

基于贝叶斯网络的 SDON 控制器自学习负载均衡算法

蒋雯丽, 梁思远, 赵芳利, 赵 峰

(西安邮电大学 通信与信息工程学院, 西安 710121)

摘要: 随着软件定义光网络(SDON)规模的增大, 需多个控制器共同为全网提供服务, 而控制器负载均衡问题影响到全网服务能力和网络生存性。提出一种基于贝叶斯网络的 SDON 控制器自学习负载均衡算法。首先, 在考虑控制器负载、控制器吞吐量 and 光交换机迁移时延等控制器相关参数的情况下, 利用贝叶斯网络预测负载拥塞程度; 其次, 结合强化学习算法作出最优动作决策, 并利用反馈机制实现参数权重的自我调节, 从而调整控制器负载拥塞程度实现负载均衡。仿真结果表明: 与 Q-learning 算法相比, 该算法更好地实现了控制器负载均衡功能, 更快地提高了负载均衡效率。

关键词: 软件定义光网络; 贝叶斯网络; 强化学习; 控制器负载均衡

中图分类号: TP393.0 文献标识码: A 文章编号: 1002-5561(2019)12-0010-06

DOI: 10.13921/j.cnki.issn1002-5561.2019.12.003

开放科学(资源服务)标识码(OSID):



Self-learning load balancing algorithm for SDON controller based on Bayesian network

JIANG Wenli, LIANG Siyuan, ZHAO Fangli, ZHAO Feng

(College of Communication and Information Engineering, Xi'an University of Post and Telecommunications, Xi'an 710121, China)

Abstract: With the increase of software defined optical network (SDON) scale, multiple controllers are needed to provide services for the whole network. The load balancing problem of controllers affects the service capability and network survivability of the whole network. A self-learning load balancing algorithm for SDON controller based on Bayesian network is proposed. Firstly, considering the controller parameters such as controller load, controller throughput and optical switch migration delay, Bayesian network is used to predict the degree of load congestion; secondly, the optimal action decision is made by combining reinforcement learning algorithm, and the feedback mechanism is used to realize the self-adjustment of parameter weights so as to adjust the control. Load balancing can be achieved by the degree of load congestion. The simulation results show that compared with Q-learning algorithm, the proposed algorithm achieves better load balancing function of the controller and improves load balancing efficiency more quickly.

Key words: software defined optical network; Bayesian network; reinforcement learning; controller load balancing

0 引言

软件定义光网络(SDON)具有网络虚拟化和资源可编程的特点, 被认为是未来光网络的发展趋势, 且

具备了更加灵活、高效和开放的网络功能, 并支持数据中心的互联互通; 同时, 云平台可以提供强大的计算、存储和管理能力^[1,2]。SDON 是将软件定义网络(SDN)技术融入到传统光网络中, 大大改善了传统光网络的弱点, 例如控制执行不到位、资源利用效率低下等^[3]。在 SDON 中, 控制层对光网络进行统一管理, SDON 通过集中控制器简化光网络中现有的复杂控制协议, 利用开放的接口统一控制网络, 可有效处理多域光网络的互联互通问题^[4,5]。但是, 网络信息类型具有多样化, 在大规模网络中容易出现控制器与光交换机配属失衡、控制器连接光交换机过多或过少和大量多载波流量突发等问题, 均会导致控制器负载失衡,

收稿日期: 2019-07-05。

基金项目: 国家自然科学基金(61875164)资助; 陕西省教育厅 2017 年专项科学研究计划(17JK0702)资助。

作者简介: 蒋雯丽(1994-), 女, 甘肃定西人, 硕士研究生, 主要研究方向为信息处理技术及应用, 软件定义网络与软件定义光网络。参与国家自然科学基金项目 1 项, 陕西省教育厅 2017 年专项科学研究计划基金项目 1 项。



