

互联网的核心应用：视频

- ❖ 用户观看视频的质量体验（QoE）直接影响视频内容提供商的收入，因此提升用户的QoE至关重要
- ❖ 提升QoE的根本挑战：视频动态码率与网络带宽动态变化之间的**不匹配性**

GLOBAL APPLICATION CATEGORY TRAFFIC SHARE				
	Rank Change	Category	Downstream	Upstream
1	-	Video Streaming	48.9%	19.4%
2	-	Social Networking	19.3%	16.6%
3	2	Web	13.1%	23.1%
4	-1	Messaging	6.7%	20.4%
5	-	Gaming	4.3%	1.9%
6	-2	Marketplace	4.1%	1.2%
7	2	File Sharing	1.3%	6.6%
8	-1	Cloud	1.1%	6.7%
9	-3	VPN and Security	0.9%	3.9%
10	-	Audio	0.2%	0.2%

提升QoE的关键：ABR算法

- ❖ 点播视频以**DASH** (Dynamic Adaptive Streaming over HTTP) 作为传输标准，已在业界广泛部署 (YouTube, Netflix, Bilibili)
- ❖ 在DASH中，一个视频被编码为多种不同码率的版本，每个版本并被划分为多个等长的视频块 (2~5s)
- ❖ DASH客户端运行**ABR** (Adaptive BitRate) 算法，为每一个视频块选择码率，目标是最大化**QoE** (Quality of Experience)

$$QoE = \sum_{k=1}^N q(R_k) - \mu \sum_{k=1}^N \max\left(\left(\frac{d_k(R_k)}{T_k} - B_k\right), 0\right) - \lambda \sum_{k=1}^{N-1} |q(R_{k+1}) - q(R_k)|$$

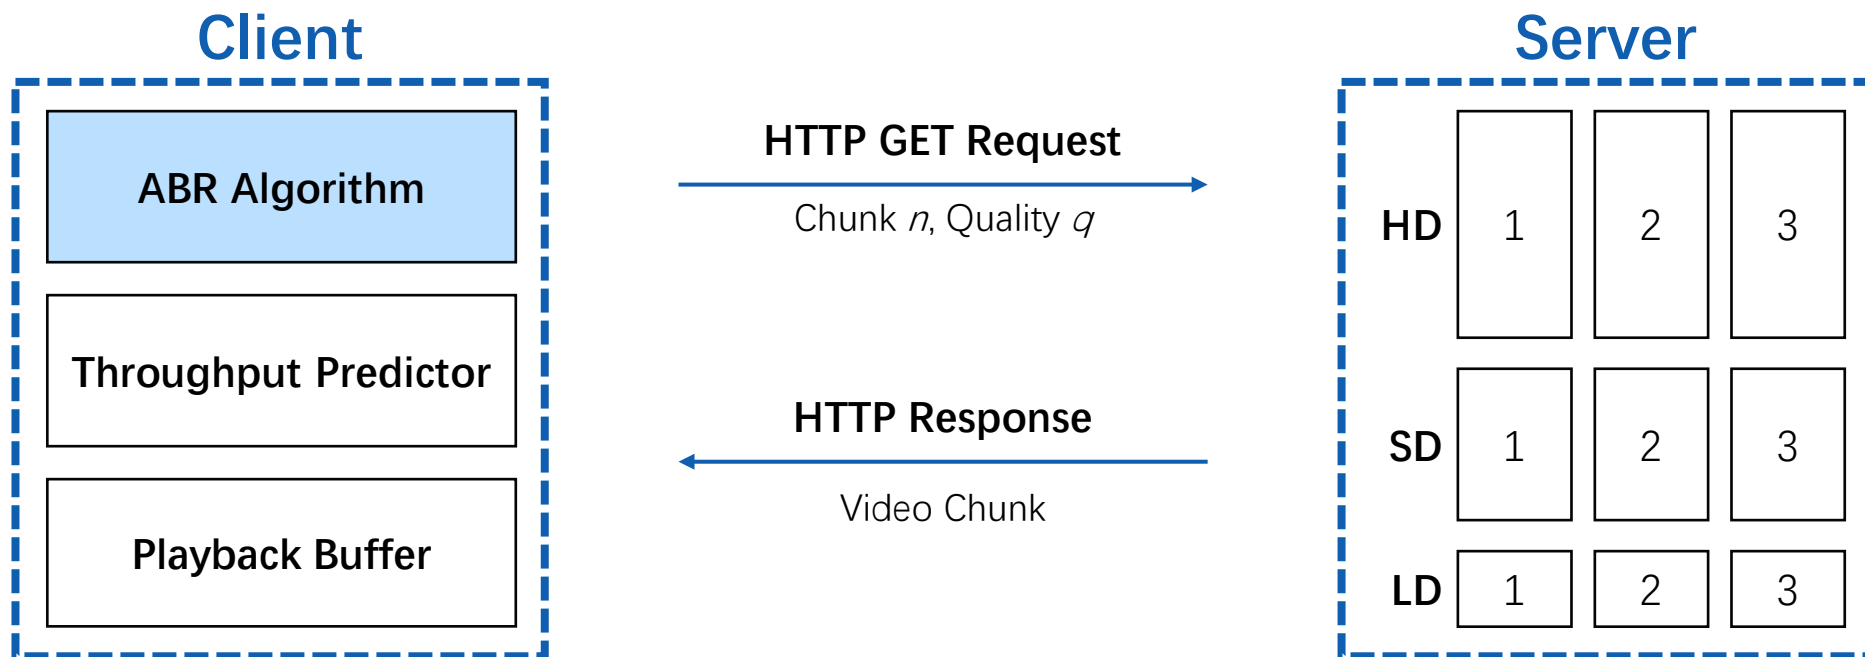
视频质量

卡顿时间

质量切换

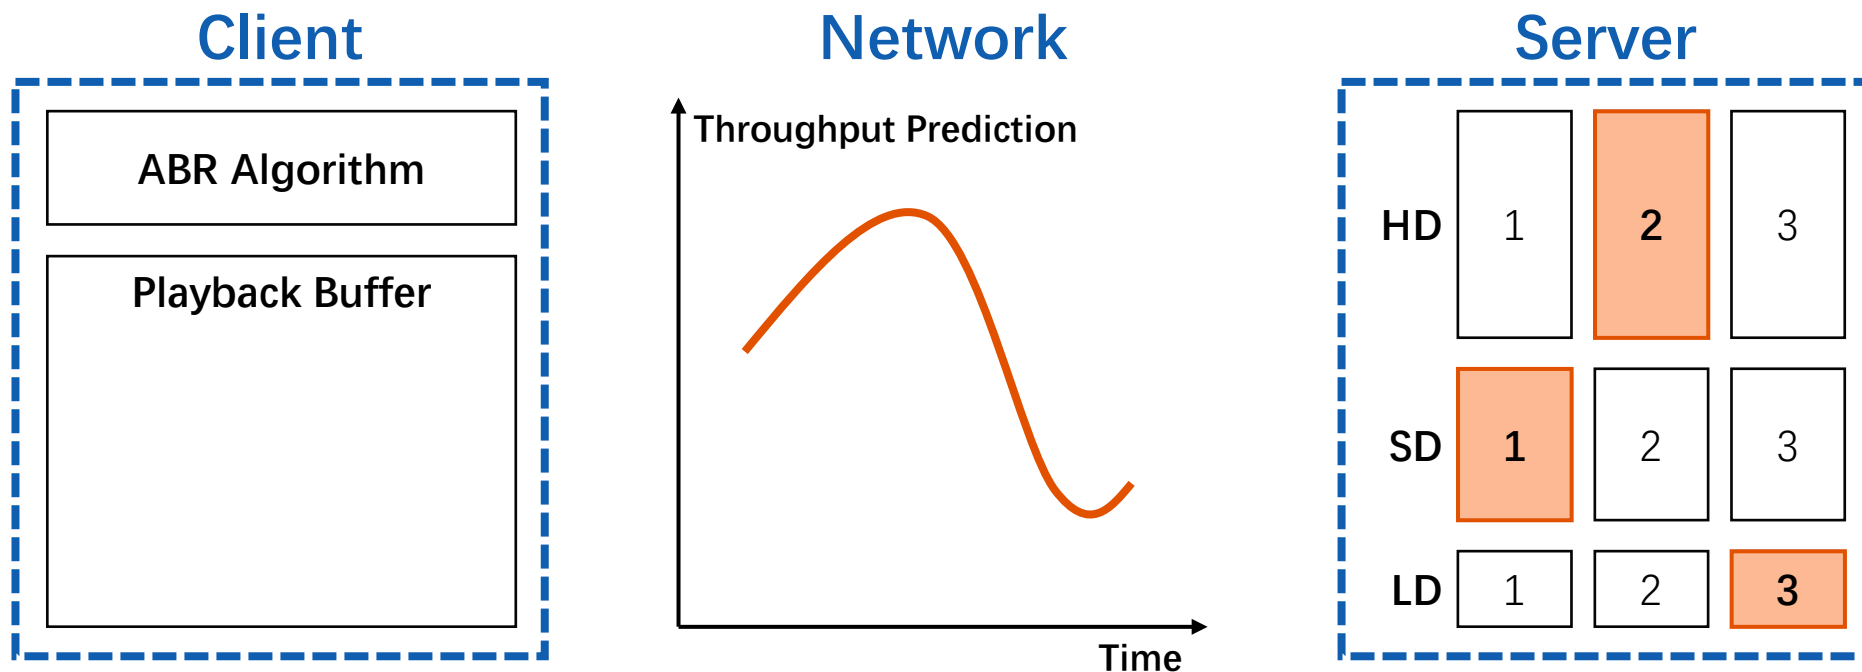
提升QoE的关键：ABR算法

- ❖ DASH客户端运行**ABR**算法，为每一个视频块选择码率，目标是最大化**QoE**
 - ▶ 目标：高质量，低卡顿，少质量切换
 - ▶ 输入：视频块吞吐量，播放缓冲区时长等
 - ▶ 输出：视频块的码率/清晰度




