

基于网络流量水平等级预测的自适应随机早期检测算法

魏德宾^{1,2}, 潘成胜³, 杨力¹, 颜佐任²

(1. 南京理工大学自动化学院, 江苏 南京 210094;

2. 大连大学信息工程学院, 辽宁 大连 116622; 3. 南京信息工程大学电子与信息工程学院, 江苏 南京 210044)

摘要: 针对随机早期检测及其变体算法中平均队列长度和数据包最大丢弃概率的计算对网络流量的变化反应迟缓的问题, 提出了一种基于网络流量水平等级预测的自适应随机早期检测算法。基于自相似网络流量的统计特性, 建立了网络流量水平等级转移概率表, 设计了自相似网络流量水平等级预测方法, 该方法复杂度较低且精度较高。进一步, 将预测结果应用于等间隔平均队列长度计算及数据包最大丢弃概率调整中, 在固定和可变瓶颈链路容量 2 种情况下的仿真发现, 无论自相似程度如何, 所提算法在丢包率和吞吐量方面都有提升, 特别在 Hurst 参数较大且流量负载较低时, 吞吐量性能提升较大。

关键词: 主动队列管理; 网络流量; 自相似; 流量水平等级预测

中图分类号: TP393

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2023092

Adaptive random early detection algorithm based on network traffic level grade prediction

WEI Debin^{1,2}, PAN Chengsheng³, YANG Li¹, YAN Zuoren²

1. School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China

2. School of Information Engineering, Dalian University, Dalian 116622, China

3. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China

Abstract: In view of the problem that the calculation of average queue length and maximum packet drop probability in random early detection algorithm and its variants reflect the changes of network traffic slowly, an adaptive random early detection algorithm based on network traffic level grade prediction was proposed. Based on the statistical characteristics of self-similar network traffic, the transition probability table of network traffic level grade was established, and a grade prediction method of self-similar network traffic level with low complexity and high accuracy was proposed. Furthermore, the prediction results were applied to calculate the average queue length in equal interval and adjust the maximum packet drop probability. Under the condition of fixed and variable bottleneck link capacity, it is found that regardless of the degree of self-similarity of network traffic, the proposed algorithm can improve the throughput and packet loss rate, especially when the Hurst parameter is large and the traffic is light.

Keywords: active queue management, network traffic, self-similar, traffic level grade prediction

0 引言

网络流量的快速增长和异构网络间的速率差异使网络拥塞控制成为现代通信网络中的关键问

题之一^[1-2]。网络路由器通过带宽有限的链路传输数据包时, 如果传入数据包的数量超过链路容量, 该链路就会拥塞, 存储数据包的路由器缓冲区可能会溢出, 需要执行有效的队列管理和调度, 才能保障

收稿日期: 2023-01-18; 修回日期: 2023-04-05

通信作者: 潘成胜, pangs@sina.com

基金项目: 国家自然科学基金资助项目 (No.U21B2003, No.61931004)

Foundation Item: The National Natural Science Foundation of China (No.U21B2003, No.61931004)

数据流的高效传输。

队列管理是指通过一定的数据包丢弃策略达到控制队列长度和数据包排队时延的目的。根据数据包丢弃策略的不同,队列管理机制主要分为被动队列管理(PQM, passive queue management)和主动队列管理(AQM, active queue management)两大类。PQM中的“去尾”策略在因特网上得到了广泛的应用,但是存在满队列、全局同步和死锁3个严重缺陷。AQM是一种预防性丢包机制,根据队列长度等指标在队列未滿时以一定概率提前丢包,以此来通知特定用户减小发送窗口,从而避免拥塞和连接的全局同步^[3]。

近年来,在传统AQM算法的基础上涌现了许多新算法,针对拥塞检测方式的不同可以分为以下几种:基于队列长度的方法,如非线性随机早期检测(RED, random early detection)^[4]、谨慎自适应RED(CARED, cautious adaptive RED)^[5]、加权队列动态AQM(WQDAQM, weight queue dynamic AQM)^[6]等;基于速率的方法,如自适应虚拟队列(AVQ, adaptive virtual queue)^[7]等;基于时延的方法,如具有目标和间隔调整的自适应控制时延(ACoDel-TIT, adaptive control delay with target and interval tuning)^[8]、长短期记忆AQM(LSTM-AQM, long short-term memory-AQM)^[9]、基于深度Q网络(DQN, deep Q-network)的AQM^[10]等;基于队列长度与速率相结合的方法,如平均队列长度和速率RED(AC-RED, average queue length and change rate RED)^[11]和整合RED(IREN, integrated RED)^[12]等;基于队列长度和时延相结合的方法,如模糊逻辑RED(FLRED, fuzzy logic RED)^[13]等。

上述方法虽各有优势,但均缺乏对网络流量特性的考虑。尤其是自1994年Leland等^[14]明确提出网络流量的自相似性以来,对WAN、NSFNET、WLAN和WWW等网络流量的测试分析发现其均具有自相似性。目前,在网络性能建模和分析中,网络流量的自相似性被广泛采用。Park等^[15]在仿真中通过改变瓶颈带宽、缓冲区容量等网络资源,对自相似网络流量的网络性能进行评估,指出在固定缓冲区条件下,随着文件大小分布函数重尾分布程度的增大,吞吐量、丢包率、排队时延等网络性能都会下降;增加网络资源可以改善网络性能,但会很快达到饱和。Norros^[16]基于分形布朗运动,利用大偏差理论推导了缓冲区占用的余累积分布函数,

结论表明对于自相似性强的业务流,队列长度将快速增长,增大缓冲区容量并不能有效地改善溢出。

网络流量的自相似性增加了流量控制和资源管理的难度,同时也开辟了一个新的研究方向——利用自相似网络流量的可预测性进行拥塞控制。现有文献中针对网络流量自相似性的AQM算法改进主要分为以下3个方面。1) 基于网络流量Hurst参数的数据包丢弃概率调整。例如,文献[17]根据网络流量的Hurst参数和平均队列长度调整数据包最大丢弃概率,以降低自相似性的影响。文献[18]利用自相似网络流量的自相关函数来设置平均队列长度计算公式中的滤波权值,进一步基于分形布朗运动模型的分析结果计算数据包丢弃概率。文献[19]基于分形布朗运动模型和队列长度的分布函数推导自相似网络流量环境下RED算法的数据包丢弃概率。文献[20]设计了基于Hurst参数与业务优先级的2级数据包丢弃策略,稳定了队列长度,降低了排队时延和时延抖动。文献[21]根据流量强度及其自相似性自动调整AQM参数,降低平均队列占用率、丢包率以及传输时延。文献[22]研究了网络流量自相似性对非整数阶比例积分控制器参数的影响,以及控制器参数对队列长度、丢包率的影响,发现控制器参数对Hurst参数有很强的依赖性。2) 利用网络流量的自相似性进行网络流量或缓冲区队列长度预测,并进行数据包丢弃概率的调整。例如,文献[23]将Hurst参数引入自相似网络流量估计中,提出幂律移动平均算法,以此来调节分组标记概率。文献[24]提出利用存在于自相似网络流量中的相关结构,基于线性最小均方误差(LMMSE, linear minimum mean square error)方法预测流量,并将队列长度稳定在理想的水平上。文献[25]利用Pareto分布的形状参数 α 确定网络流量的自相似程度,并根据 α 值将不同的流分配到不同的队列。文献[26]根据自相似网络流量特点,利用小波的多分辨率分析对到达流量的短期和长期波动进行预测,重新调整AQM算法的数据包丢弃概率。文献[27]针对网络流量的自相似性,建立差分进化三重指数平滑预测DE-Holt-Winters(differential evolution Holt-Winters)模型进行流量预测,进而将流量预测结果与改进最大丢弃概率的自适应RED(ARED, adaptive RED)结合,提出了一种主动队列管理算法。3) 在算法的性能仿真过程中,分析自相似网络流量对算法性能的影响^[28-29]。

