,存在若干微基站(Small Base Station, SBS),用户可以通过蜂窝网络或D2D进行通信。用户发送内容请求到SBS时, SBS会在本地缓存单元寻找该内容数据包,通过蜂窝通信或D2D通信传输数据。如果资源未被缓存在本地存储单元中,则在上层节点寻找数据。

2.2 内容模型

不同内容在不同用户人群中具有不同价值。内容价值大小在一定程度上取决于请求用户,但是内容本身属性对于价值的判断也是非常重要的,因此需要提取合理的内容特征。内容特征的刻画为




图1 网络架构

$$C_k = [c_1 c_2 c_3 c_4 c_5] \quad (1)$$

分别表示内分类、创作者影响力、生存时间、总请求数和当前请求数。式(2)给出了创作者影响力计算公式

$$I_p = \frac{A_p}{A} \quad (2)$$

其中 A_p 为内容创作者 p 创作内容在窗口时间被请求次数, A 代表所有内容的请求数。由于影响力会随着时间的变化, 所以需要将创作者的历史影响力和当前影响力综合考虑。那么内容创作者综合影响力为

$$I_{p,n} = \frac{I_{p,n-1}}{2} + \frac{1}{2} \sum_{i=1}^{n-1} \frac{1}{n-i} I_{p,n-i} \quad (3)$$

其中 $I_{p,n-1}$ 表示第 $n-i$ 次影响力。 c_3 表示内容存活时间, c_4 为请求总和, c_5 为内容当前请求次数并作为反馈特征 F_a 。在使用特征计算时需要降维来提高计算速度同时保证特征的表示效果[12]。

2.3 用户模型

对用户 i 通过下述矩阵描述用户特征。其中 $H_i = [h_1 h_2 h_3 h_4 h_5 h_6]$ 表示根据用户的对内容的偏程度。

$$U_i = Y_i \times H_i^T \quad (4)$$

$Y_i = [y_1 y_2 y_3 y_4 y_5 y_6]$ 表示用户特征, 包括性别、年龄、职业、分享意愿强度和位置信息等。用户分享意愿强度具体计算方式为

$$S_{i,t} = \frac{1}{2} S_{i,t-1} + \sum_{j=1}^{t-1} \frac{1}{t-j} \times \frac{S_{i,t-j}}{j!}, \quad S_{i,0} = \frac{S_{i,0}}{\sum_{i=1}^n S_{i,0}} \quad (5)$$

其中 $S_{i,t}$ 表示第 i 个用户在第 t 个观察窗口内通过D2D方式所完成的相应请求次数。在 t 时刻用户的分享意愿评分 $y_4 = g(S_{i,t})$ 其中 $g(x) = (2/(1+e^{-x})) - 1$ 。 y_5 为用户距离基站的距离, y_6 为用户所在扇区。

3 内容流行价值

缓存策略的设计目标是使得内容的缓存命中率最大。准确地量化内容的价值对缓存内容的选择具有重要意义。内容价值包括未来价值部分和当前价值部分。

3.1 缓存内容选择

每个内容就是一台老虎机, 在不同时刻缓存内容会获得不同奖励, 节点空间有限且内容收益未知, 如何收益最大化是需要考虑的问题。多臂老虎机问题核心是解决选择问题, 通过在不断的选择决策中学习使得系统更了解用户。所以缓存选择可以建模为多臂老虎机问题。