提升QoE的关键：ABR算法

- ❖ DASH客户端运行**ABR**算法，为每一个视频块选择码率，目标是最大化**QoE**
 - ▶ 目标：高质量，低卡顿，少质量切换
 - ▶ 输入：视频块吞吐量，播放缓冲区时长等
 - ▶ 输出：视频块的码率/清晰度




提升QoE的关键：ABR算法

- ❖ DASH客户端运行**ABR**算法，为每一个视频块选择码率，目标是最大化**QoE**
 - ▶ 目标：高质量，低卡顿，少质量切换
 - ▶ 输入：视频块吞吐量，播放缓冲区时长等
 - ▶ 输出：视频块的码率/清晰度



提升QoE的关键：ABR算法

- ❖ DASH客户端运行**ABR**算法，为每一个视频块选择码率，目标是最大化**QoE**
 - ▶ 目标：高质量，低卡顿，少质量切换
 - ▶ 输入：视频块吞吐量，播放缓冲区时长等
 - ▶ 输出：视频块的码率/清晰度



ABR算法学术研究

❖ 客户端ABR算法可分为四类

- 决策逻辑：线性函数、控制论、机器学习等

1

基于吞吐量

FESTIVE [CoNEXT'12]
PANDA [JSAC'14]
CS2P [SIGCOMM'16]

2

基于缓冲区

BBA [SIGCOMM'14]
BOLA [INFOCOM'16]

3

基于混合信息

MPC [SIGCOMM'15]
PBA [HotMobile'15]

4

基于机器学习

Pensieve [SIGCOMM'17]
Comyco [MM'19]




BBA [SIGCOMM'14]

A Buffer-Based Approach to Rate Adaptation: Evidence from a Large Video Streaming Service

研究动机

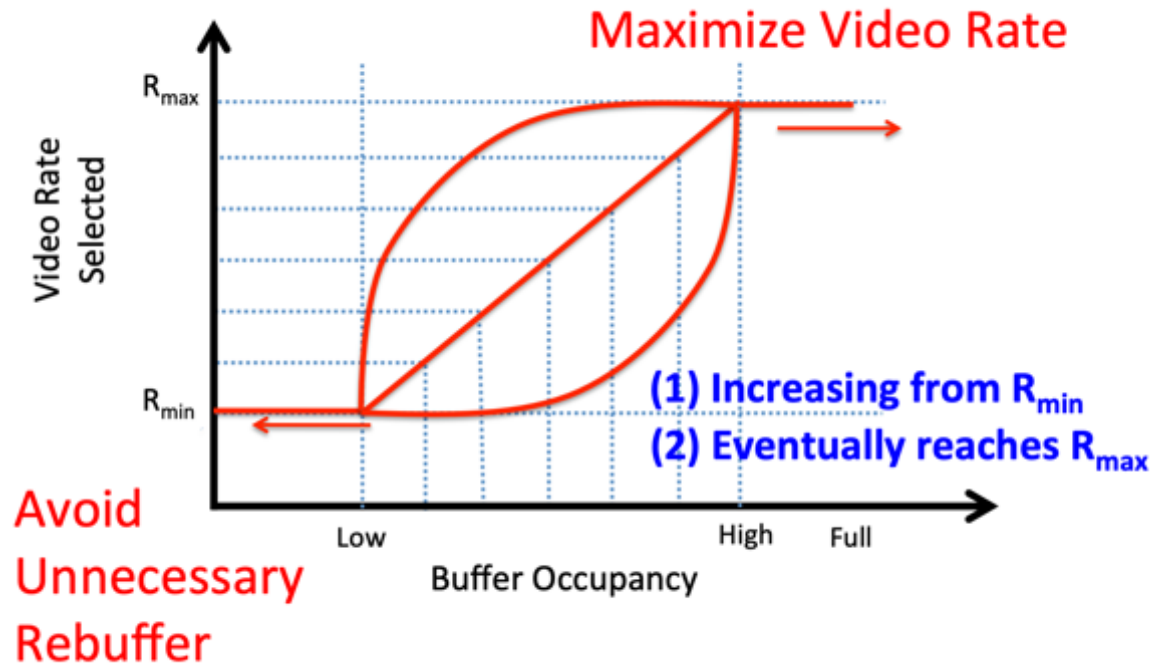
- ❖ 基于吞吐量的ABR算法依赖于吞吐量预测
- ❖ **挑战**：应用层（HTTP）吞吐量高度动态变化，难以准确预测
 - ▶ 受竞争流量、网络环境等因素影响



Basic idea: 避免预测吞吐量，仅基于缓冲区水平选择码率

Buffer-Based Algorithm


- ❖ 思想：在稳定阶段，将码率选择视作缓冲区水平的函数
 - ▶ 缓冲区水平隐含了关于网络容量变化的信息
 - ▶ 在启动阶段，依然需要基于吞吐量预测选择码率



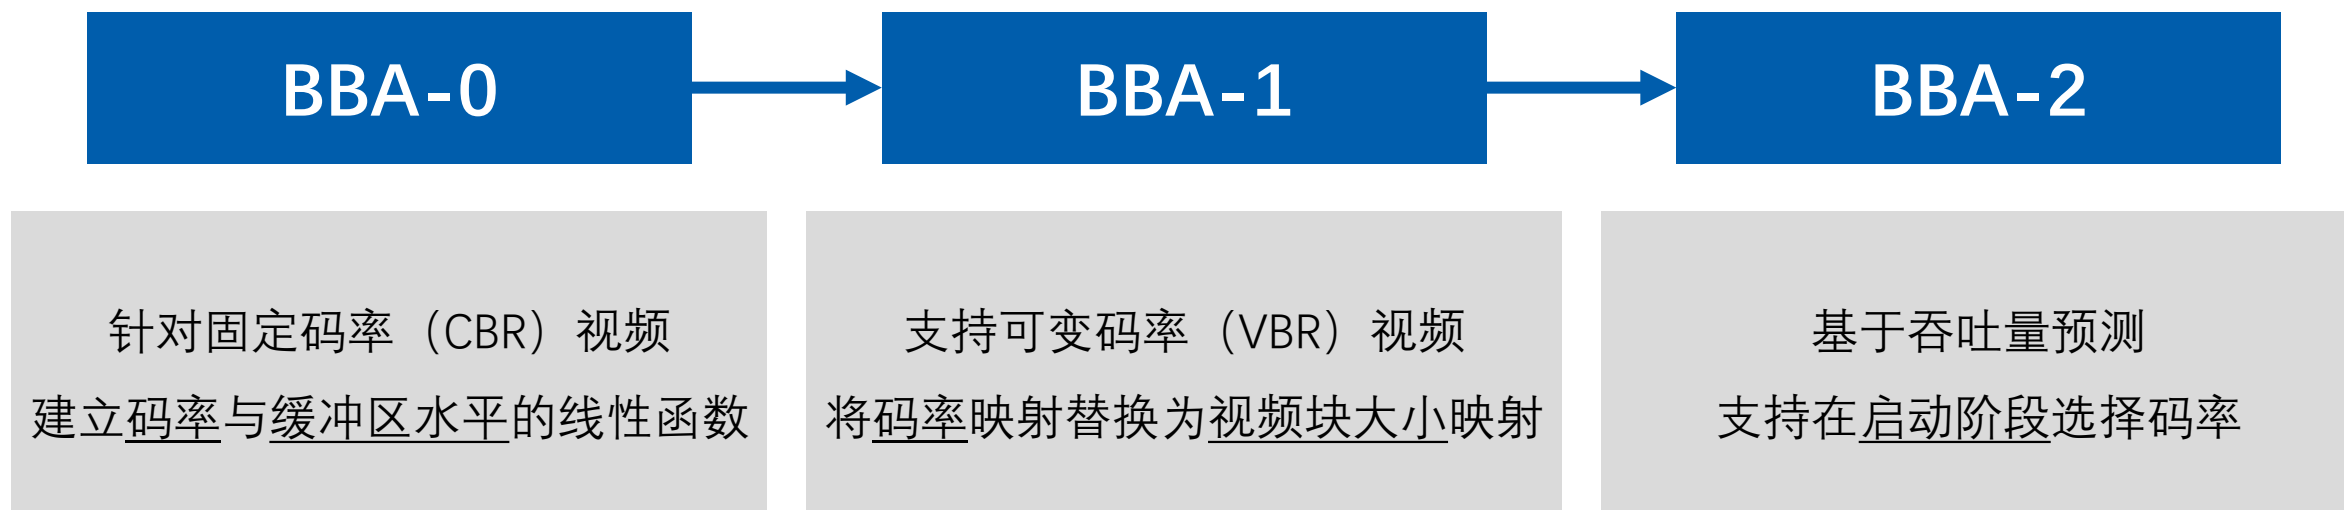
线性函数：平衡视频码率与卡顿

BBA-0决策逻辑

- ❖ 思想：在稳定阶段，将码率选择视作缓冲区水平的**线性函数**
- ❖ 设计：两个缓冲区阈值，reservoir和cushion
 - ▶ Buffer Occupancy < reservoir：选择最低码率
 - ▶ Buffer Occupancy > reservoir + cushion：选择最高码率
 - ▶ Otherwise：通过线性函数确定缓冲区水平对应的码率级别