进一步分析发现,上述基于网络流量自相似性的 AQM 算法仍存在以下三点问题。首先,上述 AQM 算法大多基于 RED 思想,而 RED 的平均队列长度是在数据包到达队列时计算的,当相邻的 2 个数据包到达时间间隔不同时,计算平均队列长度的时间间隔也不同,而不同间隔内被处理的数据包数将有较大差异,这将影响 RED 平均队列长度对网络节点拥塞程度的反映。文献[30]还指出网络流量自相似性产生的一个重要原因是数据源发送文件的持续时间 ON 和间隔时间 OFF 服从重尾分布。这里的重尾分布意味着 ON 和 OFF 可能都很长,虽然这种情况概率较小,但难以忽略,这也导致了传统 RED 算法平均队列长度的计算与时间有关。而且如果每到达一个数据包计算一次平均队列长度,将给系统带来额外负担。

其次,在有线-无线异构网络或无线网络中,通信方式的改变、链路切换、波束切换等将导致可变的链路容量,如果队列管理算法能对链路容量及时感应,并对平均队列长度和数据包丢弃概率的计算做出调整,将提升网络传输性能。

最后,现有基于自相似性的 AQM 算法在数据包丢弃概率的计算方面大多直接引入 Hurst 参数,但影响队列长度更多的是输入速率(或流量水平)的变化,将 Hurst 参数作为反映自相似网络流量程度的唯一参数应用于队列管理显得过于简单和直接。

为此,本文基于自相似网络流量的统计特性,建立了网络流量水平等级转移概率表,提出了自相似网络流量水平等级预测(TLGP, traffic level grade prediction)方法。进一步,将预测结果应用于等间隔平均队列长度计算以及数据包最大丢弃概率调整中,提出了基于网络流量水平等级预测的自适应随机早期检测(TLGP-ARED)算法,以提高网络吞吐性能。最后,将瓶颈链路的可变容量信息与缓存的负载信息、链路输入速率等相结合作为队列管理算法考虑的因素,提高队列管理算法对瓶颈链路拥塞状态的反应速度和拥塞控制效率。

1 自相似与网络流量水平等级预测

1.1 二阶自相似与重尾分布

自相似的网络流量可称为长相关的,它是指网络流量在不同观测时间尺度上表现出相同的突发模式,即无论增大还是减小时间尺度,聚集业务的突发性会得到保持。这一特性不仅存在于 WAN、NSFNET、

WLAN 和 WWW 等网络中,也存在于 Ad Hoc 和卫星网络中^[31]。实际的检验中将网络流量看作离散随机序列,并用如下的数学定义描述自相似性。

设 $X = \{X_i : i = 1, 2, \dots\}$ 是具有均值 μ 、有限方差 σ^2 和自相关函数 $R(k), k \geq 1$ 的平稳离散随机序列,其中, X_i 表示第 i 个时间间隔内到达节点的数据包数、字节数或比特数。对 $i, m = 1, 2, \dots$ 设 $X_i^{(m)} = \frac{X_{im-m+1} + \dots + X_{im}}{m}$, 称 $X^{(m)} = \{X_i^{(m)}, i = 1, 2, \dots\}$ 为随机序列 X 的长度为 m 的聚集过程,记其自相关函数为 $R^{(m)}(k)$ 。如果 $X^{(m)}$ 与 X 有相同的自相关函数 $R(k) = ((k+1)^{2H} - 2k^{2H} + (k-1)^{2H}) \frac{\sigma^2}{2}$, 即对任意 $m, k \geq 1$, 有 $R^{(m)}(k) = R(k)$, 则称 X 是严格二阶自相似的。如果对于很大的 m 和 k , 有 $\lim_{m \rightarrow \infty} R^{(m)}(k) = R(k)$, 则称 X 是渐近二阶自相似的。

其中, $\frac{1}{2} < H < 1$, H 被称为 Hurst 参数,是衡量网络流量是否具有自相似性的重要参数。

为了探究网络流量自相似性的成因,以及在仿真中生成具有自相似网络流量特征的业务源,文献[30]指出当足够多的业务源发送文件的持续时间 ON 和间隔时间 OFF 服从重尾分布时,叠加后产生的流量具有自相似性。典型的重尾分布——Pareto 分布的累积分布函数为

$$F(x) = \begin{cases} 1 - \left(\frac{\theta}{x}\right)^\alpha, & x \geq \theta \\ 0, & x < \theta \end{cases} \quad (1)$$

其中, α 为形状参数, θ 为位置参数。则 ON/OFF 源产生的聚合流量的 Hurst 参数为 $H = \frac{3-\alpha}{2}$ [30]。

1.2 流量水平等级预测

基于平稳离散随机序列 $X = \{X_i : i = 1, 2, \dots\}$ 和其长度为 m 的聚集过程 $X^{(m)} = \{X_i^{(m)}, i = 1, 2, \dots\}$, 本节估计条件概率 $\Pr\{X_{i+1}^{(m)} | X_i^{(m)}\}$ 。设 V_1 和 V_2 分别为时间片 $(t-T, t]$ 和 $(t, t+T]$ 的总流量, 即

$$V_1 = \sum_{i \in (t-T, t]} X_i, \quad V_2 = \sum_{i \in (t, t+T]} X_i$$

其中, T 为采样间隔。利用 $V_k (k=1, 2)$ 的均值 μ_k 、标准差 σ_k 和“ 3σ ”准则,细化文献[32]的流量水平等级划分标准,将网络流量水平划分为 8 个等级,由低到高分别为^[33]

$(-\infty, \mu_k - 3\sigma_k), [\mu_k - 3\sigma_k, \mu_k - 2\sigma_k), [\mu_k - 2\sigma_k, \mu_k - \sigma_k),$
 $[\mu_k - \sigma_k, \mu_k), [\mu_k, \mu_k + \sigma_k), [\mu_k + \sigma_k, \mu_k + 2\sigma_k),$
 $[\mu_k + 2\sigma_k, \mu_k + 3\sigma_k), [\mu_k + 3\sigma_k, +\infty)$