缓存系统的设计目标是最大化命中率, 目标函数定义为

$$\max \text{ hit-rate} = \frac{\sum w_{i,c}}{\sum w_i} \quad (6)$$

$$\text{s.t.} \quad \sum_{c \in C} \text{size}_c \times X_i^c \leq \text{size}_i, i \in U \quad (6a)$$

$$\sum_{c \in C} \text{size}_c \times Y_m^c \leq \text{size}_j, m \in M \quad (6b)$$

$$\sum_{c \in C} \text{size}_c \times Z_p^c \leq \text{size}_p, p \in P \quad (6c)$$

$$X_i^c, Y_m^c, Z_p^c \in \{0, 1\} \quad (6d)$$

$$w_{i,c}, w_i \in \{0, 1\} \quad (6e)$$

式(6a), (6b), (6c)表示缓存文件不能超过可用缓存空间, 式(6d)表示节点是否缓存内容 k , 式(6e)表示用户是否请求内容 k 。由Zipf定律知, 流行度前20%的内容会提供超过80%的传输量^[13]。将目标转换为量化内容的流行程度。为精确地量化内容流行程度, 本文的目标函数转换为式(7)

$$\min L = \sum_k (V_k - V'_k)^2 \quad (7)$$

由于内容的流行价值是时刻变化的, 现有研究并没有考虑到内容未来流行度。所以, 本文内容价值分为当前价值和未来价值, 将 $V_k = P_k + R_k, V'_k = P'_k + R'_k$ 代入到式(8)中得到

$$\min L = \sum_k (P_k - P'_k)^2 + (R_k - R'_k)^2 + 2(P_k - P'_k)(R_k - R'_k) \quad (8)$$

将式(8)拆分为式(9)中的两个最小化问题进行求解。

$$\left. \begin{aligned} \min f_1 &= \sum_k (p_k - p'_k)^2 \\ \min f_2 &= \sum_k (R_k - R'_k)^2 \end{aligned} \right\} \quad (9)$$

3.2 当前价值

D2D通信技术可以降低时延, 但是用户存在自

私性。当用户发出内容请求后, 辅助用户协作传输完成后需要获得相应的奖励来促进用户之间内容共享。当前流行价值也决定了用户共享该内容可以获得的奖励。

假设每个内容 k 都有一个未知强盗参数控制和一个线性 D 维的特性量 $\mathbf{X}_t$, 表示用户组的流行环境, 并且这个参数会随时间发生变化的, 并且相邻时刻之间有联系的^[14]。对内容 k 设定当前价值 P 为

$$P[r_{t,k}|\mathbf{X}_{t,k}] = \mathbf{X}_{t,k}^T \times \theta_k^* \quad (10)$$

其中 $\mathbf{X}_{t,k}^T = \mathbf{U}_{t,k} \times \mathbf{C}_{t,k}^T$ 。缓存节点在缓存一个内容 k 后, 得到的用户反馈为 $\mathbf{F}_k$ (用户是否请求该内容), 内容特征为 $\mathbf{C}_k$ 。假设内容是否被请求与内容特征以及用户特征存在线性关系。在缓存系统中最为重要的是可以满足用户的内容请求, 因此内容真实当前价值使用用户的反馈特征代替。式(10)中的实际当前价值与估计当前价值的平方差函数转换为用户反馈特征与内容特征的平方差。当特征之间的相关性较大时会使得求解不稳定, 计算误差较大, 所以需要加入惩罚项来避免这种情况。加入惩罚项后的损失函数为

$$G_{\text{loss}} = (\mathbf{F}_k - \mathbf{C}_k \times \theta_k)^2 + \gamma \|\theta_k\| \quad (11)$$

式(11)是线性最小二乘函数, 最小化损失函数是L2正则化问题, 对其求导令其为0, 则解得最优解为

$$\hat{\theta}_k = (\mathbf{C}_k^T \mathbf{C}_k + \mathbf{I}_d)^{-1} \mathbf{C}_k^T \mathbf{F}_k \quad (12)$$

其中 $\mathbf{I}_d$ 是单位矩阵。传统方法没有考虑用户个性化要求, 需要置信上界来表示该要求。当 $\mathbf{C}_k$ 独立于 $\mathbf{F}_k$, 由文献^[15]可以得到

$$P \left\{ |\mathbf{x}^T \theta - p| \leq \left(1 + \sqrt{\ln(2/\delta)/2} \right) \right\} \leq 1 - \delta \quad (13)$$