BBA变体



实验评估设置

❖ 实验环境：Netflix

- ▶ 将BBA部署于基于浏览器的播放器中
- ▶ 2013年9月，一周50W用户

❖ 对比方法

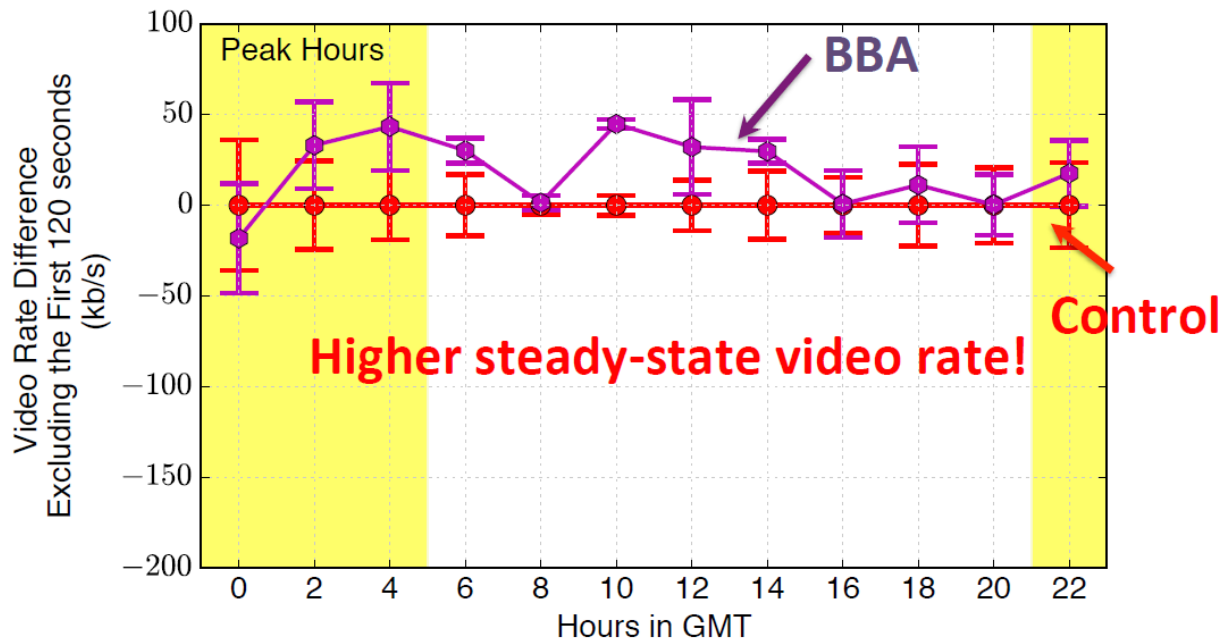
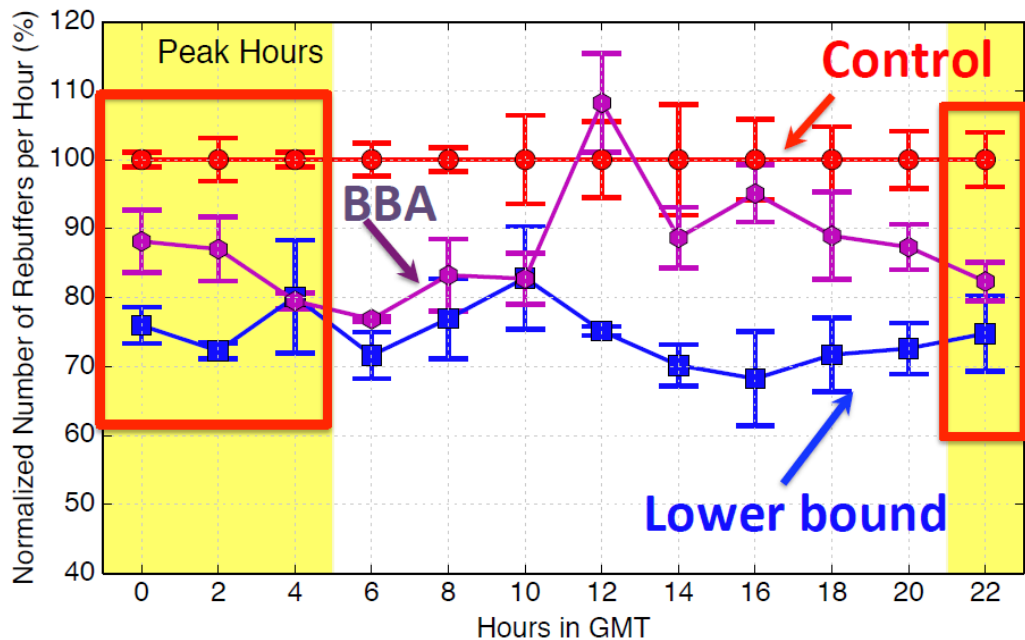
- ▶ Control: Netflix默认算法
- ▶ Lower bound: 持续选择最低码率（代表卡顿的下限）

❖ 性能指标

- ▶ 卡顿
- ▶ 码率

BBA-2评估结果

❖ 效果：BBA-2实现了10%-20%的卡顿下降，同时也提高了稳定阶段的码率



总结

❖ 优势&研究亮点

- ▶ 首个仅基于缓冲区进行码率选择的算法
- ▶ BBA-0设计与实现简单，便于部署
- ▶ BBA-0在真实场景中码率和卡顿表现优秀 (Learning in Situ [NSDI'20])

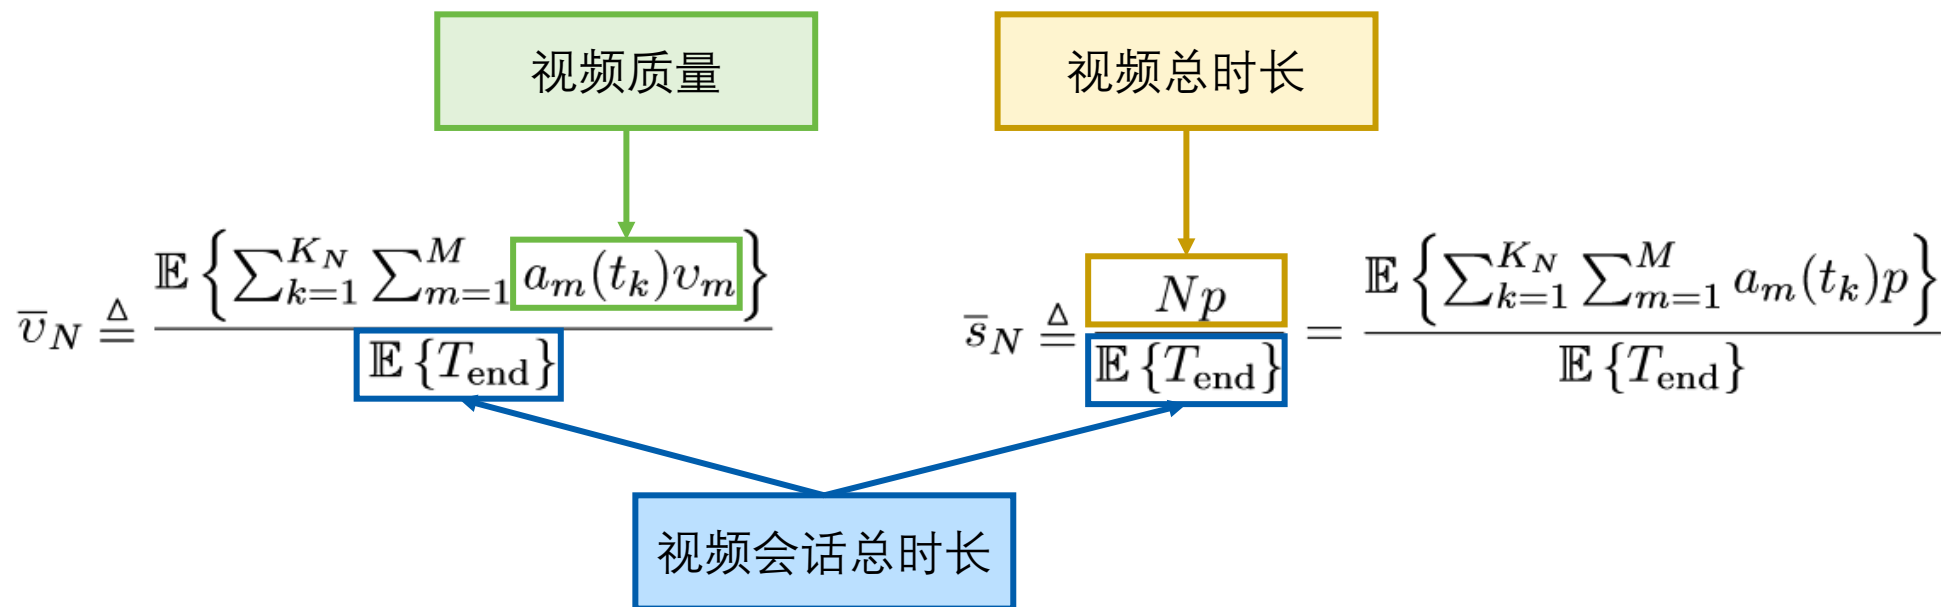
❖ 不足&后续研究

- ▶ 在稳定阶段完全忽略了吞吐量信息 → MPC [SIGCOMM'15]
- ▶ 码率切换较为频繁 → BBA-Others
- ▶ 线性映射未必最优 → BOLA [INFOCOM'16] / Stick [INFOCOM'21]
- ▶ 缺乏明确的QoE优化目标 → MPC [SIGCOMM'15] / BOLA [INFOCOM'16]