网络通信性能下降。因此,SDN 控制器负载均衡问题成为近年来 SDN 领域研究的重点和热点。文献[6]提出一种新的基于控制器集群的 SDN 多控制域网络架构,其利用负载均衡的思路设计了集群间控制器迁移、集群内从控制器优化选择和主从控制器切换等机制以提供保障,但没有对控制器的资源使用情况进行定量分析。文献[7]提出一种基于 Q -learning 的自学习路由协议,利用信噪比、时延和吞吐量等服务质量参数进行路由决策;同时,利用贝叶斯网络估计相邻网络的拥塞水平,调整 Q -learning 权重。其路由决策有效地提高了重负载动态自组网的数据包传递率(PDR),但是没有结合功率控制和路由做出更复杂的决策。文献[8]提出一种基于强化学习的网络拥塞预防机制,以实现 SDN 中的高效路由,其使用预先定义的阈值和强化学习路由算法重新选择路径,改变多载波流量表,进而改善网络拥塞。但是强化学习路由算法没有考虑到 Q 值局部最大的问题。文献[9]将 SDN 引入到光网络中,设计了一种基于网络感知的动态链路负载均衡机制,并提出基于带宽的最短路径算法,根据实时网络状态信息为视频流选择当前链路质量最优的传输路径,但是在仿真实验中使用的网络拓扑结构相对单一,只验证了点到点的视频流传输,而真实的网络拓扑规模较大且结构复杂。文献[10]提出基于 Q -learning 的动态交换机迁移算法,运用 Q -learning 算法对 SDN 交换机迁移算法模型进行了优化,实现了 SDN 控制器负载均衡,但是单独使用 Q -learning 算法可能会将整个网络视为黑盒子,正如神经网络一样,这种方法很容易使 Q 值陷入局部最大。针对上述问题,本文提出基于贝叶斯网络的 SDN 控制器自学习负载均衡算法,实现控制器负载均衡。

1 SDN 控制器负载均衡情况下的强化学习模型

在人工智能领域,一般会用智能体表示能够做决策的物体,强化学习考虑的是智能体与环境之间的交互任务,其最基本的问题是一个智能体在未知的环境中,如何根据观察和反馈去调整自己的行为,从而使积累的反馈值最大化。一般情况下, Q -learning 算法需要每个节点记录一个表,即储存 Q 值的 Q 表。本文提出的算法则要求每个节点记录 2 个表:一个是用于存储 Q 值的 Q 表,另一个是用于存储先验概率和条件概率的贝叶斯网络(BN)表。每当迁移光交换机时,它将查询其 Q 表和 BN 表,提取相关信息并更新 2 个表,从而选择相应的最佳动作。

1.1 状态空间和动作空间

基于贝叶斯网络的 SDN 控制器自学习负载均衡算法,先需划分状态空间。其状态空间定义为 SDN 系统中所有控制器构成的集合,即 $\{State\} = \{C_1, C_2, C_j, \dots, C_{N_c}\}$ 。基于贝叶斯网络的 SDN 控制器自学习负载均衡算法,其动作空间定义为所有光交换机到核心控制器的连接,即 $A = \{(S_1, C_1), \dots, (S_i, C_j), \dots, (S_{N_s}, C_{N_c})\}$ 。其中,每个元素都定义为光交换机 S_i 连接到控制器 C_j 的对应动作。

1.2 回报函数

基于贝叶斯网络的 SDN 控制器自学习负载均衡算法,在每次迁移后记录 SDN 控制器的相关参数信息,如控制器负载 L_c 、迁移时的延迟 D 和吞吐量 T 等参数。这些参数都是衡量控制器负载均衡算法的重要指标,本文利用 SDN 控制器的负载参数可以得到回报函数:

$$r(s, a) = w_1 L_c + w_2 T - w_3 D \quad (1)$$

其中, w_1 是控制器的负载 L_c 的权重; w_2 是光交换机迁移时吞吐量的权重;吞吐量 T 指控制器每秒内能够处理业务的数量; w_3 是迁移光交换机时光交换机到控制器的延迟 D 的权重。在状态 s 下执行动作 a , 回报函数越大,对应的 Q 值越大。