式(13)证明了可以利用置信上界来降低这种误差, 将式(10)增加置信上界, 如式(14)所示

$$P \left\{ |\mathbf{x}^T \theta - p| \leq \left(1 + \sqrt{\ln(2/\delta)/2} \right) \cdot \left(\sqrt{\mathbf{X}_{t,k}^T (\mathbf{C}_k^T \mathbf{C}_k + \mathbf{I}_d)^{-1} \mathbf{X}_{t,k}} \right) \right\} \leq 1 - \delta \quad (14)$$

由于归一化的处理, 式(14)依然成立。因此置信上界可以表示为

$$|\mathbf{X}_{t,k}^T \theta_k - P[r_{t,k}|\mathbf{X}_{t,k}]| \leq \alpha \sqrt{\mathbf{X}_{t,k}^T (\mathbf{C}_k^T \mathbf{C}_k + \mathbf{I}_d)^{-1} \mathbf{X}_{t,k}} \quad (15)$$

其中 $\alpha = 1 + \sqrt{\ln(2/\delta)/2}$ 代表了对于某些个性化内容的探索程度。将式(11)、式(15)合并得到当前价值为

$$P_{k,t} = (\mathbf{X}_{t,k}^T \hat{\theta}_k + \alpha \sqrt{(\mathbf{X}_{t,k}^T (\mathbf{C}_k^T \mathbf{C}_k + \mathbf{I}_d)^{-1} \mathbf{X}_{t,k})}) \quad (16)$$

3.3 未来价值

未来价值由用户社交情况所决定, 设定未来价值 $\hat{R} \approx \hat{\mathbf{U}}^T \times \hat{\mathbf{C}}$, 其中 $\hat{\mathbf{U}}^T$ 是用户社交矩阵, $\hat{\mathbf{C}}$ 是内容社交域特征矩阵。社交矩阵 $\mathbf{S} = \mathbf{L}^T \mathbf{W}$, 其中 $\mathbf{L}$ 是用户对其他用户影响的矩阵, $\mathbf{W}$ 是用户被其他用户影响的矩阵。将式(9)中关于未来价值最小化问题转化为在已知当前价值及用户社交情况下最大化概率求得, 即

$$\max p(\hat{R} | \mathbf{R}, \mathbf{S}) \quad (17)$$

如图2中所示, 用户在社区中, 内容请求偏好既可以影响其他用户也可以被影响。因此, 内容未来价值是由用户属性、内容属性、用户影响矩阵和用户被影响矩阵共同决定。




图2 用户间社交对价值的影响

用户的传播作用取决于该用户社交情况。因此价值的条件概率分布被建模为^[16]

$$p(R | \hat{\mathbf{U}}, \hat{\mathbf{C}}, \sigma^2) = \prod_{i,j \in \Omega} \mathcal{N}(R_{ij} | g(\hat{\mathbf{U}}_i^T \hat{\mathbf{C}}_j), \sigma_R^2) \quad (18)$$

假设社区中的用户特征和内容特征满足高斯分布^[17]

$$\left. \begin{aligned} p(\hat{\mathbf{U}} | \sigma_U^2) &= \prod_{i=1}^m \mathcal{N}(\hat{\mathbf{U}}_i | 0, \sigma_U^2 \mathbf{I}) \\ p(\hat{\mathbf{C}} | \sigma_C^2) &= \prod_{k=1}^m \mathcal{N}(\hat{\mathbf{C}}_k | 0, \sigma_C^2 \mathbf{I}) \end{aligned} \right\} \quad (19)$$