BOLA [INFOCOM'16]

BOLA: Near-optimal bitrate adaptation for online videos

- ❖ 思想：将ABR形式化为效用最大化问题，基于李雅普诺夫优化求解
 - ▶ 两类效用：提高平均视频质量 \bar{v}_N ，降低卡顿时间（即增加不卡顿时间占比 \bar{s}_N ）
 - ▶ 总效用 = $\bar{v}_N + \gamma \bar{s}_N$





BOLA-BASIC决策逻辑

❖ 逻辑：求解 $(Vv_m + V\gamma p - Q(t_k))/S_m$ 的最大值，为下一视频块选择码率

- ▶ V 、 γ ：调整参数
- ▶ v_m ：码率级别 m 的视频质量（与码率呈对数关系）
- ▶ p ：视频块时长
- ▶ $Q(t_k)$ ：第 k 个时隙中缓冲区的视频块数量
- ▶ S_m ：码率级别 m 的视频块大小

❖ 决策函数：阶梯状



BOLA变体



实验评估设置

❖ 实验环境： Trace-driven Simulation

❖ 对比方法

- ▶ ELASTIC、PANDA
- ▶ 离线最优（基于动态规划，代表最高效用）


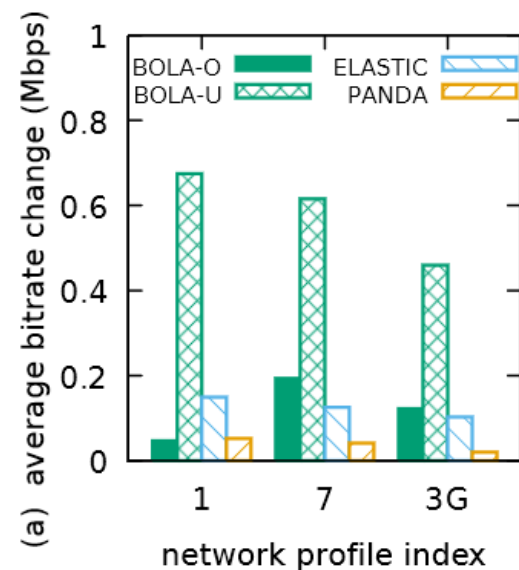
❖ 数据集

- ▶ 网络trace： Norway 3G/HSDPA、 DASH benchmarks
- ▶ 视频： Big Buck Bunny（10min）， 视频块大小3s， 10种码率级别， 缓冲区上限25s

BOLA-O & BOLA-U评估结果

❖ 效果:

- ▶ BOLA-U的效用始终优于对比算法，且在离线最优的84%-95%范围内
- ▶ BOLA-O的效用略低于BOLA-U，但码率切换程度明显降低



总结

❖ 优势&研究亮点

- ▶ 基于缓冲区的ABR算法代表作之一
- ▶ BOLA-O作为dash.js开源视频播放器默认ABR算法的核心部分，在真实场景中得以应用
- ▶ 基于李雅普诺夫优化方法设计，理论性较强

❖ 不足&后续研究


- ▶ 稳定阶段忽略吞吐量信息 → MPC [SIGCOMM'15] / BOLA-E & DYNAMIC [MMSys'18]
- ▶ 缺乏统一的QoE优化目标 → MPC [SIGCOMM'15]
- ▶ 不同环境下的最优参数难以确定 → Oboe [SIGCOMM'18]
- ▶ 除了ABR算法外还涉及视频块请求等逻辑，实现繁琐且偏工程化，部署较为困难

MPC [SIGCOMM'15]

A Control-Theoretic Approach for Dynamic Adaptive Video Streaming over HTTP

研究动机

- ❖ 设计空间：过往算法或只基于吞吐量，或只基于缓冲区水平



Basic idea: 将吞吐量与缓冲区信息结合以进行码率选择

Model Predictive Control

- ❖ 思想：将ABR形式化为**随机最优控制**问题，利用**模型预测控制（MPC）**求解
- ❖ 设计选择：strawman solutions
 - ▶ 比例-积分-微分（PID）：目标是稳定性而非优化，且适用于连续系统而非离散系统
 - ▶ 马尔可夫决策过程（MDP）：假设吞吐量变化服从马尔可夫过程，实践中不一定否成立
 - ▶ **模型预测控制（MPC）**：将码率选择视为有限时域内的QoE最大化问题，适用于ABR算法

Model Predictive Control

❖ 原理：预测关键变量，求解优化问题

- ▶ 预测有限时间范围的吞吐量
- ▶ 基于预测吞吐量，根据**视频缓冲区模型**，估计解空间中每组解取得的QoE
- ▶ 选择能够使总体**QoE目标**最大的一组码率选择作为解

❖ 算法步骤：

- ▶ 解空间初始化：考虑未来5个视频块的6种码率选择，解空间大小为 6^5
- ▶ 预测吞吐量：计算过去5个视频块的调和平均数，作为吞吐量预测值
- ▶ 最大化QoE：遍历解空间中的每组解（即未来5个视频块的码率选择），计算每组解对应的预期QoE，记录最大值
- ▶ 输出决策：将能够使QoE最大化的一组解的第一个码率选择作为算法输出

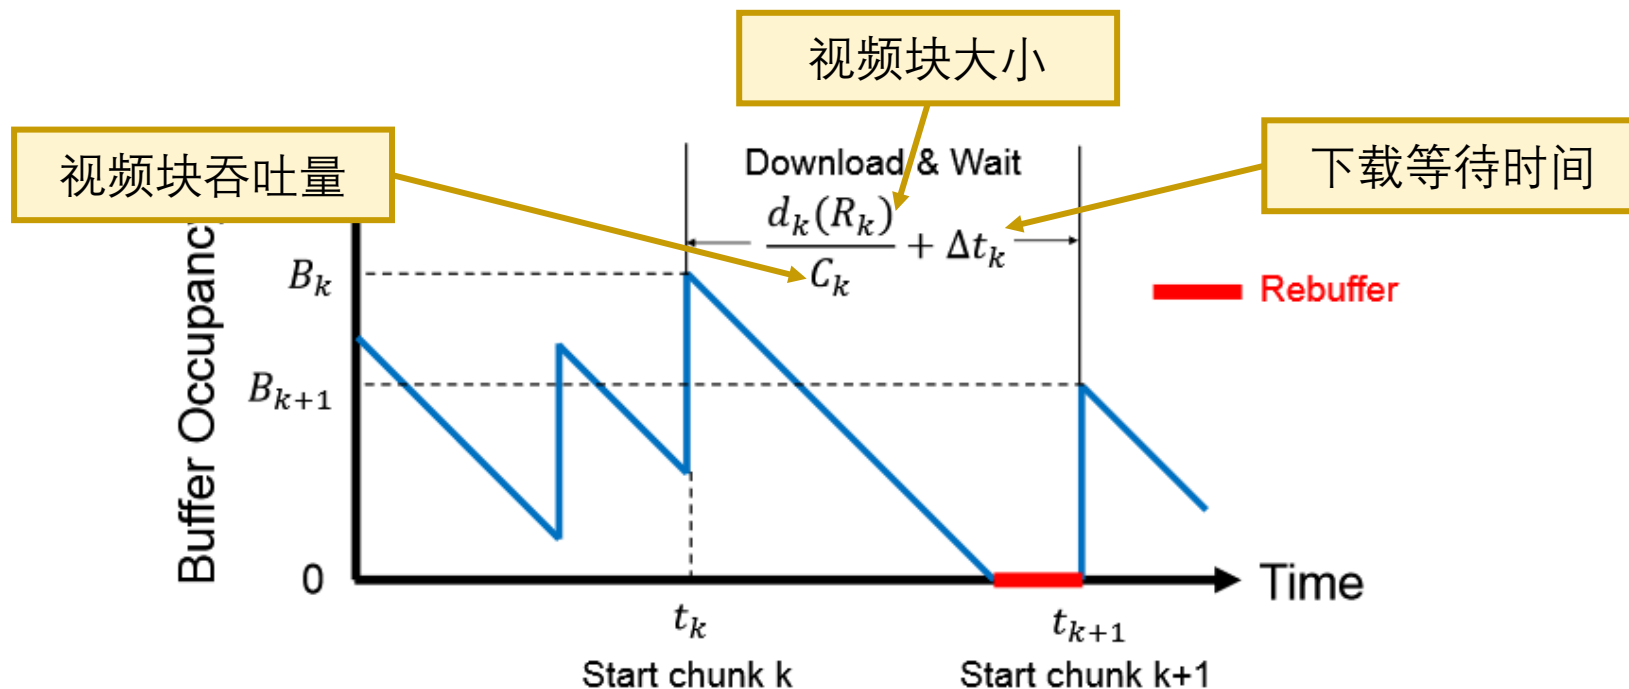
视频缓冲区模型

❖ 缓冲区水平变化

- ▶ 减少：视频观看过程中，缓冲区水平随播放时间匀速减少
- ▶ 增加：视频块下载完成后，缓冲区水平增加一个视频块的时长

❖ 卡顿：初始缓冲区水平 < 视频块下载时间（忽略下载等待时间）

- ▶ 视频块下载时间 = 视频块大小 $d_k(R_k)$ / 视频块吞吐量 C_k



QoE目标

❖ 将QoE目标建模为多个指标的线性函数

- ▶ 视频质量: $q(R_k)$ (可简化为码率: R_k)
- ▶ 卡顿时间: $\max\left(\left(\frac{d_k(R_k)}{T_k} - B_k\right), 0\right)$
- ▶ 质量切换: $|q(R_{k+1}) - q(R_k)|$ (可简化为码率切换: $|R_{k+1} - R_k|$)
- ▶ 启动延迟: T_s (通常忽略)

$$QoE = \sum_{k=1}^N q(R_k) - \mu \sum_{k=1}^N \max\left(\left(\frac{d_k(R_k)}{T_k} - B_k\right), 0\right) - \lambda \sum_{k=1}^{N-1} |q(R_{k+1}) - q(R_k)| - \mu_s T_s$$