1.3 值函数

Q -learning 算法是强化学习的一种特殊形式,不需要模型的先验知识,只需通过 Q 表来存储所有状态对应动作的 Q 值, Q 值代表每个动作的预期回报值。在 Q -learning 算法学习过程中,通过迭代计算来逼近最优值函数。预设一个 Q 值矩阵,初始化矩阵并把初始值都设定为 0。 Q 值迭代更新为:

$$Q_{t+1}(s, a) = (1 - \alpha) Q_t(s, a) + \alpha (r(s, a) + \gamma \max_{a_n} Q_t(s, a_n)) \quad (2)$$

其中, s, a 分别表示控制器当前的状态和动作, a_n 表示当前状态采取的下一个动作。在 $t+1$ 次迭代时,状态 s 选择动作 a 。 α 是学习效率,用于控制旧 Q 值和新 Q 值之间的差异程度,若 $\alpha=0$,函数就没有迭代;若 $\alpha=1$,其为一个贝尔曼方程。 γ 为学习参数,取值 $[0, 1]$, $\gamma \rightarrow 0$,表示控制器决策更多考虑的是当前行为的奖励值; $\gamma \rightarrow 1$,表示控制器决策会更多考虑到未来行为的奖励值。 $\max Q_t(s, a_n)$ 定义为选择下一个动作 a_n 时的最大奖励值。

1.4 动作决策

迁移光交换机时,本文依据当前 SDN 控制器的

相关 Q 值做出动作决策,基于玻尔兹曼概率分布做出迁移决策,下一个动作选择时并不总是选择具有最高 Q 值的动作。基于贝叶斯网络的 SDON 控制器自学习负载均衡算法的动作选择策略表达式为:

$$P(a|s) = \frac{e^{\beta Q_t^j(s,a)}}{\sum_{l \in A(s)} e^{\beta Q_t^j(s,l)}} \quad (3)$$

其中,在第 t 次迭代时,状态 s 选择动作 a , $Q_t^j(s,a)$ 定义为当前控制器 j 在状态 s 下选择动作 a 的 Q 值。 $A(s)$ 定义为状态 s 下选择的一组可选择动作, l 属于 $A(s)$, 是状态 s 下选择的一组可选择动作中的某一个动作, β 是一个确定选择非贪婪动作概率的参数, $P(a|s)$ 是在状态 s 下选择动作 a 时的概率。

2 贝叶斯网络设计

单独使用文献[10]中的 Q -learning 算法会将整个网络视为黑盒子,正如神经网络一样,很容易使 Q 值陷入局部最大。当需要考虑众多因素时,通常不考虑强化学习过程中各种因素的权重,但如果没有模型的优化,会使 Q 值极易陷入局部最大,因此权重调整对于强化学习是必要且重要的。但是,通过 Q -learning 算法, Q 值大的动作每次被选择的可能性较大,导致具有良好链路质量的某些节点出现严重拥塞,从而降低整体网络性能。因此,本文利用贝叶斯网络解决 Q 值局部最大的问题,最初的贝叶斯网络结构是基于推理和领域知识构建的,其结构图如图 1 所示。




图 1 最初的贝叶斯网络结构

在贝叶斯网络预测 SDON 控制器负载拥塞程度之前,需定义控制器的负载级别,控制器负载级别 C 定义如下:

$$C = \frac{N_c}{N_s} \times \frac{L_c}{L_s} \quad (4)$$

其中, N_c 为控制器 C_j 连接光交换机 S 的数目, N_s 为拓扑中的光交换机总数目, L_c 为控制器 C_j 连接的所有光交换机的负载, L_s 为拓扑网络中所有光交换机的总负载。