记 L_1, L_2 分别为 $(t-T, t]$ 和 $(t, t+T]$ 上聚合流量水平等级的随机变量。其中, $L_k=1$ 表示聚合流量水平等级最低, $L_k=8$ 表示聚合流量水平等级最高。

为了从聚合流量序列 X 中估算 $\Pr\{L_2 | L_1\}$, 将 X 分为 N 个时间长度为 T 的连续且非重叠聚合流量块, 将 2 个相邻的聚合流量块 V_1, V_2 配对为一个组, 并确定其对应的流量水平等级 ℓ_1, ℓ_2 。令 n_{ℓ_1} 表示满足 $L_1 = \ell_1$ 的块总数, n_{ℓ_2} 表示在 $L_1 = \ell_1$ 条件下, 满足 $L_2 = \ell_2$ 的块总数, 则流量水平等级转移概率为

$$\Pr\{L_2 = \ell_2 | L_1 = \ell_1\} = \frac{n_{\ell_2}}{n_{\ell_1}} \quad (2)$$

根据当前流量水平 $L_1 = \ell_1$ 预测下一时间段队列的平均流量水平等级为

$$\bar{\ell} = \sum_{\ell_2=1}^8 \ell_2 \Pr\{L_2 = \ell_2 | L_1 = \ell_1\} \quad (3)$$

接下来, 采用多个独立的 Pareto 分布的 ON/OFF 源叠加模型生成自相似流量。其中, 数据包为固定包长 500 B, ON 的平均时间为 320 ms, OFF 的平均时间为 1 200 ms。由于篇幅有限, 本文只选择 α 为 1.2 和 1.8 这 2 种情况, 得到 2 组数据。


由 $H = \frac{3-\alpha}{2}$ 得到这 2 组数据的 Hurst 参数理论值分别为 0.9 和 0.6。仿真时间为 10 000 s, 取 $T = 0.5$ s, 根据式(2)和式(3)列出 $\alpha = 1.2$ 和 $\alpha = 1.8$ 的流量水平等级转移概率, 分别如表 1 和表 2 所示, 图形化表示如图 1 所示。

表 1 $\alpha=1.2$ 时流量水平等级转移概率


L_1	L_2								$\bar{\ell}$
	1	2	3	4	5	6	7	8	
1	0.24	0.65	0.12	0	0	0	0	0	1.88
2	0.03	0.34	0.53	0.09	0	0	0	0	2.69
3	0	0.07	0.48	0.40	0.05	0	0	0	3.43
4	0	0	0.16	0.55	0.27	0.02	0	0	4.14
5	0	0	0.02	0.28	0.54	0.15	0	0	4.85
6	0	0	0	0.05	0.39	0.46	0.10	0	5.61
7	0	0	0	0	0.09	0.51	0.36	0.04	6.35
8	0	0	0	0	0	0.13	0.55	0.33	7.20

表 2 $\alpha=1.8$ 时流量水平等级转移概率

L_1	L_2								$\bar{\ell}$
	1	2	3	4	5	6	7	8	
1	0	0	0.25	0.44	0.25	0.06	0	0	4.13
2	0	0.04	0.22	0.42	0.26	0.07	0	0	4.12
3	0	0.03	0.18	0.40	0.30	0.09	0.01	0	4.27
4	0	0.02	0.16	0.37	0.33	0.11	0.02	0	4.39
5	0	0.01	0.13	0.33	0.35	0.15	0.03	0	4.58
6	0	0.01	0.09	0.30	0.37	0.19	0.04	0.01	4.78
7	0	0.01	0.07	0.19	0.43	0.24	0.05	0.02	5.05
8	0	0	0.06	0.14	0.33	0.41	0.06	0	5.27



(a) $\alpha=1.2$ 的业务源流量水平等级转移概率



(b) $\alpha=1.8$ 的业务源流量水平等级转移概率

图 1 基于 Pareto 分布的 ON/OFF 源的流量水平等级转移概率

从表 1 和表 2 可以看出, 当 $\alpha = 1.2$, 即 Hurst 参数为 0.9 时, 未来网络流量水平等级与当前等级比较接近, 即如果当前的流量水平 L_1 较低, 那么 L_2 也可能较低; 如果当前的流量水平 L_1 较高, 那么 L_2

也可能较高。这为根据网络流量的自相似性进行流量预测提供了可能。但当 $\alpha=1.8$ ，即 Hurst 参数为 0.6 时，未来网络流量水平等级与当前等级的相关性不高，即无论当前的流量水平 L_1 是低还是高，未来流量水平 L_2 的等级处于 4~5 级的概率更高一些，这一点可以从图 1 更清晰地看出。

如上所述，根据当前时间间隔内节点收到的数据包数得到网络流量水平等级，再由当前网络流量水平等级预测下一个时间间隔的流量水平等级。为了从预测的流量水平等级得到下一时间间隔的流量，本文考察 $\alpha=1.2$ 时的网络流量发现，流量水平等级处于 3~5 级时，当前时间间隔的流量与下一时间间隔的流量相差不大。但当等级在 1~2 级和 6~8 级时，由于重尾分布的高变异性特征，当前流量与下一时间间隔的流量差异要比 3~5 级更大，但是仍以较大的概率分别停留在低流量水平等级和高流量水平等级。在 $\alpha=1.8$ 的情况下，未来网络流量水平等级与当前等级的相关性不高，这会影响到流量预测的准确性，但类似上述低、中、高等级的流量预测差异性仍然保持。所以，本文在高流量水平等级（6~8 级）时设计增加量，在低流量水平等级（1~2 级）时设计减少量，增加量和减少量通过参数 γ 和 η 来调节。本文将这种流量预测方法称为网络流量水平等级预测方法，具体描述如下。

设 $\tau_0=(0, t_0], \tau_1=(t_0, t_1], \tau_2=(t_1, t_2] \dots$ 是一列长度为 δ 的时间间隔， $A(\tau_n)$ 为时间间隔 τ_n 内链路汇聚后的网络流量，预测下一时间间隔内网络流量为

$$\hat{A}(\tau_{n+1}) = \begin{cases} \frac{\bar{\ell}_{n+1}}{\ell_n} A(\tau_n) - \gamma\sigma, \ell_n \leq 2 \\ \frac{\bar{\ell}_{n+1}}{\ell_n} A(\tau_n), 2 < \ell_n < 6 \\ \frac{\bar{\ell}_{n+1}}{\ell_n} A(\tau_n) + \eta\sigma, \ell_n \geq 6 \end{cases} \quad (4)$$

其中， σ 为网络流量时间序列的标准差。为了得到最优的 $\gamma, \eta \in [0, 1]$ 值，对 N 个训练数据进行等级计算和流量预测，并计算平均绝对误差率为

$$M = \frac{1}{N-1} \sum_{i=0}^{N-1} \left| \frac{\hat{A}(\tau_{i+1}) - A(\tau_{i+1})}{A(\tau_{i+1})} \right| \quad (5)$$