QoE最大化问题

❖ 参数

- ▶ $\mu, \lambda, \mu_s, q(\cdot)$

❖ 输入

- ▶ 视频块时长: L
- ▶ 视频块大小: $d_k(\cdot)$
- ▶ 缓冲区上限: B_{max}
- ▶ 吞吐量trace: $\{C_t\}$

需要预测

❖ 输出

- ▶ 码率决策: R_1, \dots, R_K (K 为最大视频块序号)
- ▶ 启动延迟: T_s
- ▶ 下载等待时间: Δt_k

$$\max_{R_1, \dots, R_K, T_s} QoE_1^K \quad (6)$$

$$s.t. \quad t_{k+1} = t_k + \frac{d_k(R_k)}{C_k} + \Delta t_k, \quad (7)$$

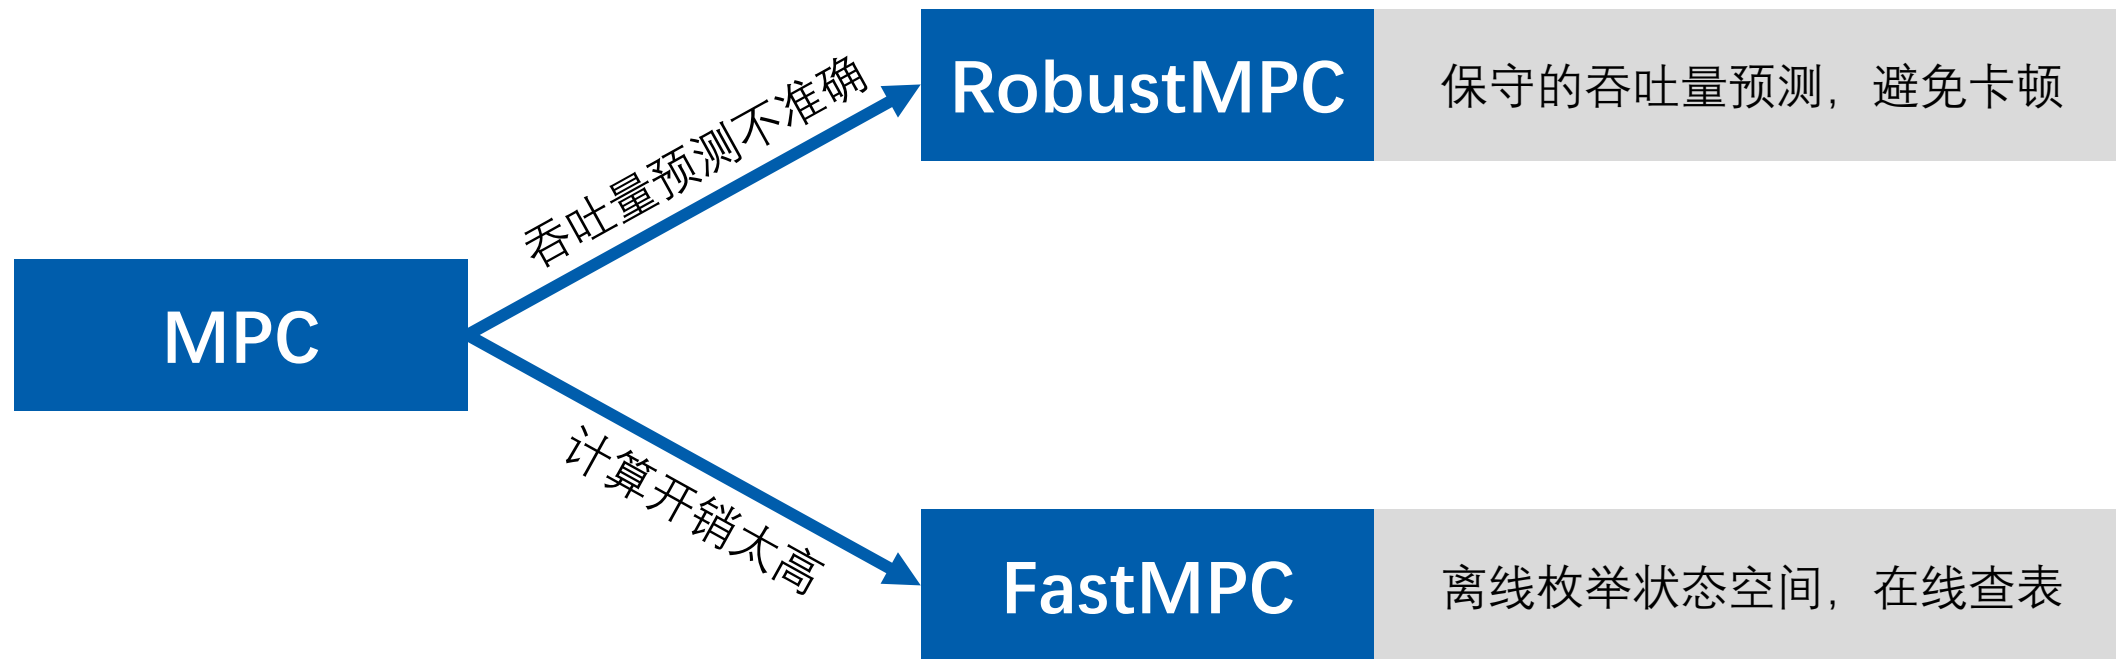
$$C_k = \frac{1}{t_{k+1} - t_k - \Delta t_k} \int_{t_k}^{t_{k+1} - \Delta t_k} C_t dt, \quad (8)$$

$$B_{k+1} = \left(\left(B_k - \frac{d_k(R_k)}{C_k} \right)_+ + L - \Delta t_k \right)_+, \quad (9)$$

$$B_1 = T_s, \quad B_k \in [0, B_{max}] \quad (10)$$

$$R_k \in \mathcal{R}, \quad \forall k = 1, \dots, K. \quad (11)$$

MPC变体



实验评估设置

❖ 实验环境：Trace-driven仿真

- ▶ Emulation（性能评估）：Linux tc限速，基于dash.js播放器进行实验
- ▶ Simulation（敏感性分析）

❖ 对比方法

- ▶ RB、BB（BBA-0）、FESTIVE [CoNEXT'12]、dash.js默认类RB算法


❖ 数据集

- ▶ 网络trace：FCC、Norway 3G/HSDPA、Synthetic
- ▶ 视频：Envivio（260s），视频块大小4s，码率级别{350kbps, 600kbps, 1000kbps, 2000kbps, 3000kbps}，缓冲区上限30s

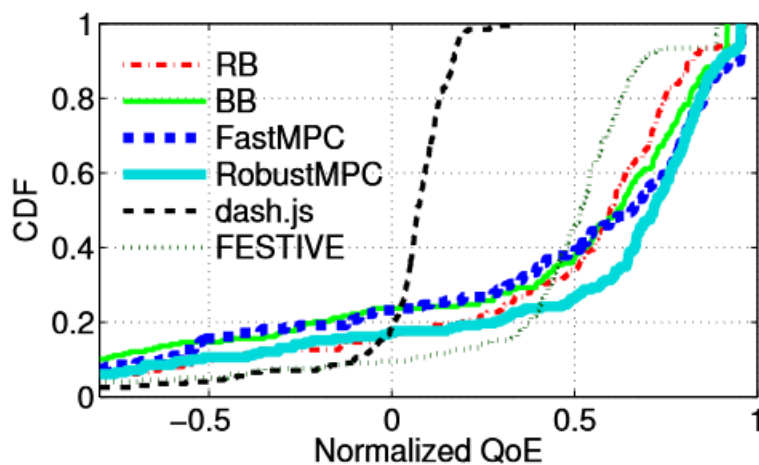
RobustMPC & FastMPC评估结果

❖ 效果:


- ▶ RobustMPC在三种数据集上相对次优算法分别实现了15%、10%和5%的QoE提升
- ▶ FastMPC的性能受预测错误率影响，在FCC和Synthetic数据集上表现较好，在HSDPA数据集上性能有所下降



(a) FCC dataset



(b) HSDPA dataset



(c) Synthetic dataset

总结

❖ 优势&研究亮点

- ▶ 基于混合信息的ABR算法代表作，扩展了ABR算法的设计空间
- ▶ 基于控制论方法设计，性能有理论保证
- ▶ MPC与RobustMPC实现较为简单，便于部署
- ▶ 统一了不同的QoE优化目标，是后续研究工作的基础

❖ 不足&后续研究


- ▶ 依赖准确的吞吐量预测 → CS2P [SIGCOMM'16] / Fugu [NSDI'20] / Lumos [INFOCOM'22]
- ▶ MPC计算开销较大 → PiTree [MM'19]
- ▶ 线性QoE不一定符合真实用户感知 → ITU-P P.1203