类似地, 用户社交特征如式(20)分布

$$\left. \begin{aligned} p(\mathbf{S} | \mathbf{L}, \mathbf{W}, \sigma^2) &= \prod_{i,j \in \Psi} \mathcal{N}(S_{ij} | g(\mathbf{L}_i^T \mathbf{W}_j), \sigma_S^2) \\ p(\mathbf{L} | \sigma_L^2) &= \prod_{i=1}^m \mathcal{N}(\mathbf{L}_i | 0, \sigma_L^2 \mathbf{I}) \\ p(\mathbf{W} | \sigma_W^2) &= \prod_{i=1}^m \mathcal{N}(\mathbf{W}_i | 0, \sigma_W^2 \mathbf{I}) \end{aligned} \right\} \quad (20)$$

处于同一社区的其他用户行为会受到用户内容请求偏好造成的影响, 给定式(21)分布模拟该影响

$$p(\hat{\mathbf{U}} | \mathbf{L}, \sigma_M^2) = \prod_{i=1}^n \mathcal{N}(\hat{\mathbf{U}}_i | \mathbf{L}_i, \sigma_M^2 \mathbf{I}) \quad (21)$$

然后将用户特征向量在影响其他用户内容请求下的先验分布定义为

$$p(\hat{\mathbf{U}} | \mathbf{L}, \sigma_F^2, \sigma_M^2) \propto p(\hat{\mathbf{U}} | \sigma_F^2) p(\hat{\mathbf{U}} | \mathbf{L}, \sigma_M^2) \quad (22)$$

在用户影响其他用户请求偏好的情况下, 用户特征、内容特征、影响矩阵, 影响矩阵的后验分布为

$$\begin{aligned} p(\hat{\mathbf{U}}, \hat{\mathbf{C}}, \mathbf{L}, \mathbf{W} | \hat{R}, \mathbf{S}, \sigma^2, \sigma_F^2, \sigma_M^2) \\ \propto p(\hat{R} | \hat{\mathbf{U}}, \hat{\mathbf{C}}, \sigma^2) p(\mathbf{S} | \mathbf{L}, \mathbf{W}, \sigma^2) p(\hat{\mathbf{U}} | \sigma_F^2) \\ p(\hat{\mathbf{U}} | \mathbf{L}, \sigma_M^2) p(\mathbf{C} | \sigma_F^2) p(\mathbf{L} | \sigma_F^2) p(\mathbf{W} | \sigma_F^2) \end{aligned} \quad (23)$$

同理可得, 在用户影响被其他用户内容请求偏好的情况下, 后验分布为

$$\begin{aligned} p(\hat{\mathbf{U}}, \hat{\mathbf{C}}, \mathbf{L}, \mathbf{W} | \hat{R}, \mathbf{S}, \sigma^2, \sigma_F^2, \sigma_N^2) \\ \propto p(\hat{R} | \hat{\mathbf{U}}, \hat{\mathbf{C}}, \sigma^2) p(\mathbf{S} | \mathbf{L}, \mathbf{W}, \sigma^2) p(\hat{\mathbf{U}} | \sigma_F^2) \\ p(\hat{\mathbf{U}} | \mathbf{W}, \sigma_M^2) p(\hat{\mathbf{C}} | \sigma_F^2) p(\mathbf{L} | \sigma_F^2) p(\mathbf{W} | \sigma_F^2) \end{aligned} \quad (24)$$

由于用户内容请求偏好之间影响与被影响的情况是同时存在的, 所以需要综合概率来模拟影响与被影响情况下对内容未来价值影响。因此, 用户特征的先验分布是由3个因素决定, 即零均值高斯分布的方差、 $\mathbf{L}$ 以及 $\mathbf{W}$ 。用户特征的先验分布为

$$\begin{aligned} p(\hat{\mathbf{U}} | \mathbf{L}, \mathbf{W}, \sigma_F^2, \sigma_M^2, \sigma_N^2) \\ \propto p(\hat{\mathbf{U}} | \sigma_F^2) p(\hat{\mathbf{U}} | \mathbf{L}, \sigma_M^2) p(\hat{\mathbf{U}} | \sigma_N^2) \end{aligned} \quad (25)$$