参数 $\alpha=1.2$ 的 30 个 ON/OFF 源生成自相似流，利用式(4)和式(5)进行流量预测，计算平均绝对误差率。基于平均绝对误差率的 γ 与 η 值如图 2 所示。从图 2 可以看出，当 $\gamma=0.6, \eta=0.7$ 时，平均绝对误差

率是最小的。进一步分析可以发现， γ 和 η 的取值与 α 的取值相关，随着 α 的增大， γ 和 η 的绝对值会变小。




图 2 基于平均绝对误差率的 γ 与 η 值

本文以平均绝对误差率作为指标将本文的 TLGP 与 FARIMA (fractional autoregressive integration moving average)^[24]、LMMSE^[24]、DE-Holt-Winters^[27] 进行对比。以生成表 1 的数据中的前 1000 个作为训练样本，之后的 300 个数据作为预测比较，结果如图 3 所示。

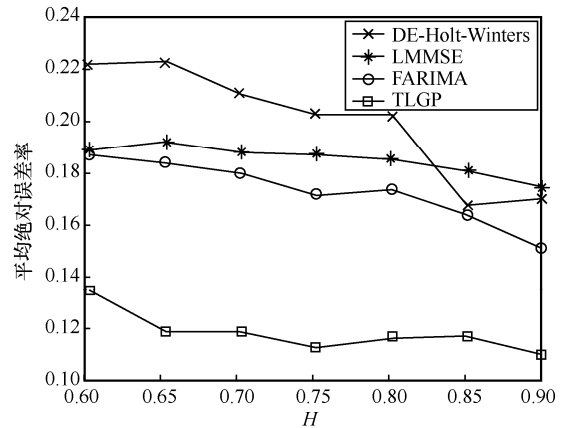




图 3 各流量预测算法在不同 H 下的平均绝对误差率

图 3 还描述了 DE-Holt-Winters、LMMSE、FARIMA 和本文 TLGP 的平均绝对误差率与 Hurst 参数 H 的关系。当 H 趋近于 1 时，几种模型的平均绝对误差率总体上都有减小的趋势，说明长相关的特征越显著，预测算法的性能越好，本文的 TLGP 的预测效果最好。但从算法复杂度来看，LMSSE 和 DE-Holt-Winters 的算法复杂度更低，因为它们不需要计算 Hurst 参数值。


将式(4)的流量预测结果与 FARIMA 和 DE-Holt-Winters 的预测结果比较，时间间隔为 0.5 s，如图 4 所示。



(a) FARIMA 预测结果



(b) DE-Holt-Winters 预测结果



(c) TLGP 预测结果

图 4 3 种预测算法流量预测结果对比

为了进一步考察流量水平等级预测方法对实际网络流量的预测效果，本文采用贝尔实验室提供的流量数据集 pAug89.TL，并在固定时间间隔 500 ms 内统计到达的数据包数，在包级上用上述预测算法对网络流量进行预测。仿真结果表明，FARIMA、DE-Holt-Winters 和本文 TLGP 平均绝对误差率分别为 0.85、0.67 和 0.28，这说明在真实网络流量情况中，本文算法仍然是几个预测算法里效果最好的。图 5 为 TLGP 对真实网络流量的预测结果。




图 5 TLGP 对真实网络流量的预测结果

2 基于流量水平等级预测的随机早期检测

针对传统 RED 算法平均队列长度计算与数据包时间间隔相关，以及现有算法将 Hurst 参数作为反映自相似网络流量程度的唯一参数并应用于队列管理显得过于简单和直接的问题，本文提出了基于流量水平等级预测的主动队列管理算法，包括基于流量水平等级预测的平均队列长度计算和最大丢弃概率自适应调整等。

2.1 平均队列长度计算

RED 算法的主要思想是基于平均队列长度为到达的数据包计算一个被拒绝的概率，从而控制业务源发送数据包的速率，降低链路拥塞风险。传统 RED 算法平均队列长度计算式为 $avg(t_n) = (1 - w_q)avg(t_{n-1}) + w_q q(t_n)$ ，其中， $avg(t_{n-1})$ 为上一次计算的平均队列长度， $q(t_n)$ 为当前时刻瞬时队列长度， $w_q \in [0, 1]$ 为滤波权重因子。

RED 中丢弃概率的计算与阈值 min_{th} 和 max_{th} 有关，当平均队列长度 $avg(t_n)$ 小于最小阈值 min_{th} 时，不丢包；当 $avg(t_n)$ 大于最大阈值 max_{th} 时，所有到达的包都被丢弃；当 $min_{th} \leq avg(t_n) \leq max_{th}$ 时，通过 $max_p \frac{avg(t_n) - min_{th}}{max_{th} - min_{th}}$ 来计算数据包丢弃概率。其中， max_p 为数据包最大丢弃概率。

RED 算法中平均队列长度是在传入数据包到达时计算的，也就是说平均队列长度的计算时间是变化的，取决于数据包到达的时间间隔。而时间间隔的不同，导致此段时间内被服务的数据包数目不同，数据包到达时间间隔较小时平均队列长度快速更新，数据包到达时间间隔较大时平均队列长度缓慢更新。而在每个包到达时进行采样过于频繁，并没有提供任何明显的好处^[19]，过于缓慢的更新不能

很好反映网络拥塞程度的变化。因此，本文采用固定时间间隔的平均队列长度更新方法。此外，在以固定时间间隔计算平均队列长度的同时，根据上一时间间隔的流量水平，预测下一时间间隔的流量水平，并在队列长度的计算中将流量水平的变化因素考虑在内。

如 1.2 节所述， $A(\tau_n)$ 为时间间隔 τ_n 内到达的网络流量， $\hat{A}(\tau_{n+1})$ 为流量水平等级预测得到的下一时间间隔到达流量。设 t_n 时刻瞬时队列长度为 $q(t_n)$ ，则时间间隔 τ_{n+1} 内队列长度的预测值为 $\hat{q}(\tau_{n+1}) = (q(t_n) + \hat{A}(\tau_{n+1}) - C(\tau_{n+1})\delta)^+$ 。其中， $C(\tau_{n+1})$ 为时间间隔 τ_{n+1} 内的链路容量， $(x)^+ = \max\{0, x\}$ 。将瓶颈链路的容量信息、缓存负载信息、链路输入速率相结合作为缓存队列管理算法考虑的因素，得到时间间隔 τ_{n+1} 内基于预测的平均队列长度为

$$\text{avg}(t_n) = (1 - w_q)\text{avg}(t_{n-1}) + w_q q(t_n) \quad (6)$$

$$\text{avg}(\tau_{n+1}) = (1 - w_q)\text{avg}(t_n) + w_q \hat{q}(\tau_{n+1}) \quad (7)$$

