

doi:10.13756/j.gtxyj.2021.05.003

光通信系统与网络技术

50 Gbit/s-EPON 中基于预测的多波长带宽分配算法

朱 祥¹, 李国勇¹, 许 鸥²

(1. 太原理工大学 电气与动力工程学院, 太原 030024; 2. 广东工业大学 信息工程学院, 广州 510006)

摘要:根据 IEEE 802.3ca 新标准中对 50 Gbit/s—以太网无源光网络(EPON)上行链路的说明,网络上行链路中需要对多波长进行动态带宽分配。文章采用长短时记忆神经网络对网络流量进行预测,旨在提高带宽分配的效率;同时,考虑到网络中不同类型业务对网络时延和带宽要求的差别,分别对不同优先级的业务采取不同的分配方案。仿真实验表明,基于神经网络预测的方法可以有效降低网络的延迟;对不同业务采取不同分配方案时,高优先级业务的延迟降低,并且随着网络负载的提高,延迟变化幅度较小。文章所提算法满足了高优先级业务的需求,虽然低优先级业务延迟与之前方式相比有所增大,但考虑到低优先级业务对延迟要求并不高,因此对于网络整体服务质量影响不大。

关键词:50 Gbit/s 以太网无源光网络;长短时记忆神经网络;动态带宽分配;网络服务质量

中图分类号:TP393 **文献标志码:**A **文章编号:**1005-8788(2021)05-0024-07

Multi-Wavelength Bandwidth Allocation Algorithm based on Prediction in 50 Gbit/s-EPON

ZHU Xiang¹, LI Guo-yong¹, XU Ou²

(1. College of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China;
2. School of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: According to the description of 50 Gbit/s-Ethernet Passive Optical Network (EPON) in IEEE 802.3ca new standard, multi-wavelength dynamic bandwidth allocation is needed in network uplink. In this paper, long short-term memory neural network is used to predict the network traffic in order to improve the efficiency of bandwidth allocation. At the same time, considering the different requirements of network delay and bandwidth for different types of services in the network, different allocation schemes are adopted for different priority services. The simulation results show that the neural network prediction method can effectively reduce the delay of the network. When different allocation schemes are adopted for different services, the latency of high-priority services decreases, and the latency varies with the increase of network load. The algorithm proposed in this paper meets the requirements of high-priority service. Although the latency of low-priority service is increased compared with the previous method, it has little impact on the overall service quality of the network considering that low-priority service does not have high latency requirements.

Key words: 50 Gbit/s-EPON ;long short-term memory neural network ;dynamic bandwidth allocation ;quality of service

0 引 言

2020 年 6 月 4 日,电气与电子工程师协会(Institute of Electrical and Electronics Engineers, IEEE)标准委员会通过了 IEEE Std 802.3ca-2020 标准^[1]。该标准指出,50 Gbit/s—以太网无源光网络(Ethernet Passive Optical Network, EPON)技术中存在多波长组合使用的情况。

动态带宽分配(Dynamic Bandwidth Allocation, DBA)是目前主流的网络资源分配方式,该方法由光线路终端(Optical Line Terminal, OLT)根据当前网络的实际情况动态地为各个光网络单元(Optical Network Unit, ONU)分配合适的带宽,合理利用带宽资源。从带宽分配的时间方面可以将分配方式分为在线分配、离线分配和在线—离线分

配^[2]。

如果将多条波长看作一条,经典的 DBA 算法自适应周期时间的交错轮询(Interleaved Polling with Adaptive Cycle Time, IPACT)算法^[3]也可用于 50 Gbit/s-EPON 中,称为修正的 IPACT(Modified-IPACT)算法;文献[4]提出了“First-Fit”算法,将单个 ONU 的所有消息都放在一条波长上进行传输,减少了传输时切换波长造成的时间损耗;文献[5]中根据 50 Gbit/s-EPON 的特点,提出了注水(Water-Filling, WF)-DBA 算法,该算法将所有波长看作一组相通的容器,每次分配带宽时都看作是一个“WF”过程,确保所有波长得到了充分利用;文献[6]中使用反馈(Back-Propagation, BP)神经网络,对等待发送时间内新增的流量数据进行预测,获得了不错的效果。