同时考虑用户间存在的两种影响情况, 将式(23)、式(24)通过概率合成得到式(26)

$$\begin{aligned} p(\hat{\mathbf{U}}, \hat{\mathbf{C}}, \mathbf{L}, \mathbf{W} | \hat{R}, \mathbf{S}, \sigma^2, \sigma_F^2, \sigma_M^2, \sigma_N^2) \\ \propto p(\hat{R} | \hat{\mathbf{U}}, \hat{\mathbf{C}}, \sigma^2) p(\mathbf{S} | \mathbf{L}, \mathbf{W}, \sigma^2) \\ p(\hat{\mathbf{U}} | \mathbf{L}, \sigma_M^2) p(\hat{\mathbf{U}} | \mathbf{W}, \sigma_N^2) p(\hat{\mathbf{U}} | \sigma_F^2) \\ p(\hat{\mathbf{C}} | \sigma_F^2) p(\mathbf{L} | \sigma_F^2) p(\mathbf{W} | \sigma_F^2) \end{aligned} \quad (26)$$

为方便计算, 对式(26)中的概率分布取对数, 最大化式(26)等同于最小化式(27)中的损失函数。

$$\begin{aligned} H_{\text{loss}} &= \frac{1}{2} \sum_{i,j \in \Omega} \left(\hat{R}_{ij} - g(\hat{\mathbf{U}}_i^T \hat{\mathbf{C}}_j) \right)^2 \\ &+ \frac{\lambda_1}{2} \sum_{i=1}^n \|\hat{\mathbf{U}}_i - \mathbf{L}_i\|_F^2 \\ &+ \frac{1}{2} \sum_{i,k \in U} (S_{ik} - g(\mathbf{L}_i^T \mathbf{W}_k))^2 \\ &+ \frac{\lambda_2}{2} \sum_{i=1}^n \|\mathbf{U}_i - \mathbf{W}_i\|_F^2 + \frac{\lambda}{2} \left(\sum_{i=1}^n \|\hat{\mathbf{U}}_i\|_F^2 \right. \\ &\left. + \sum_{i=1}^m \|\hat{\mathbf{C}}_i\|_F^2 + \sum_{i=1}^n \|\mathbf{L}_i\|_F^2 + \sum_{i=1}^n \|\mathbf{W}_i\|_F^2 \right) \end{aligned} \quad (27)$$

内容在当前网络中请求的数量 n_{C_k} 越多, 方差应该被设为更小, 并且方差和请求次数成反比。对概率分布重新定义, 将式(20)改写为式(28)

$$p(\hat{C}|\sigma_F^2) = \prod_{k=1}^K \mathcal{N}\left(\hat{C}_k|0, \frac{\sigma_F^2}{n_{C_k}} I\right) \quad (28)$$

类似地, 用相同的方法定义其他参数的概率分布, 则新损失函数为

$$\begin{aligned} H_{\text{loss}} = & \frac{1}{2} \sum_{i,k \in \Omega} \left(\hat{R}_{ik} - g\left(\hat{U}_i^T \hat{C}_k\right) \right)^2 \\ & + \frac{\lambda_1}{2} \sum_{i=1}^n \|\hat{U}_i - \mathbf{L}_i\|_F^2 \\ & + \frac{1}{2} \sum_{i,j \in U} (S_{ij} - g(\mathbf{L}_i^T \mathbf{W}_j))^2 \\ & + \frac{\lambda_2}{2} \sum_{i=1}^n \|\mathbf{U}_i - \mathbf{W}_i\|_F^2 \\ & + \frac{\lambda}{2} \left(\sum_{i=1}^n n_{u_i} \|\mathbf{U}_i\|_F^2 + \sum_{k=1}^m n_{C_k} \|\mathbf{C}_k\|_F^2 \right. \\ & \left. + \sum_{i=1}^n n_{L_i} \|\mathbf{L}_i\|_F^2 + \sum_{i=1}^n n_{W_i} \|\mathbf{W}_i\|_F^2 \right) \quad (29) \end{aligned}$$