其中， $\text{avg}(t_n)$ 为当前时间间隔的平均队列长度， $\text{avg}(\tau_{n+1})$ 为未来一个时间间隔内基于预测的平均队列长度，式(6)和式(7)可以反映不同数据包到达密度下，特别是当到达队列的数据包的时间间隔服从重尾分布时的缓存占用情况。根据时间间隔内平均队列长度，数据包丢弃概率为

$$P_b = \begin{cases} 0, & \text{avg}(\tau_{n+1}) \leq \min_{th} \\ \max_p \frac{\text{avg}(\tau_{n+1}) - \min_{th}}{\max_{th} - \min_{th}}, & \min_{th} < \text{avg}(\tau_{n+1}) < \max_{th} \\ 1, & \text{avg}(\tau_{n+1}) \geq \max_{th} \end{cases} \quad (8)$$

其中， \min_{th} 的值取决于数据包到达过程的突发性、链路容量、传播时延和缓冲区容量等。此外，最优的 \min_{th} 和 \max_{th} 设置可平衡高队列时延和低链路利用率。这里 \max_{th} 和 \min_{th} 之差应该大于一个往返时间内平均队列大小的平均增加量，或与带宽时延积成正比。本文将 \min_{th} 设置为带宽时延积的 0.3 倍， $\max_{th} - \min_{th}$ 约等于带宽时延积。

因为本文采用固定时间间隔 δ 进行瞬时队列长度采样，式(6)和式(7)中参数 w_q 需根据文献[34]设置如下

$$w_q = 1 - \varepsilon^{\frac{\delta}{I}} \quad (9)$$

其中， I 为由丢包导致的传输控制协议 (TCP) 连接

平均窗口增减周期的长度。采样间隔 δ 不超过一个往返时间 RTT。上述 w_q 的计算方法在保持平均队列长度接近长期平均值和平均队列长度能够快速响应流量变化这 2 种对立条件之间，取得了一个很好的折中。

2.2 最大丢弃概率自适应调整

RED 的主要目标是提供低平均队列时延和高吞吐量，而其平均队列长度对拥塞程度和 RED 参数设置非常敏感，为了消除影响 RED 性能的参数敏感性，在各种流量场景中实现指定的目标平均队列长度，ARED 根据队列长度的增加和减小，采用加性增加和乘性减小的方式，动态调整最大丢弃概率 \max_p ，控制平均队列长度。ARED 虽然可以在一定程度上降低 RED 参数设置的敏感性，但当拥塞程度突然发生变化时，其固定且保守的 \max_p 调整方法会因为丢弃足够的数据包，而使平均队列长度在短时间内超出目标范围，导致吞吐量下降。为此，本文提出的 TLGP-ARED 算法将根据自相似网络流量水平等级预测结果，保守或激进地对 \max_p 进行动态调整，以提高网络的整体吞吐性能。

如 1.2 节所述，网络流量水平被分为 8 个等级。设 avg 为当前平均队列长度， a 为最大丢弃概率增加因子， b 为最大丢弃概率减小因子，时间间隔为 0.5 s。设

$$\text{target}_{low} = \min_{th} + 0.4(\max_{th} - \min_{th})$$

$$\text{target}_{up} = \min_{th} + 0.6(\max_{th} - \min_{th})$$

如果 avg 低于 target_{low} ，且 $\bar{l} < 3$ ，则认为拥塞程度和未来流量水平等级都较低，可根据流量水平等级以较大幅度降低 \max_p ，在这种情况下，根据 ARED 保守地降低 \max_p 将导致缓存利用率不足。

如果 avg 低于 target_{low} ，且 $\bar{l} \geq 3$ ，则认为未来的流量处于较高水平，则根据 ARED 保守地降低 \max_p 。若大幅度降低 \max_p 将导致发送速率进一步增加，可能使 avg 高于 target_{up} 。

如果 avg 高于 target_{up} ，且 $\bar{l} > 6$ ，则认为拥塞程度和未来流量水平等级都较高，可根据流量水平等级以较大幅度增加 \max_p ，以避免 avg 超过 \max_{th} 。

如果 avg 高于 target_{up} ，并且 $\bar{l} \leq 6$ ，则根据 ARED 保守地增加 \max_p 。在这种情况下，若大幅增加 \max_p ，将无谓地丢弃更多的数据包。

关于算法中最大丢弃概率调整因子 a 和 b 的边界，文献[5]指出，应有 $a < 0.25$ 且 $b > 0.83$ 。本文在

遵循这一原则的基础上, 在拥塞程度较低且未来流量水平等级较低时, 取较小的 b , 并且未来流量水平等级越低, b 值越小。在拥塞程度较大且未来流量水平等级较高时, 取较大的 a , 并且未来流量水平等级越高, a 值越大。具体来说, 在拥塞程度较低, 且 \bar{c} 从 1 增加到 3 时, 让 b 从 0.83 逐渐增加到 0.9; 当 $\bar{c} \geq 3$ 时, b 取值为 0.9。在拥塞程度较高, 且 \bar{c} 从 6 增加到 8 时, 让 a 逐渐增加到 $0.25 \max_p$; 当 $\bar{c} \leq 6$ 时, a 取值为 $\min\{0.01, 0.25 \max_p\}$ 。最大丢弃概率调整算法如算法 1 所示。

算法 1 最大丢弃概率调整算法

```

every interval seconds:
if avg < targetlow and maxp > 0.01 then
  if  $\bar{c} < 3$  then
    decrease maxp as following
     $b = 0.83 + (0.07 \times 0.33(\bar{c} - 1))$ 
    maxp = maxp b
  else
    decrease maxp as ARED
     $b = 0.9$ 
    maxp = maxp b
  end if
else if avg > targetup and maxp < 0.5 then
  if  $\bar{c} > 6$  then
     $a = 0.25 \max_p 0.125 \bar{c}$ 
    maxp = maxp + a
  else
    increase maxp as ARED
     $a = \min\{0.01, 0.25 \max_p\}$ 
    maxp = maxp + a
  end if
end if

```

3 仿真

本文仿真场景分为固定链路容量和可变链路容量 2 种情况。TLGP-ARED-1 表示在传统 ARED 基础上使用最大丢弃概率调整算法; TLGP-ARED-2 表示在 TLGP-ARED-1 基础上同时使用根据式(6)和式(9)的等间隔瞬时队列长度采样; TLGP-ARED 表示在 TLGP-ARED-2 的基础上根据式(7)和式(9), 使用基于预测的平均队列长度计算方法。

在固定链路容量情况下, 比较了本文算法 TLGP-ARED-1 与 CARED^[5]、文献[21]和文献[27]提出的算法在不同 Hurst 参数不同流量负载情况下的队列长度、时延、丢包率和吞吐量等。在可变链路容量情况下, 比较了 TLGP-ARED-1、TLGP-ARED-2 和 TLGP-ARED 的队列长度、时延、丢包率和吞吐量等。

3.1 仿真网络拓扑

采用如图 6 所示的网络拓扑结构进行 NS2 仿真, 按照 1.2 节所述方式设置了 m 个具有自相似特征的 TCP 流, 并可根据 α 的取值调整自相似程度。 $S_1 \sim S_n$ 为源节点, $D_1 \sim D_n$ 为目的节点, R_1 和 R_2 为路由器。TCP 数据发送方为 New-Reno 类型。