收稿日期:2020-12-31

基金项目:国家重点研发计划资助项目(2019YFB1803803)

作者简介:朱祥(1996—),男,山西太原人。硕士,主要研究方向为智能控制。

通信作者:许鸥,副教授。E-mail: xuou@gdut.edu.cn

本文基于长短时记忆(Long Short-Term Memory, LSTM)神经网络对复杂的网络流量进行预测,提出了一种支持网络服务质量(Quality of Service, QoS)的基于神经网络预测的多波长 DBA(Predict-Dual Wavelength Dynamic Bandwidth Allocation, PD-DWDBA)算法。

1 LSTM 神经网络预测模型

对于网络流量预测,许多学者已经对其进行了研究。首先,部分学者提出了线性预测模型对网络流量进行建模,如分段自回归滑动平均模型(Autoregressive Moving Average, ARMA)等;之后,其他学者又开发出了非线性预测模型,如支持向量机(Support Vector Machine, SVM)和高斯过程(Gaussian Process, GP)等模型^[7],相比线性模型,这些方法对于当前网络流量的非线性特征有着很好的表现;神经网络和深度学习近几年受到学者的广泛关注,它们在解决非线性问题上也有着非常好的效果,如 BP 神经网络和径向基(Radial Basis Function, RBF)神经网络等,这类神经网络虽然在网络流量预测方面也取得了较好的效果,但缺点是,它们的每一步预测只考虑了当前的输入信息,对于网络流量这种前后联系紧密的时间序列来说,不能很好地提取出数据的特点。同时,对于短时间内快速变化的网络流量,这些方法也不能很好地获取网络的变化情况。

循环神经网络(Recurrent Neural Network, RNN)在计算每个时刻的输出时,都会考虑到之前的输入信息,因此对于网络流量这样的时间序列有着很好的预测效果^[8]。但 RNN 容易出现梯度消失和爆炸的风险。本文采取了 RNN 的变种形式 LSTM 神经网络,该网络克服了传统 RNN 梯度消失和爆炸的缺点,在自然语句识别和时间序列预测方面获得了不错的效果^[9]。LSTM 网络节点结构如图 1 所示,下标 t 为当前时刻; h_t 为节点的输出; C_t 为隐藏的胞体,其包含有整个计算过程中保留下来的信息; X_t 为输入值; σ 为 sigmoid 函数; $\tanh$ 为双曲正切函数。整个节点的计算过程如下:

(1) 遗忘门

遗忘门负责选择需要遗忘的信息,将 h_{t-1} 与 X_t 结合后,经 sigmoid 函数计算得到一个权值矩阵 f_t 。 f_t 的大小在 $[0, 1]$ 之间,其中 0 表示全部遗忘(丢弃),1 表示保留。

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f), \quad (1)$$




图 1 LSTM 网络节点结构

式中: W_f 为遗忘门权值; b_f 为遗忘门偏值。

(2) 输入门

输入门决定保留哪些信息,保留的信息为 i_t 。其中 i_t 与 f_t 相类似,都有一个权值的作用。

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i), \quad (2)$$

式中: W_i 为输入门权值; b_i 为输入门偏值。

(3) 输出门

输出门负责计算需要输出的信息 o_t 。

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o), \quad (3)$$

式中: W_o 为输出门权值; b_o 为输出门偏值。

(4) 更新胞体信息

对于 LSTM 结构最重要的组成部分,当前节点最终的胞体信息 C_t 主要通过以下方式产生:首先,将遗忘门的计算结果 f_t 与上一时刻的胞体信息 C_{t-1} 相乘,这样就选择性地丢弃了一些久远的、无用的信息;然后将 h_{t-1} 与 X_t 结合之后的值通过 $\tanh$ 函数计算,与胞体权值 W_c 相乘,得到一个短时的胞体,保存暂时的信息;最后将这两部分相加,最终得到了该时刻的胞体信息。

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, X_t] + b_c), \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t, \quad (5)$$