对式(29)求得梯度后即可得到参数的更新方式。

4 内容缓存策略

本节将介绍结合UCB算法和Momentum梯度下降法的内容社交价值预测算法。以及基于内容流行价值的缓存内容选择策略。包括微基站缓存策略以及宏基站缓存策略。

4.1 微基站缓存

本文选择使用最大置信区间概率。传统算法的收敛时间较长, 结果会有较大误差。因此本文基于UCB算法和Momentum梯度下降法设计了内容社交价值预测 (Content Social Value Prediction, CSVP) 算法。该算法结合UCB算法和Momentum梯度下降法对两个问题进行求解。如表1的算法1所示。

整个缓存系统的控制中心位于宏基站, 因此该算法是由宏基站进行计算的, 并将结果下发到微基站, 微基站执行缓存动作。CSVP算法主要对第3节中的两个最小化问题进行求解并得出内容对每个用户的当前价值和未来价值, 并对总价值取平均值, 按照价值降序选择缓存内容。5到9行主要计算内容的当前价值, 其中6行、7行是对没有缓存过的内容进行初始化, 第9行计算强盗参数的值以及当前价值, 第10到第13行计算内容的未来价值, 其中第10行到第12行是利用Momentum梯度下降法求解损失函数, 第13行输出未来价值, 第14行计算内容在当前时间窗口的总价值, 第16行输出价值降序。

表 1 算法1 内容社交价值预测

输入:	$T, r, \alpha, \lambda, \lambda_1, \lambda_2, \beta_1, \beta_2, \xi$
输出:	价值列表, 观察用户请求情况
(1)	随机初始化参数 $\hat{U}, \hat{C}, \mathbf{L}, \mathbf{W}$
(2)	For $t=1, 2, \dots, T$ do
(3)	感知内容特征及用户特征
(4)	For all $k \in C$ do
(5)	如果内容是新内容:
(6)	初始化参数: $\mathbf{A}_k \leftarrow \mathbf{I}_d, \mathbf{B}_k \leftarrow \mathbf{0}_{d \times 1}$
(7)	结束
(8)	更新参数: $\theta_{t,k} \leftarrow \mathbf{A}_{t,k}^{-1} \mathbf{B}_{t,k},$ $P_{t,i,k} \leftarrow \mathbf{X}_{t,k}^T \theta_k + \alpha \sqrt{\mathbf{X}_{t,k}^T \mathbf{A}_{t,k}^{-1} \mathbf{X}_{t,k}},$ $\mathbf{A}_{t,k} \leftarrow \mathbf{A}_{t,k} + \mathbf{X}_{t,k} \mathbf{X}_{t,k}^T, \mathbf{B}_{t,k} \leftarrow \mathbf{B}_{t,k} + r_t \mathbf{X}_{t,k}$
(9)	当式(29)的值没有收敛时:
(10)	根据梯度更新参数
(11)	结束
(12)	计算未来价值
(13)	计算总价值
(14)	结束
(15)	按降序输出价值列表, 观察用户请求情况
(16)	结束

4.2 宏基站缓存

为了使得宏基站满足公共内容需求, 本文基于CSVP算法算的价值基础上设计了一种宏基站缓存选择算法。在不同的微基站缓存单元中的公共部分可以被认为具有较高的全局流行度, 因此只需要在CSVP算法的基础上筛选出公共部分即可。将CSVP算法计算得到的每个内容的每比特总价值按降序排列, 检查前 i 个内容大小总和是否超出总缓存空间, 在没有超出缓存空间的前提下把前 i 个内容缓存到本地。

5 仿真结果

在本节中将从内容命中率、平均请求时延方面将本文所提算法CSVP与FIFO, LRU, LFU算法进行比较。用户请求内容由Zipf定律决定并且每一次传输都可以正确传输。表2给出了相关仿真参数。