图 6 仿真网络拓扑结构

源节点和目的节点到路由器的链路容量均为 10 Mbit/s, 传播时延分别为 2 ms 和 4 ms。2 个路由器 R_1 和 R_2 通过瓶颈链路连接, 固定链路容量时设为 1.5 Mbit/s, 传输时延为 20 ms。在瓶颈链路上执行上述 AQM 算法, 其中, $\min_{th} = 5$ 个包, $\max_{th} = 15$ 个包, 缓冲区容量为 35 个包, 最大丢包率 $\max_p = 0.1$, $w_q = 0.0027$ 。在等间隔瞬时队列采样时使用式(9)计算 w_q 值, 此时设 $\varepsilon = 0.01$, $\delta = 0.11s$ 为平均 RTT, $I = 10.74s$ 。

3.2 瞬时队列与平均队列长度

在瓶颈链路为固定容量的情况下, 设置 30 个业务源, $\alpha = 1.2$, 即 $H = 0.9$, CARED、文献[21]算法、文献[27]算法和 TLGP-ARED-1 的瞬时队列和平均队列的动态变化情况如图 7 所示。

从图 7 可以看出, CARED、文献[21]算法的平均队列长度波动最大, 文献[27]和本文算法 TLGP-ARED-1 的平均队列长度波动较小, 且 TLGP-ARED-1 具有更平稳的平均队列长度。

进一步, 利用 NS2 软件和本文中的仿真拓扑将流量数据集 pAug89.TL 按照数据包发送间隔及其大小输入瓶颈链路, 共计发送数据包数 968 631 个, 在瓶颈链路上考察各种队列管理算法下数据包丢失情况。




图 7 各算法的瞬时队列与平均队列长度

真实网络流量下的丢包量和丢包率如表 3 所示。从表 3 可以看出，本文算法具有较低的包丢弃概率。

表 3 真实网络流量下的丢包量和丢包率

算法	丢包量/个	丢包率
CARED	33 562	3.40%
文献[21]算法	32 931	3.47%
文献[27]算法	32 895	3.40%
本文算法	32 623	3.37%

3.3 $H=0.9$ 时各算法队列时延、丢包率、吞吐量

本节采用 3.1 节的拓扑和业务源设置，考察本文算法在时延、丢包率和吞吐量方面的性能增益。表 4~表 6 分别展示了在不同网络负载情况下，本文算法 TLGP-ARED-1 与 CARED、文献[21]算法、文献[27]算法的性能对比，Imp1、Imp2 和 Imp3 分别表示 TLGP-ARED-1 算法相对于 CARED、文献[21]算法、文献[27]算法的性能提升度。

表 4

$H=0.9$ 时各算法时延比较

连接数目/条	CARED/ms	文献[21]算法/ms	文献[27]算法/ms	TLGP-ARED-1/ms	Imp1	Imp2	Imp3
10	45.6	45.5	45.5	45.4	0.44%	0.22%	0.22%
20	63.0	64.7	63.2	63.4	-0.63%	2.01%	-0.32%
30	62.4	65.4	62.8	64.2	-2.88%	1.83%	-2.23%
60	62.9	65.8	64.6	64.5	-2.54%	1.98%	0.15%
80	64.2	66.9	65.1	64.8	-0.94%	3.13%	0.46%
90	64.6	68.2	65.6	65.2	-0.93%	4.40%	0.61%

从表 4~表 6 可以看出，在吞吐量方面，本文 TLGP-ARED-1 算法优于 CARED、文献[21]算法和文献[27]的算法。在中高负载时，其平均吞吐量提高 2%左右，这在网络拥塞的情况下并不容易做到。在低负载时，TLGP-ARED-1 与 CARED、文献[21]算法和文献[27]的算法相比，吞吐量分别提高了 3.28%、0.36%和 13.39%，在丢包率方面总体稍有减少，时延方面有所增加。这是因为本文算法采用了自相似网络流量水平等级预测，并将其应用到数据包丢弃概率的调整中，在缓存队列长度较小且未来流量水平较低时增大数据包丢弃概率降低幅度，在缓存队列长度较大且未来流量水平较高时增大数据包丢弃概率提升幅度，从而提高网络吞吐性能、降低丢包率，但因队列长度增加，时延性能总体改善并不明显。

3.4 $H=0.6$ 时各算法队列时延、丢包率、吞吐量

本节仿真采用 $H = 0.6$ 的业务源，从表 7~表 9

表5 $H=0.9$ 时各算法丢包率比较

连接数目/条	CARED	文献[21]算法	文献[27]算法	TLGP-ARED-1	Imp1	Imp2	Imp3
10	0.189%	0.358%	0.678%	0.238%	-0.049%	0.120%	0.440%
20	0.789%	0.980%	0.834%	0.801%	-0.012%	0.179%	0.033%
30	0.874%	0.947%	0.800%	0.804%	0.070%	0.143%	-0.004%
60	0.824%	0.948%	0.814%	0.801%	0.023%	0.147%	0.013%
80	0.837%	0.948%	0.817%	0.803%	0.034%	0.145%	0.014%
90	0.859%	0.950%	0.817%	0.769%	0.090%	0.181%	0.048%

表6 $H=0.9$ 时各算法吞吐量比较

连接数目/条	CARED/(kbit·s ⁻¹)	文献[21]算法/(kbit·s ⁻¹)	文献[27]算法/(kbit·s ⁻¹)	TLGP-ARED-1/(kbit·s ⁻¹)	Imp1	Imp2	Imp3
10	1 291.44	1 329.03	1 176.30	1 333.76	3.28%	0.36%	13.39%
20	1 326.75	1 293.24	1 277.88	1 359.80	2.49%	5.15%	6.41%
30	1 347.01	1 301.95	1 364.41	1 342.28	-0.35%	3.10%	-1.62%
60	1 316.24	1 311.70	1 301.08	1 346.16	2.27%	2.63%	3.46%
80	1 321.56	1 324.33	1 316.70	1 329.85	0.63%	0.42%	1.00%
90	1 309.05	1 332.81	1 308.08	1 310.38	0.10%	-1.68%	0.18%

表7 $H=0.6$ 时各算法时延比较

连接数目/条	CARED/ms	文献[21]算法/ms	文献[27]算法/ms	TLGP-ARED-1	Imp1	Imp2	Imp3
10	44.66	41.91	41.52	43.23	3.20%	-3.15%	-4.12%
20	63.21	67.62	65.09	66.45	-5.13%	1.73%	-2.09%
30	64.54	68.19	64.19	63.43	1.72%	6.98%	1.18%
60	64.65	68.12	65.23	64.60	0.08%	5.17%	0.97%
80	64.74	68.16	65.43	64.83	-0.14%	4.89%	0.92%
90	63.21	68.18	65.98	64.76	-2.45%	5.02%	1.85%