式中: $\tilde{C}_t$ 为当前节点的临时胞体信息; b_c 为胞体偏值。

(5) 计算最后的输出

将胞体信息通过 $\tanh$ 函数计算后与输出门结果 o_t 相乘,得到节点最终的输出值 h_t 为

$$h_t = o_t \cdot \tanh(C_t). \quad (6)$$

相比于 RNN, LSTM 神经网络对之前的信息进行了选择性地处理和保留,这样就防止了梯度爆炸和梯度消失等问题的出现,网络的预测效果也得到了很大的提升。

2 支持 QoS 的 PD-DWDBA 算法用于多波长 DBA

为了方便地说明该算法,引入表 1 中的符号。

表 1 算法中各个符号含义

符号	含义
RTT_i	第 i 个 ONU 与 OLT 之间的发送延迟
t_λ	波长 λ 可开始传输时间($\lambda = 1, 2$)
$r_{i,type}^j$	第 i 个 ONU 在第 j 个轮询周期内的请求带宽大小($type$: H(高优先级业务), L(低优先级业务))
B_{MAX}	允许授权的最大带宽
$g_{i,type}^j$	第 i 个 ONU 在第 j 个轮询周期内获得的授权带宽大小和波长
$p_{i,type}^j$	第 i 个 ONU 在第 j 个轮询周期内预测的带宽大小
v	波长传输速率
T_{guard}	传输保护时间
$t_{i,type}^j$	第 i 个 ONU 在第 j 个轮询周期内传输所需时间
$start_{i,type}^j$	第 i 个 ONU 在第 j 个轮询周期内开始传输时间
$net_{i,type}^j$	第 i 个 ONU 各个优先级业务的路径网络模型

首先,对文献[3]、[4]和[5]中提及的 3 种多波

长 DBA 算法进行比较分析,如图 2 所示。

在离线带宽分配过程中,ONU 的调度顺序十分重要。上述 3 种方法中都是按照 RTT_i 升序进行排列,这样可以保证开始传输时的时间损耗最小,剩余 ONU 传输时的延迟在分配带宽时已提前考虑,可以忽略不计。由图 2(a)可知,Modifier-IPACT 算法简单易懂,但每个波长上都有多个 ONU 进行传输,引入较多的保护时间;由图 2(b)可知,First-Fit 算法虽然减少了保护时间的损耗,但波长资源出现闲置,造成了浪费;由图 2(c)可知,WF-DBA 算法综合考虑了两种方式,充分利用了波长资源,同时减少了保护时间,但是单纯使用 RTT_i 作为排序原则,可能出现如图 3 所示的情况,由于倒数第 2 个请求带宽过大,最后一个 ONU 的带宽全部部署在一条波长上,导致波长浪费。




图 2 3 种算法分配带宽时不同波长上的情况




图 3 按照 RTT 大小进行调度可能出现的意外情况

因此,为了防止这种情况的发生,本文所涉及 DBA 算法中的调度顺序为:首先,选出 RTT_i 最小的两个 ONU 最先调度,保证开始传输时的时间损耗最小;剩余的 ONU 则按照分配带宽大小进行升序排列。

对于离线 DBA 算法,其 ONU 与 OLT 之间相互发送接收数据的时序如图 4 所示。




图 4 离线 DBA 算法中 ONU
与 OLT 间发送数据的时序

每个 ONU 发送 REPORT 消息汇报缓存队列长度后,会有新的数据到达缓存队列,若能将该部分数据进行提前分配,理论上就可以提高传输效率,降低延迟。假设从 ONU 发送 REPORT 消息到 ONU 实际发送数据的时间间隔为 Δt ,若能得知这时的网络速率,就可以得到 Δt 时间内到达的新数据的大小,OLT 就可以进行调度分配。OLT 在收到 ONU 发送的 REPORT 消息后,可以计算出两个周期内

REPORT 消息到达的时间间隔 Δt , 从而计算出该周期内的平均速率, 将该速率输出到提前训练好的 LSTM 神经网络模型中, 得到下一段时间内的速率, 最终得到等待发送时间内新增的数据大小。将结果与 ONU 请求的带宽相加, 与最大授权带宽大小比较, 确定最终授权的带宽大小。