表 2 仿真参数设置

参数	参数值
内容库数量	5000
内容包大小	20 MB
SBS-UE延时	20 ms
BS-UE延时	50 ms
CDN-UE延时	100 ms
D2D延时	10 ms

在图3中,给出了不同策略的缓存命中率。可以看出,缓存空间较小时,CSVP策略的缓存命中率高于其他策略。这是由于CSVP和其他策略相比更关注用户个性化请求,在缓存空间为100时命中率约为43%,而其他对比算法命中率都低于40%。CSVP策略随着缓存空间增加,命中率可以接近70%。




图3 不同策略下的命中率

图4给出了缓存策略在时延方面的表现,和其他比较,本文提出的策略在一定程度上降低时延。时延随着命中率提高而降低。当缓存空间为100时,CSVP方法延时时约65 ms,LRU和FIFO方法时延大约为72 ms和66 ms。随着空间增大缓存命中率提高,时延进一步降低到40 ms。




图4 不同策略下的请求时延

在图5中,随着齐夫参数的增大,用户请求的内容更加集中,CSVP的命中率也随之达到78%。在图6中随着 α 增大,命中率也在逐步增大,证明对当前价值增加一个和内容特征相关的置信区间是有效的。当 ξ 从0增加到0.5时,缓存命中率从38%增加至42%说明将用户社交因素引入内容价值计算也是合理有效的。

6 结束语

本文提出基于内容和用户特征的内容价值预测算法解决缓存内容问题。结合特征感知,分析内容对用户的价值和存在社交关系的用户之间的潜在价




图5 不同齐夫参数下的命中率




图6 不同学习率下的命中率

值并通过D2D通信共享来用户之间的内容。在宏基站处,优先考虑大部分用户的请求内容偏好,微基站处针对范围内的用户提供更加个性化的缓存内容。通过仿真表明,CSVP策略优于现有的缓存策略,可以实现较好的降低时延效果。基站之间的内容迁移可以弥补本基站的内容库多样性不足的问题。另外,频繁读写缓存单元影响缓存单元寿命,降低读写次数又会降低缓存命中率,在成本与性能间取得一个平衡促进边缘缓存的应用。因此,下一步将深入研究缓存替换次数对系统性能的影响以及在不同宏基站、微基站之间的内容迁移问题。

参考文献

- [1] Cisco. Cisco visual networking index: Global mobile data traffic forecast update, 2017–2022 white paper[EB/OL]. <https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/white-paper-c11-738429.html>, 2019.
- [2] REBECCHI F, DE AMORIM M D, and CONAN V. Droid: Adapting to individual mobility pays off in mobile data offloading[C]. 2014 IFIP Networking Conference, Trondheim, Norway, 2014: 1–9. doi: 10.1109/IFIPNetworking.2014.6857087.
- [3] FANG Chao, YAO Haipeng, WANG Zhuwei, et al. A survey of mobile information-centric networking: research issues and challenges[J]. *IEEE Communications Surveys & Tutorials*, 2018, 20(3): 2353–2371. doi: 10.1109/COMST.