Pensieve [SIGCOMM'17]

Neural Adaptive Video Streaming with Pensieve

研究动机

- ❖ MPC的性能依赖于准确的吞吐量预测，在高动态网络环境下很难实现
- ❖ RobustMPC采用更保守的吞吐量预测，但很难实现最优性能

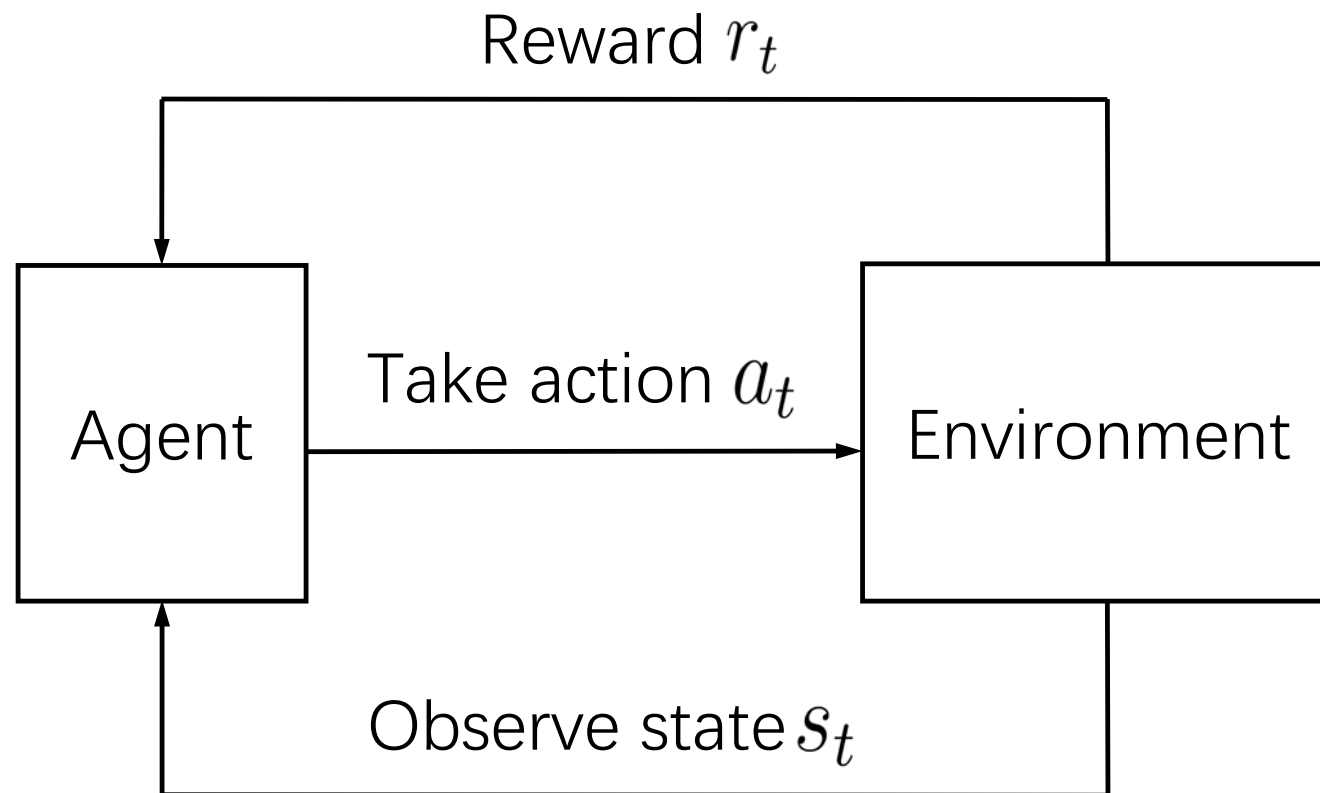


Basic idea: 从视频流会话中学习网络环境变化

Pensieve原理：强化学习

❖ 框架：代理（Agent）+环境（Environment）

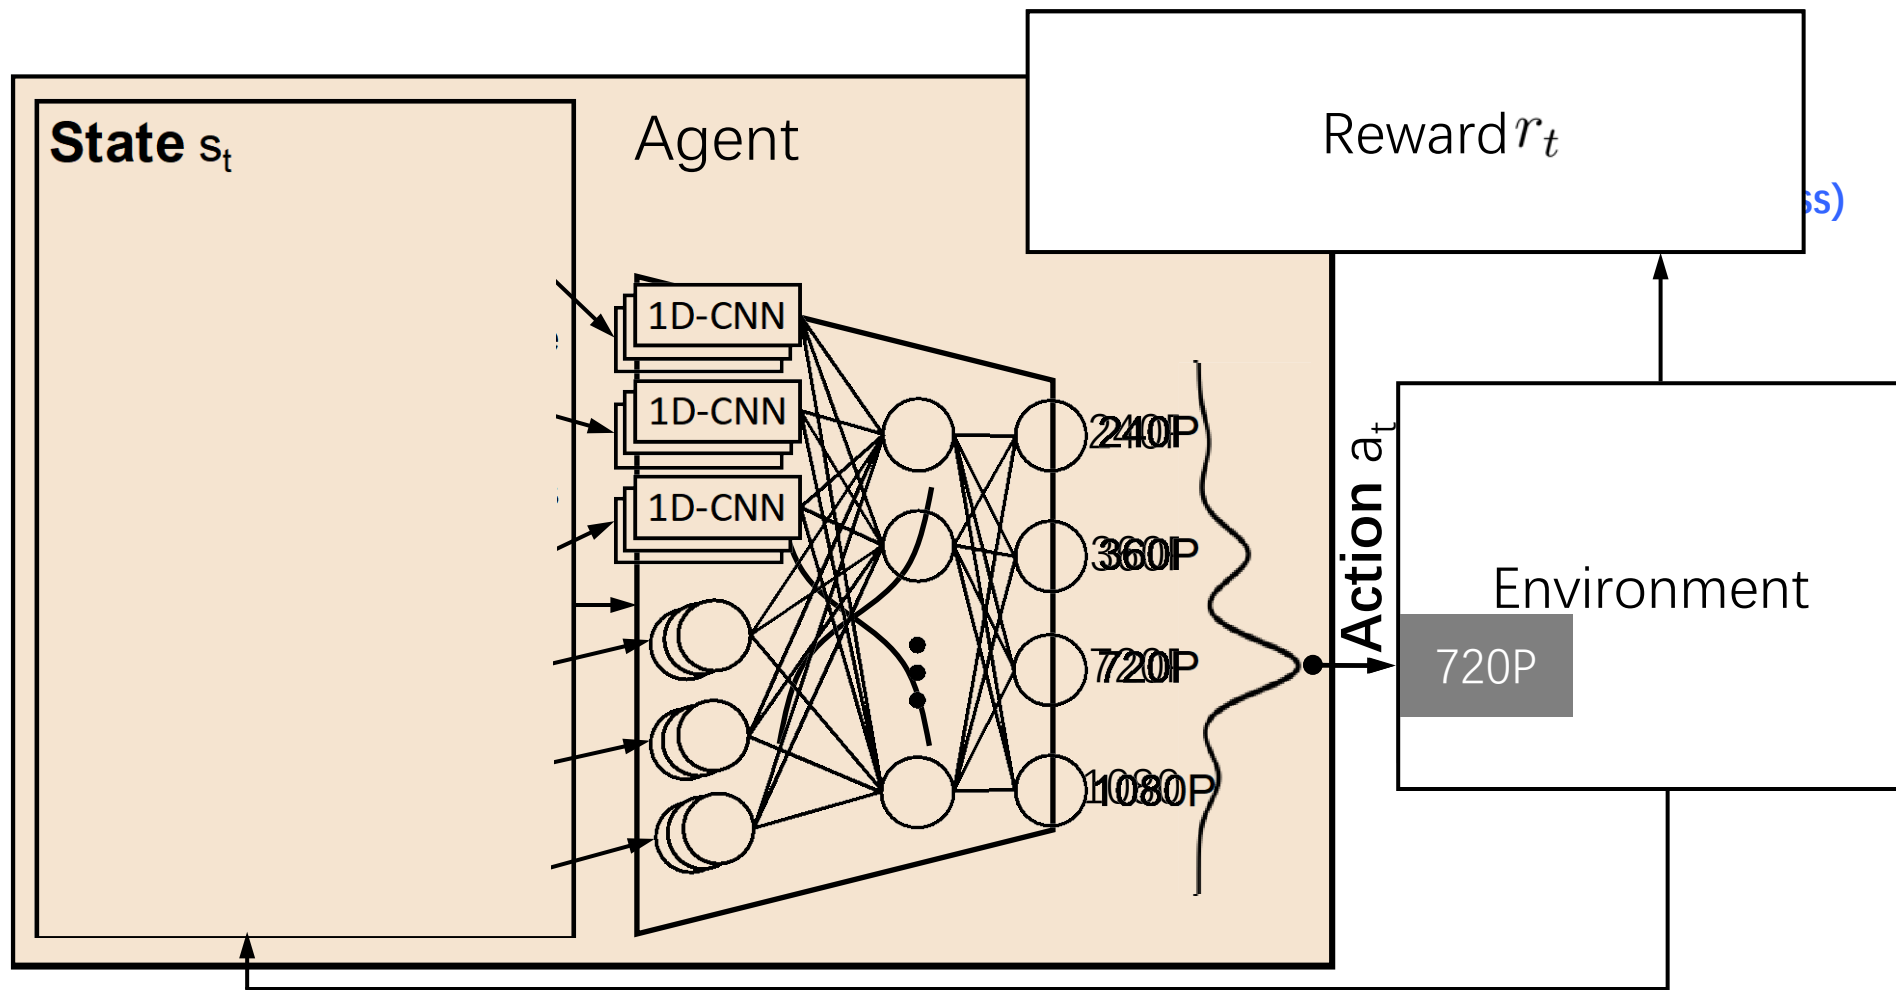
- ▶ 代理基于观察的状态（输出特征），做出行动（输出码率决策），获得奖励（QoE分数）