根据不同业务的特点,一般情况下将网络中的业务分为 3 类:全力转发型(EF),保证带宽型(AF)和尽力而为型(BE)。EF 业务要求充足稳定的带宽和低延迟;AF 业务要求充足稳定的带宽;BE 业务对于带宽和延迟均无要求。对于 3 种业务类别,可将其分为两类:高优先级业务(High Priority),要求低延迟;低优先级业务(Low Priority),对延迟要求不高。为了满足高优先级业务的低延迟要求,在进行带宽分配时,首先对所有 ONU 的高优先级业务进行分配,然后再处理低优先级业务。

图5所示为支持QoS的PD-DWDBA算法中各个波长上消息的分布情况。首先,为高优先级业务分配带宽时,直接采取First-Fit策略,将单个ONU的高优先级业务部署在一条波长上,减少切换波长带来的时间损耗,同时,不限制其带宽大小,保证高优先级业务的带宽;分配低优先级业务时,采取WF-DBA策略,保证两条波长在该轮询周期结束后时间相同,为了防止某个ONU带宽过大导致长时间占据带宽,分配带宽时限制带宽大小。对于不同优先级业务,分别建立神经网络模型进行预测,提前分配带宽。




图 5 支持 QoS 的 PD-DWDBA 算法中波长分布

支持 QoS 的 PD-DWDBA 算法的伪代码如下所示:

- (1) 根据提前采集好的高优先级业务数据和低优先级业务数据训练神经网络 net_H 和 net_L ;
- (2) OLT 收到所有的 REPORT 消息后, 对 ONU 进行排序, 确定调度顺序;
- (3) 首先根据所有的 $r_{i,H}^j$ 分配高优先级业务;
- (4) For $i = 1 \rightarrow N$ do;
- (5) 通过神经网络计算等待时间内新增的流量 $p_{i,H}^j = net_{i,H}(r_{i,H}^j)$;

- (6) 计算 $t_{i,H}^j = (r_{i,H}^j + p_{i,H}^j)/v$;
- (7) 选择最早可传输的波长, 将该波长分配给该 ONU;
- (8) 计算 $start_{i,H}^j = t_\lambda + t_{i,H}^j$;
- (9) 将授权的发送时间和波长打包到 $g_{i,H}^j$;
- (10) 更新波长可传输时间 $t_\lambda = t_\lambda + t_{i,H}^j$;
- (11) 然后分配低优先级业务;
- (12) For $i = 1 \rightarrow N - 1$ do;
- (13) 通过神经网络计算等待时间内新增的流量 $p_{i,L}^j = net_{i,L}(r_{i,L}^j)$;

- (14) 将 $r_{i,L}^j + p_{i,L}^j$ 与 B_{MAX} 比较,选择较小的值作为实际分配带宽;
- (15) 计算 $t_{i,L}^j = \min(r_{i,L}^j + p_{i,L}^j, B_{MAX})/v$;
- (16) 选择最早可传输的波长,将该波长分配给该 ONU;
- (17) 计算 $start_{i,L}^j = t_{\lambda} + t_{i,L}^j$;
- (18) 将授权的发送时间和波长打包到 $g_{i,L}^j$;
- (19) 更新波长可传输时间 $t_{\lambda} = t_{\lambda} + t_{i,L}^j$;
- (20) 对于调度表中最后一个 ONU,首先将其带宽部署到最先可传输的波长上,然后比较两条波长的时间:若时间误差在 10% 之内,则可看作结束时间相同,分配结束;当误差较大时,将多余部分平均分配,部署在两条波长上;
- (21) 将授权的发送时间和波长打包到 $g_{i,L}^j$;
- (22) 更新波长可传输时间;
- (23) 将 $g_{i,H}^j$ 和 $g_{i,L}^j$ 打包,以广播的形式发送给 ONU,分配结束。