表8 $H=0.6$ 时各算法丢包率比较

连接数目/条	CARED	文献[21]算法	文献[27]算法	TLGP-ARED-1	Imp1	Imp2	Imp3
10	0.092%	0.044%	0.013%	0.043%	0.049%	0.001%	-0.030%
20	0.722%	1.188%	0.783%	0.837%	-0.115%	0.351%	-0.054%
30	0.839%	1.321%	0.836%	0.782%	0.057%	0.539%	0.054%
60	0.845%	1.215%	0.892%	0.779%	0.066%	0.436%	0.113%
80	0.812%	1.238%	0.887%	0.786%	0.026%	0.452%	0.101%
90	0.802%	1.242%	0.885%	0.779%	0.023%	0.463%	0.106%

表9 $H=0.6$ 时各算法吞吐量比较

连接数目/条	CARED/(kbit·s ⁻¹)	文献[21]算法/(kbit·s ⁻¹)	文献[27]算法/(kbit·s ⁻¹)	TLGP-ARED-1/(kbit·s ⁻¹)	Imp1	Imp2	Imp3
10	1 250.92	1 223.45	1 234.076	1 250.27	-0.05%	2.19%	1.31%
20	1 344.93	1 306.76	1 298.643	1 311.52	-2.48%	0.36%	0.99%
30	1 290.12	1 298.02	1 366.146	1 342.76	4.08%	3.45%	-1.71%
60	1 280.69	1 278.48	1 295.14	1 308.29	2.16%	2.33%	1.02%
80	1 293.75	1 279.76	1 297.34	1 312.35	1.44%	2.55%	1.16%
90	1 305.45	1 275.52	1 275.827	1 307.82	0.18%	2.53%	2.51%

可以看出，本文的 TLGP-ARED-1 算法在时延、丢包率和吞吐量方面的性能依然稳健，但其提高幅度相较 $H = 0.9$ 时有所降低，甚至有的时候性能会下降。这主要是因为本文的流量水平等级预测方法随着自相似程度的降低准确度会降低，影响了数据包丢弃概率调整的准确性。

3.5 可变瓶颈链路容量条件下的算法对比

利用图 6 的网络拓扑构建可变瓶颈链路容量的卫星通信网络，其中， R_1 - R_2 为瓶颈链路，由链路切换等导致其容量可变，设在 $0 \sim 20$ s，瓶颈链路 R_1 - R_2 容量为 1.5 Mbit/s；在 $20 \sim 50$ s， R_1 - R_2 容量为 3 Mbit/s。TCP 源的数目为 30 个， $\alpha = 1.2$ 。图 8 给出了 TLGP-ARED-1、TLGP-ARED-2、TLGP-ARED 算法的平均队列长度和瞬时队列长度。从图 8 可以看出，采用等间隔瞬时队列采样的 TLGP-ARED-2 和 TLGP-ARED 算法的平均队列长度的波动性较大，但瞬时队列长度比 TLGP-ARED-1 变化小。

本文统计了 TLGP-ARED-1、TLGP-ARED-2 和 TLGP-ARED 算法的时延、时延标准差、丢包率和吞吐量，结果如表 10 所示。Imp1、Imp2 和 Imp3 分别表示 TLGP-ARED-2 相对于 TLGP-ARED-1、TLGP-ARED 相对于 TLGP-ARED-1 和 TLGP-ARED 相对于 TLGP-ARED-2 的性能提升度。从表 10 可以看出，使用等间隔瞬时队列采样的 TLGP-ARED-2 和 TLGP-ARED 算法具有比使用每包瞬时队列长度采样的 TLGP-ARED-1 算法更低的时延和时延抖动、更大的吞吐量，但是丢包率增加。而同时使用等间隔瞬时队列采样和基于预测的平均队列长度计算与最大丢弃概率调整的 TLGP-ARED 算法，可以降低链路的时延和时延抖动、增加吞吐量。这主要是因为将自相似网络流量水平等级预测结果应用于平均队列长度计算中，将瓶颈链路的可变容量信息与缓存的负载信息相结合作为队列管理算法考虑的因素，提高了队列管理算法对瓶颈链路拥塞状态的反应速度和拥塞控制效率。




图 8 3 种 TLGP-ARED 算法的瞬时与平均队列长度对比

4 结束语

自相似性是网络流量的重要特性，对路由节点缓冲区容量设计、队列管理和调度、网络的拥塞控制等有重要影响。本文分析了网络流量自相似程度与流量水平等级转移概率之间的关系，得到网络流量水平等级预测方法，并将此预测结果应用于主动队列管理算法的最大丢弃概率调整和

表 10 可变瓶颈容量情况下 TLGP-ARED-1、TLGP-ARED-2 与 TLGP-ARED 性能比较

比较项目	TLGP-ARED-1	TLGP-ARED-2	TLGP-ARED	Imp1	Imp2	Imp3
时延/ms	57.4	56.5	56.7	1.57%	1.22%	-0.35%
时延标准差/ms	4.1	3.9	3.8	4.88%	7.31%	2.56%
丢包率	1.53%	1.99%	1.84%	-0.46%	-0.31%	0.15%
吞吐量/(kbit·s ⁻¹)	1 486.5	1 529.6	1 631.3	2.90%	9.74%	6.65%

等间隔采样的平均队列长度计算中, 在固定和可变瓶颈链路容量 2 种情况下仿真发现, 无论自相似程度如何, 本文算法在吞吐量方面都有提升, 特别在 Hurst 参数较大且流量负载较低时, 吞吐量性能提升更大。该算法可为由网络流量突发、异构网络链路速率差异等导致的网络拥塞提供新的解决思路。

参考文献:

- [1] JUNG S, KIM J, KIM J H. Intelligent active queue management for stabilized QoS guarantees in 5G mobile networks[J]. *IEEE Systems Journal*, 2021, 15(3): 4293-4302.
- [2] IRAZABAL M, LOPEZ-AGUILERA E, DEMIRKOL I, et al. Dynamic buffer sizing and pacing as enablers of 5G low-latency services[J]. *IEEE Transactions on Mobile Computing*, 2022, 21(3): 926-939.
- [3] BARCZYK M, CHYDZINSKI A. AQM based on the queue length: a real-network study[J]. *PLOS ONE*, 2022, 17(2): e0263407.
- [4] ZHOU K, YEUNG K L, LI V. Nonlinear RED: a simple yet efficient active queue management scheme[J]. *Computer Networks*, 2006, 50(18): 3784-3794.
- [5] TAHILIANI M P, SHET K C, BASAVARAJU T G. CARE: cautious adaptive RED gateways for TCP/IP networks[J]. *Journal of Network and Computer Applications*, 2012, 35(2): 857-864.
- [6] BAKLIZI M. Weight queue dynamic active queue management algorithm[J]. *Symmetry*, 2020, 12: 2077.
- [7] KUNNIYUR S S, SRIKANT R. An adaptive virtual queue (AVQ) algorithm for active queue management[J]. *IEEE/ACM Transactions on Networking*, 2004, 12(2): 286-299.
- [8] YE J C, LEUNG K C. Adaptive and stable delay control for combating bufferbloat: theory and algorithms[J]. *IEEE Systems Journal*, 2020, 14(1): 1285-1296.
- [9] SANTOS C, SILVA C, PEDROSO C M. Improving perceived quality of live adaptative video streaming[J]. *Entropy*, 2021, 23(8): 948.
- [10] KIM M, JASEEMUDDIN M, ANPALAGAN A. Deep reinforcement learning based active queue management for IoT networks[J]. *Journal of Network and Systems Management*, 2021, 29(3): 1-28.
- [11] PAN C S, ZHANG S, ZHAO C, et al. A novel active queue management algorithm based on average queue length change rate[J]. *IEEE Access*, 2022, 10: 75558-75570.
- [12] ABU-SHAREHA A A. Integrated random early detection for congestion control at the router buffer[J]. *Computer Systems Science and Engineering*, 2022, 40(2): 719-733.
- [13] ABUALHAJ M M, ABU-SHAREHA A A, AL-TAHRAWI M M. FLRED: an efficient fuzzy logic based network congestion control method[J]. *Neural Computing and Applications*, 2018, 30(3): 925-935.
- [14] LELAND W E, TAQQU M S, WILLINGER W, et al. On the self-similar nature of Ethernet traffic[J]. *IEEE/ACM Transactions on Networking*, 1994, 2(1): 1-15.
- [15] PARK K, KIM G, CROVELLA M. On the effect of traffic self-similarity on network performance[C]//*Proceedings of the SPIE International Conference Performance and Control of Network Systems*. Bellingham: SPIE Press, 1997: 168-175.
- [16] NORROS I. On the use of fractional Brownian motion in the theory of connectionless networks[J]. *IEEE Journal on Selected Areas in Communications*, 1995, 13(6): 953-962.
- [17] XU X D, GENG C M, ZHU S R, et al. An improved RED algorithm based on ascending semi-Cauchy distribution and EBP[C]//*Proceedings of 11th IEEE Singapore International Conference on Communication Systems*. Piscataway: IEEE Press, 2009: 294-298.
- [18] TAN X H, HUANG Y H. Parameters setting scheme of RED with long-range dependent traffic input[C]//*Proceedings of 2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*. Piscataway: IEEE Press, 2009: 1-4.
- [19] 王晖, 季振洲, 孙彦东, 等. 基于时间槽的自相似流量随机早检测算法—SFRED[J]. *通信学报*, 2010, 31(10): 115-120.
- [19] WANG H, JI Z Z, SUN Y D, et al. Time slot-based RED algorithm on self-similar flows: SFRED[J]. *Journal on Communications*, 2010, 31(10): 115-120.
- [20] 别玉霞, 潘成胜, 刘海燕, 等. 基于 AOS 的 Hurst-优先级自适应 RED 与动态调度算法[J]. *通信学报*, 2012, 33(10): 160-169.
- [20] BIE Y X, PAN C S, LIU H Y, et al. Hurst and priority adaptive RED combined with dynamic scheduling algorithm based on AOS[J]. *Journal on Communications*, 2012, 33(10): 160-169.
- [21] MAREK D, SZYGULA J, DOMAŃSKI A, et al. Adaptive Hurst-sensitive active queue management[J]. *Entropy*, 2022, 24(3): 418.
- [22] DOMAŃSKI A, DOMAŃSKA J, CZACHÓRSKI T, et al. The influence of the traffic self-similarity on the choice of the non-integer order $Pi\alpha$ controller parameters[C]//*Proceedings of the 32nd International Symposium at the IFIP World Computer Congress*. Cham: Springer, 2018: 76-83.
- [23] LIU H, YAN W. An adaptive proportional integral active queue management algorithm based on self-similar traffic rate estimation in WSN[J]. *KSI Transactions on Internet and Information Systems*, 2011, 5(11): 1946-1958.
- [24] GAO Y, HE G H, HOU J C. On exploiting traffic predictability in active queue management[C]//*Proceedings of Annual Joint Conference of the IEEE Computer and Communications Societies*. Piscataway: IEEE Press, 2002: 1630-1639.
- [25] AMIN F, MIZANIAN K. Buffer management for self-similar network traffic[C]//*Proceedings of the 6th International Symposium on Telecommunications*. Piscataway: IEEE Press, 2013: 737-742.
- [26] 温昱晖, 朱祥华, 张勇. 自相似流量的主动队列管理算法[J]. *电子与信息学报*, 2006, 28(7): 1303-1307.
- [26] WEN Y H, ZHU X H, ZHANG Y. Self-similar traffic control in active queue management[J]. *Journal of Electronics & Information Technol-*

ogy, 2006, 28(7): 1303-1307.

- [27] BIE Y X, LI Z H, HU Z, et al. Queue management algorithm for satellite networks based on traffic prediction[J]. IEEE Access, 2022, 10: 54313-54324.
- [28] DOMAŃSKI A, DOMAŃSKA J, CZACHÓRSKI T, et al. The use of a non-integer order PI controller with an active queue management mechanism[J]. International Journal of Applied Mathematics and Computer Science, 2016, 26(4): 777-789.
- [29] SZYGULA J, DOMAŃSKI A, DOMAŃSKA J, et al. Supervised learning of neural networks for active queue management in the internet[J]. Sensors, 2021, 21(15): 4979.
- [30] TAQQU M S, WILLINGER W, SHERMAN R. Proof of a fundamental result in self-similar traffic modeling[J]. ACM SIGCOMM Computer Communication Review, 1997, 27(2): 5-23.
- [31] 张宾, 杨家海, 吴建平. Internet 流量模型分析与评述[J]. 软件学报, 2011, 22(1): 115-131.
- ZHANG B, YANG J H, WU J P. Survey and analysis on the Internet traffic model[J]. Journal of Software, 2011, 22(1): 115-131.
- [32] 魏德宾, 沈婷, 杨力, 等. 基于自相似流量水平分级预测的网络队列调度算法[J]. 通信学报, 2020, 41(4): 182-189
- WEI D B, SHEN T, YANG L, et al. Network queue scheduling algorithm based on self-similar traffic level grading prediction[J]. Journal on Communications, 2020, 41(4): 182-189
- [33] PARK K, TUAN T. Performance evaluation of multiple time scale TCP under self-similar traffic conditions[J]. ACM Transactions on Modeling and Computer Simulation, 2000, 10(2): 152-177.
- [34] FIROIU V, BORDEN M. A study of active queue management for congestion control[C]//Proceedings of the Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Piscataway: IEEE Press, 2002: 1435-1444.

[作者简介]



魏德宾 (1978-), 男, 辽宁大连人, 南京理工大学博士生、大连大学副教授, 主要研究方向为空间信息网络传输技术、流量工程和网络优化。



潘成胜 (1962-), 男, 江苏宜兴人, 博士, 南京信息工程大学教授, 主要研究方向为天地一体化智能网络流量理论。



杨力 (1982-), 女, 黑龙江哈尔滨人, 博士, 南京理工大学教授, 主要研究方向为空间信息网络传输技术、无线通信网络协议理论与方法。



颜佐任 (1996-), 男, 湖南常德人, 大连大学硕士生, 主要研究方向为空间信息网络传输技术。