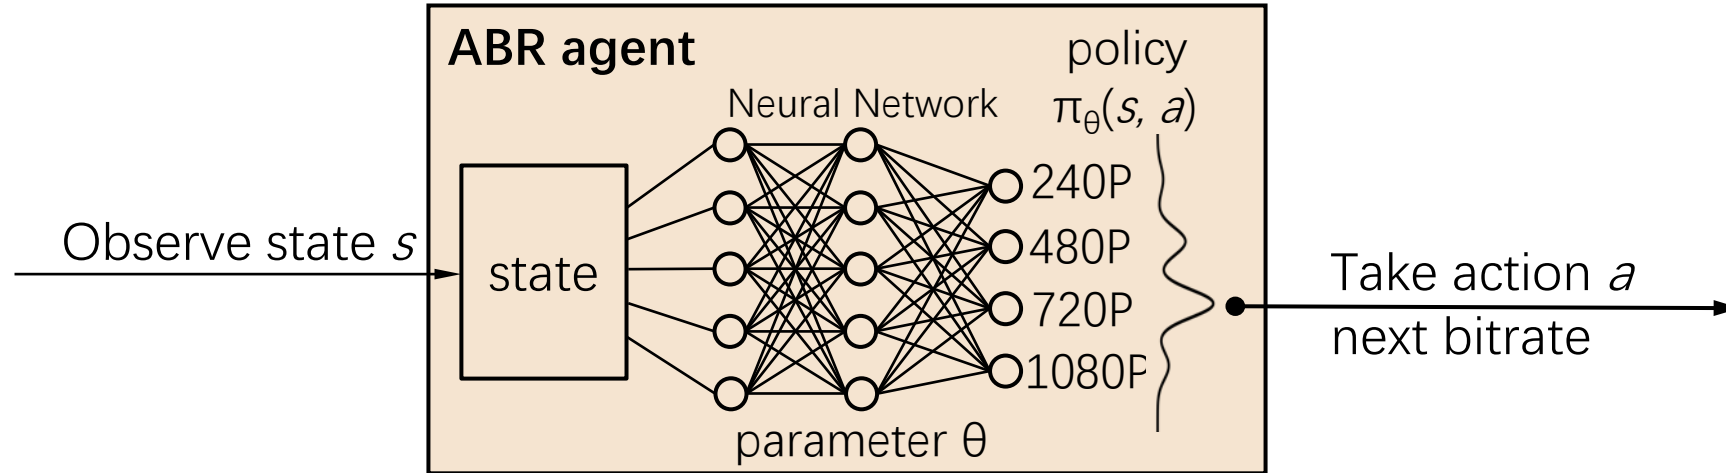


目标：最大化累积奖励 $\sum_t r_t$



Pensieve设计

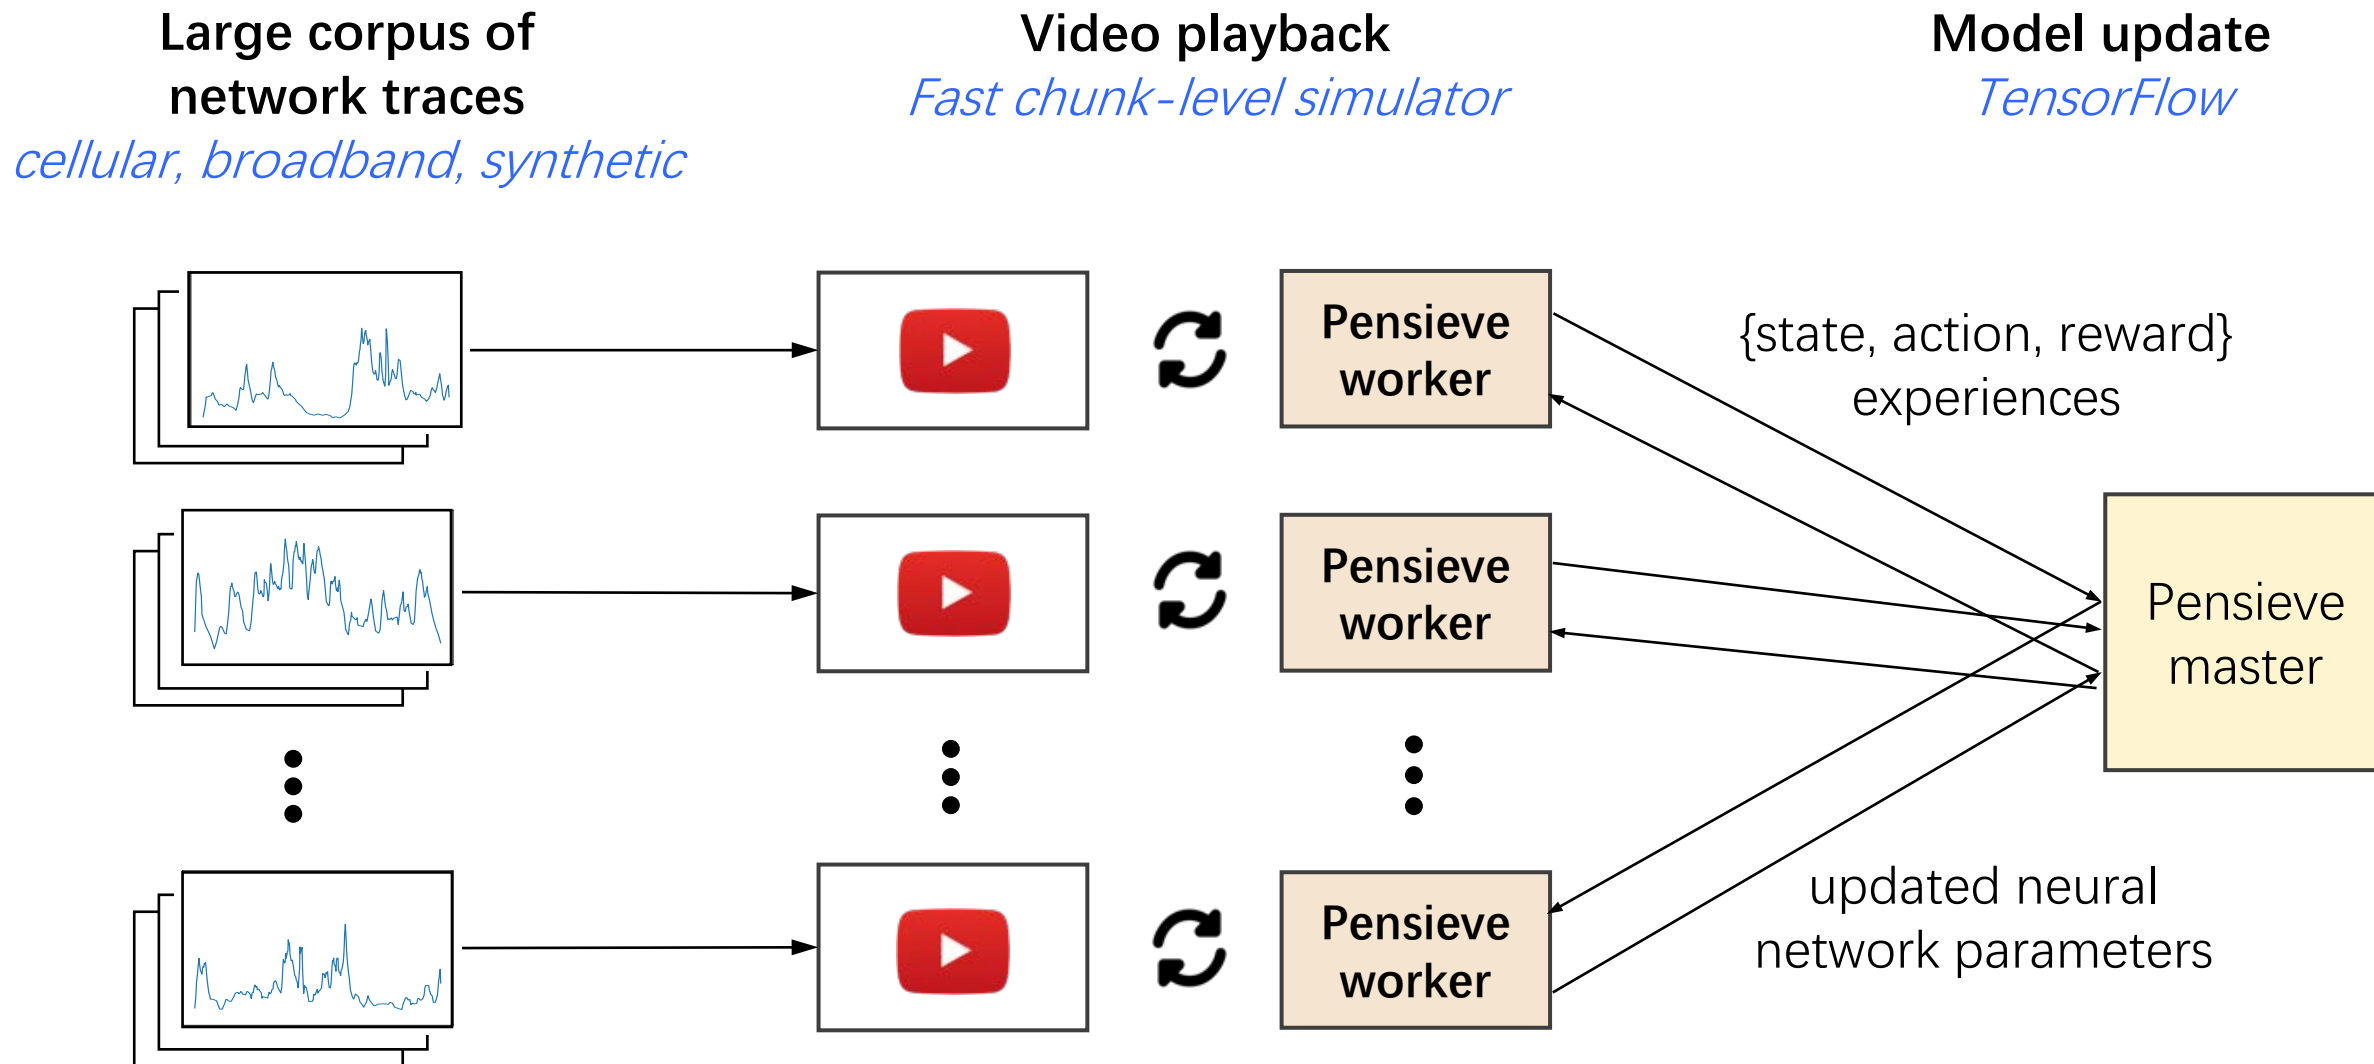




Collect experience data: trajectory of [state, action, reward]

Training: $\theta \leftarrow \theta + \alpha \nabla_{\theta} \mathbb{E}_{\pi_{\theta}} \left[\sum_t r_t \right]$ → estimate from empirical data

Pensieve训练系统 (A3C)



实验评估设置

❖ 实验环境: Trace-driven Emulation & Simulation

❖ 对比方法

- ▶ RB、BB (BBA-0) 、BOLA、MPC、RobustMPC
- ▶ 离线最优 (代表性能上限)


❖ 数据集

- ▶ 网络trace: FCC、Norway 3G/HSDPA
- ▶ 视频: EnvivioDash3 (193s) , 视频块大小4s, 码率级别{300, 750, 1200, 1850, 2850, 4300} kbps, 缓冲区上限60s