3 实验研究

3.1 LSTM 神经网络模型预测效果

1993 年, Leland 和 Taqqu 等人通过对采集的网络流量进行分析,发现网络流量在不同时间尺度上有着相似的属性,这一特点称作网络流量的自相似性^[10]。之后研究人员在此基础上提出了众多仿真网络流量的方式,其中应用最广泛的是 ON/OFF 模型。ON/OFF 模型是在 ON 期间产生流量, OFF 期间不产生流量,其中 ON 与 OFF 的持续时间需要满足重尾分布。通过这样不断地 ON 与 OFF 交替,产生的数据就具有与实际网络流量相类似的自相似性。经过众多研究发现, ON/OFF 模型产生的数据源与现实接入网的流量数据有着相同的特性。本文将 32 个 ON/OFF 数据源叠加, ON 和 OFF 的持续时间分别满足 $\text{pareto}(1.00, 1.40)$ 和 $\text{pareto}(0.01, 1.20)$ 分布,产生的数据包大小在 64 ~ 1 518 bytes 之间。在软件中,数据源是随机发送大小随机的数据包,而在带宽分配中需要根据当前队列中的流量数据大小来分配带宽。因此,在仿真时,需要统计一定时间内队列中的流量总大小。本文采用 2 ms 采样时间,将 2 ms 内产生的所有数据之和作为一次流量数据。经过 20 s 的仿真,得到 10 000 组数据。部分数据分布如图 6 所示。

将 BP 神经网络、传统 RNN 和本文所使用的 LSTM 神经网络进行对比,结果如图 7 所示。由图可知, BP 神经网络和传统 RNN 的预测效果虽然可






图 6 训练神经网络时的网络流量数据


以跟随到实际数据的变化趋势,但却不能跟踪到实际网络流量快速大幅度的变化,而 LSTM 神经网络的预测结果与实际流量值十分接近。



(a) BP 神经网络预测结果



(b) RNN 预测结果



(c) LSTM 神经网络预测结果

图 7 BP 神经网络、RNN 和 LSTM

神经网络对网络流量预测的效果

3.2 DBA 算法

本次仿真的参数如表 2 所示。

表 2 仿真参数

参数	数值
ONU 个数	36
ONU 与 OLT 距离/km	20
轮询周期长度/ms	2
$v/\text{Gbit/s}$	25
保护时间 $T_{\text{guard}}/\mu\text{s}$	1

首先,不考虑业务分级的情况,网络流量由 ON/OFF 模型产生,ON 和 OFF 的持续时间分别满足 $\text{pareto}(1.00, 1.40)$ 和 $\text{pareto}(0.01, 1.20)$ 分布,数据包大小在 $64 \sim 1\,518\text{ bytes}$ 之间。对比 Modified-IPACT、WF-DBA 和 PD-DWDBA 算法,以带宽负载率作为横坐标,包延迟作为纵坐标,观察不同负载情况下的延迟情况如图 8 所示。





图 8 3 种 DBA 算法网络延迟比较


由图可知,随着网络负载的不断上升,3 种方法的网络延迟都在不断上升,但从全局来看,基于预测的 PD-DWDBA 算法产生的延迟要低于另外两种算法,证明了该方法确实可以提高网络性能。此时,整个网络中高优先级业务与低优先级业务的延迟情况如图 9 所示。

图 9(a)所示为高优先级业务的延迟,由图可知,未分级处理情况下,Modified-IPACT 算法中高优先级业务延迟相对较大,WF-DBA 和 PD-DWD-BA 算法中高优先级业务延迟较低,但是 WF-DBA 算法中高优先级业务的延迟在低负载情况下出现波动,两种算法的高优先级业务延迟在负载增大后迅速增大,这对于高优先级业务的传输是不利的。图 9(b)所示为低优先级业务的延迟,由于网络中主要以低优先级业务为主,因此低优先级业务的延迟与网络的整体延迟十分接近。

在此基础上,采用支持 QoS 的算法进行分析。高优先级业务采取 poisson 模型,数据包大小为 70 bytes ;低优先级业务采取 ON/OFF 模型,ON 和 OFF 的持续时间分别满足 $\text{pareto}(1.00, 1.40)$ 和