- 2018.2809670.
- [4] TATAR A, DE AMORIM M D, FDIDA S, *et al.* A survey on predicting the popularity of web content[J]. *Journal of Internet Services and Applications*, 2014, 5(1): 8. doi: [10.1186/s13174-014-0008-y](https://doi.org/10.1186/s13174-014-0008-y).
- [5] CHANDRASEKARAN G, WANG N, and TAFAZOLLI R. Caching on the move: Towards D2D-based information centric networking for mobile content distribution[C]. The 40th IEEE Conference on Local Computer Networks, Clearwater Beach, USA, 2015: 312–320, doi: [10.1109/LCN.2015.7366325](https://doi.org/10.1109/LCN.2015.7366325).
- [6] KHAN F H and KHAN Z. Popularity-aware content caching for distributed wireless helper nodes[J]. *Arabian Journal for Science and Engineering*, 2017, 42(8): 3375–3389. doi: [10.1007/s13369-017-2505-3](https://doi.org/10.1007/s13369-017-2505-3).
- [7] TAGHIZADEH M and BISWAS S. Community based cooperative content caching in social wireless networks[C]. The 14th ACM International Symposium on Mobile Ad Hoc Networking and Computing, Bangalore, India, 2013: 257–262. doi: [10.1145/2491288.2491318](https://doi.org/10.1145/2491288.2491318).
- [8] 柴蓉, 王令, 陈明龙, 等. 基于时延优化的蜂窝D2D通信联合用户关联及内容部署算法[J]. 电子与信息学报, 2019, 41(11): 2565–2570. doi: [10.11999/JEIT180408](https://doi.org/10.11999/JEIT180408).
- CHAI Rong, WANG Ling, CHEN Minglong, *et al.* Joint clustering and content deployment algorithm for cellular d2d communication based on delay optimization[J]. *Journal of Electronics & Information Technology*, 2019, 41(11): 2565–2570. doi: [10.11999/JEIT180408](https://doi.org/10.11999/JEIT180408).
- [9] MEGIDDO N and MODHA D S. ARC: A self-tuning, low overhead replacement cache[C]. The 2nd USENIX Conference on File and Storage Technologies, San Francisco, USA, 2003: 115–130.
- [10] MEGIDDO N and MODHA D S. Outperforming LRU with an adaptive replacement cache algorithm[J]. *Computer*, 2004, 37(4): 58–65. doi: [10.1109/MC.2004.1297303](https://doi.org/10.1109/MC.2004.1297303).
- [11] XIANG Lin, Ng D W K, GE Xiaohu, *et al.* Cache-aided non-orthogonal multiple access: The two-user case[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2019, 13(3): 436–451. doi: [10.1109/JSTSP.2019.2907864](https://doi.org/10.1109/JSTSP.2019.2907864).
- [12] LI Lihong, CHU Wei, LANGFORD J, *et al.* A contextual-bandit approach to personalized news article recommendation[C]. The 19th International Conference on World Wide Web, Raleigh, USA, 2010: 661–670. doi: [10.1145/1772690.1772758](https://doi.org/10.1145/1772690.1772758).
- [13] ZIPF G K. Selected studies of the principle of relative frequency in language[J]. *Language*, 1933, 9(1): 89–92. doi: [10.4159/harvard.9780674434929](https://doi.org/10.4159/harvard.9780674434929).
- [14] JIANG Wei, FENG Gang, QIN Shuang, *et al.* Multi-agent reinforcement learning for efficient content caching in mobile D2D networks[J]. *IEEE Transactions on Wireless Communications*, 2019, 18(3): 1610–1622. doi: [10.1109/TWC.2019.2894403](https://doi.org/10.1109/TWC.2019.2894403).
- [15] WALSH T J, SZITA I, DIUK C, *et al.* Exploring compact reinforcement-learning representations with linear regression[C]. The 25th Conference on Uncertainty in Artificial Intelligence, Montreal, Canada, 2009, 591–598.
- [16] MA Hao, ZHOU T C, LYU M R, *et al.* Improving recommender systems by incorporating social contextual information[J]. *ACM Transactions on Information Systems*, 2011, 29(2): 1–23. doi: [10.1145/1961209.1961212](https://doi.org/10.1145/1961209.1961212).
- [17] YANG Bo, LEI Yu, LIU Jiming, *et al.* Social collaborative filtering by trust[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(8): 1633–1647. doi: [10.1109/TPAMI.2016.2605085](https://doi.org/10.1109/TPAMI.2016.2605085).
- 杨 静: 女, 1972年生, 高级工程师, 研究方向为泛在无线通信网络、物联网技术等。
- 李金科: 男, 1995年生, 硕士生, 研究方向为D2D通信。

责任编辑: 余 蓉