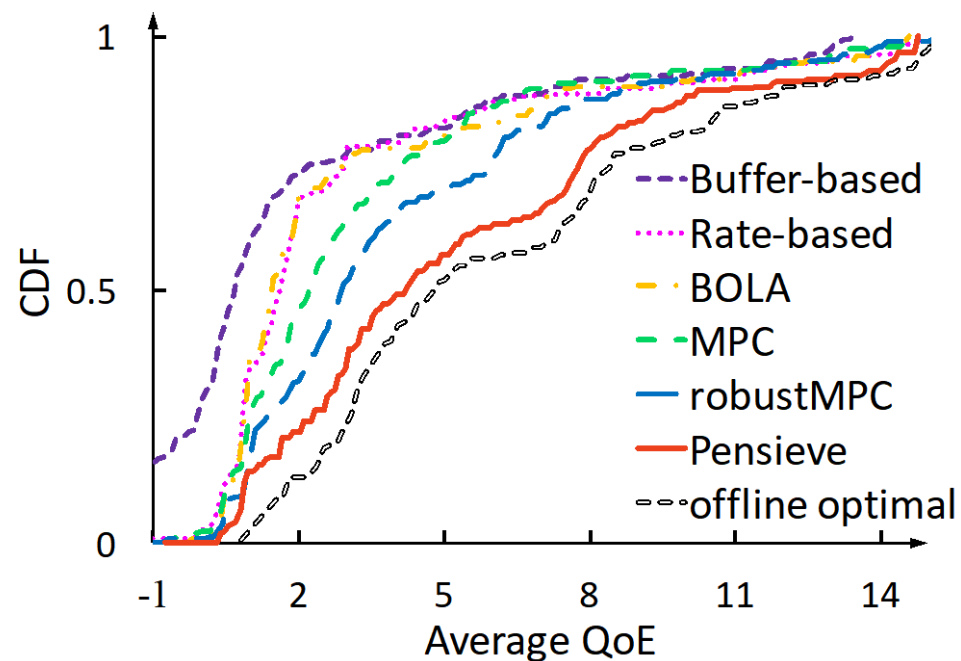
Pensieve评估结果

❖ 总体QoE:

- ▶ Pensieve相对于次优算法取得了12%-25%的QoE提升
- ▶ Pensieve与离线最优的性能差距在9%-14%以内



Norway 3G cellular dataset

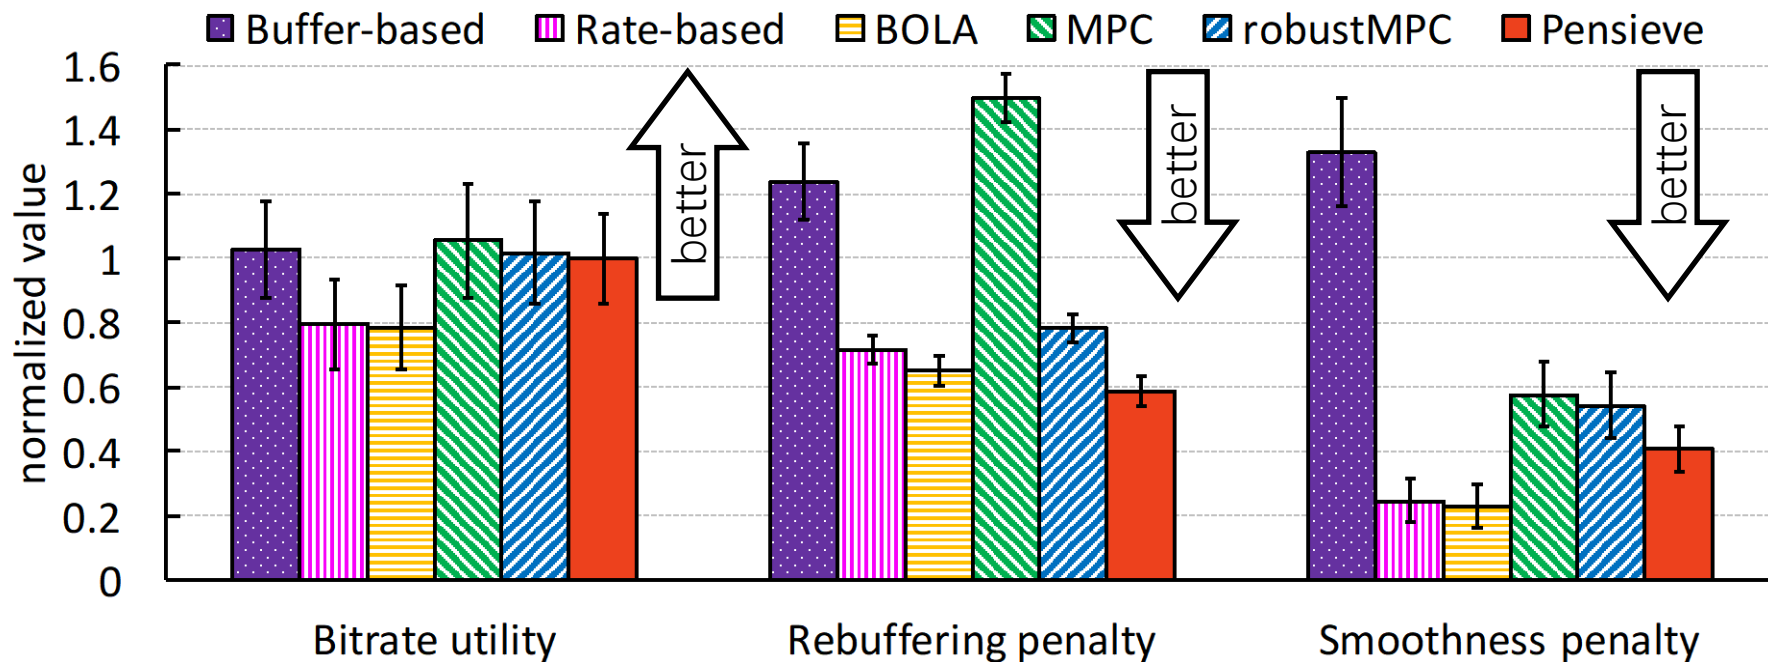


FCC broadband dataset

Pensieve评估结果

❖ QoE细分指标:

- ▶ Pensieve相对于次优算法降低了10%-32%的卡顿



总结

❖ 优势&研究亮点

- ▶ 基于机器学习类的ABR算法代表作
- ▶ 成功将强化学习方法应用于ABR算法中, [工作开源](#), 为后续研究奠定基础

❖ 不足&后续研究

- ▶ 机器学习的问题 (轻量化与可解释性等) → PiTree [MM'19] / Metis [SIGCOMM'20]
- ▶ 离线仿真环境与真实网络系统存在偏差 → CausalSim [NSDI'23]
- ▶ 其他: 真实环境部署 (ABRL [ICML'19 RL4RealLife Workshop])、模仿学习 (Comyco [MM'19])、在线学习 (OnRL [MobiCom'20])、长尾学习与泛化 (A2BR [JSAC'22]) 等