(a) 高优先级业务延迟对比



(b) 低优先级业务延迟对比

图 9 3 种 DBA 算法高优先级业务和低优先级业务延迟

$\text{pareto}(0.01, 1.20)$ 分布,数据包大小在 $64 \sim 1\,518\text{ bytes}$ 之间。网络的延迟状况如图 10 所示。




图 10 支持 QoS 的 DBA 算法与不支持 QoS 的算法的网络延迟比较

首先,由图可知,当采用支持 QoS 的 PD-DWD-BA 算法时,网络整体延迟值相较于 PD-DWDBA 算法而言有增大,当网络负载 > 0.8 时,延迟大于 WF-DBA 算法。同理,网络中占据主要部分的低优先级业务的延迟也出现了类似的状况(如图 11(b)所示)。这是由于网络优先传输高优先级业务,且不限其带宽大小,高优先级业务占据了较大的带宽,导致了网络整体效果的下降。但同时,如图 11(a)所示,采用支持 QoS 的 PD-DWDBA 算法能够使高优先级业务的延迟显著降低,并且随着负载的增大,延迟的变化幅度也明显减缓。而低优先级业务对于网络时延并不敏感,因此延迟的增大对于网络用户而言区别并不大。




图 11 支持 QoS 的 PD-DWDBA 算法高优先级业务和低优先级业务延迟对比

4 结束语

基于 50 Gbit/s-EPON 的网络标准,本文提出了支持 QoS 的 PD-DWDBA 算法用于多波长 DBA。在仿真测试中,相比之前的 DBA 算法,使用本方法后,网络中高优先级业务的延迟情况得到明显改善,并且随着网络负载的增大,减缓了延迟波动幅度,不过同时导致了低优先级业务的延迟小幅增大。可能的原因是,在带宽分配过程中,为了保证高优先级业务的带宽需求,并没有对其进行限制,导致高优先级业务占据较大的带宽。接下来需要针对这部分缺陷进行改进,在保证高优先级业务当前状况的情况下,降低低优先级业务延迟量。

参考文献:

[1] IEEE Std 802.3ca-2020, IEEE Standard for Ethernet Amendment 9:Physical Layer Specifications and Management Parameters for 25 Gbit/s and 50 Gbit/s Passive Optical Networks[S].

[2] 吴旭佳. 下一代以太无源光接入网的带宽资源管理研究[D]. 上海:上海交通大学,2019.

[3] Kramer G,Mukherjee B,Pesavento G. IPACT a Dynamic Protocol for an Ethernet PON (EPON) [J]. IEEE Communications Magazine,2002,40(2):74—80.

[4] Hussain S B, Hu W, Xin H, et al. Low-Latency Dynamic Wavelength and Bandwidth Allocation Algorithm for NG-EPON[J]. Journal of Optical Communications and Networking, 2017, 9(12):1108—1115.

[5] Wang W,Guo W,Hu W. On the Efficiency and Fairness of Dynamic Wavelength and Bandwidth Allocation Algorithms for Scheduling Multi-type ONUs in NG-EPON[J]. Optical Fiber Technology,2018,45:208—216.

[6] 董传成. 基于突发业务预测且公平的 EPON 动态带宽分配策略研究[D]. 镇江:江苏大学,2010.

[7] 杜爽,徐展琦,马涛,等. 基于神经网络模型的网络流量预测综述[J]. 无线电通信技术,2020,46(2):216—222.

[8] Wen Y, Zhu G. Prediction for Non-Gaussian Self-Similar Traffic with Neural Network[C]// World Congress on Intelligent Control & Automation. Dalian, China: IEEE, 2006:1713171.

[9] Chen Q, Zhu X, Ling Z, et al. Enhanced LSTM for Natural Language Inference[C]// the 55th Annual Meeting of the Association for Computational Linguistics. Vancouver, Canada: ACL,2017:P17—1152.

[10] Leland W E, Taquq M S, Willinger W, et al. On the Self-Similar Nature of Ethernet Traffic[J]. ACM SIGCOMM Computer Communication Review, 1993, 23(4):183—193.