本文通过贝叶斯网络预测 SDON 控制器的拥塞水平,利用控制器相关参数(如控制器负载 L_c 、延迟 D 、光交换机的迁移次数 N 、吞吐量 T 和控制器负载级别 C)^[11] 预测控制器负载的拥塞程度。简化的贝叶斯结构如图 2 所示。控制器负载拥塞程度计算为:

$$\begin{aligned} P(C|L_c, D, T) &= P(L_c, D, T|C) \frac{P(C)}{P(L_c, D, T)} \\ &= \frac{P(L_c)P(D|L_c, C)P(T|L_c, C)}{(L_c, D, T)} \times \\ &\quad \sum_N \left(P(C|N) \frac{P(L_c|N)P(N)}{P(L_c)} \right) \\ &= \frac{P(D|L_c, C)P(T|L_c, C)}{P(L_c, D, T)} \times \\ &\quad \sum_N (P(C|N)P(L_c|N)P(N)) \end{aligned} \quad (5)$$

其中,基于每个拥塞级别,都对应一个预定义权重集。因此,预测 SDON 控制器负载拥塞程度之后,本文使用相应的权重集合 $w = \{w_1, w_2, w_3\}$,通过式(1)计算回报函数。基本思想是:对于更高级别的拥塞程度,使用更小的权重,通过调节参数权重大小以调整 SDON 控制器负载拥塞程度,进而实现 SDON 控制器负载均衡。




图 2 简化的贝叶斯网络结构

3 基于贝叶斯网络的 SDON 控制器自学习负载均衡设计

基于贝叶斯网络的 SDON 控制器自学习系统的设计流程如下:首先,控制器与光交换机建立通道,控制器通过通道控制和管理光交换机;其次,当光交换机收到一个光信号数据包且流表中没有匹配条目,光交换机会将数据包封装在 packet_in 消息发送给控制器,此时数据包会缓存在光交换机中等待处理;最后,控制器收到 packet_in 消息后,发送 flow_mod 消息向光交换机写一个流表项,且将 flow_mod 消息中的 buffer_id 值设置为 packet_in 消息中的 buffer_id 值。从而控制器向光交换机写入一条与数据包相关的流表项,并且指定该数据包按照该流表项的 action 列表处

理。其状态空间定义为给定的控制器集合, $\{C\}$ 为控制器集合, $\{S\}$ 为光交换机集合, 即 $S=\{S_1, S_2, S_i, \dots, S_{N_s}\}$ 。 S_i 为普通光交换机节点。基于贝叶斯网络的SDON控制器自学习架构如图3所示。




图3 基于贝叶斯网络的SDON控制器自学习架构

连接到控制器 C_j 的光交换机数量 N_{C_j} 为:

$$N_{C_j} = \sum_{S_i \in S, C_j \in C} b_{ij} \quad (6)$$

其中, b_{ij} 为光交换机与控制器之间的连接关系, 取值为0或1。控制器 C_j 的负载为从其连接的所有光交换机通过光信号传输的数据量, 即控制器连接的所有光交换机负载总和为:

$$L_{C_j} = \sum_S P(S_i) \quad (7)$$

其中, P 是数据包个数。SDON网络中的各个光交换机节点到控制器放置节点产生的传播延迟 D :

$$D = \frac{1}{V} \sum_{S_i \in S, C_j \in C} d(S_i, C_j) \quad (8)$$

其中, $d(S_i, C_j)$ 是从光交换机节点 i 到控制器节点 C_j 的链路长度, 节点总数为 v 。

本文所提算法的优化目标是最小化控制器负载的标准偏差值, 即负载均衡度为:

$$\text{Object: } \min \sqrt{\sum_{j=1}^{N_c} \left(L_{C_j} - \frac{1}{N_c} \sum_{j=1}^{N_c} L_{C_j} \right)^2} \quad (9)$$

为得到优化解, SDON控制器负载均衡问题固有的约束有延迟约束、成本约束、二元约束和代数约束。

◆延迟约束: 控制器到光交换机的最大延迟的最小值必须小于阈值 T_D 。

◆成本约束: 迁移光交换机的数量定义为迁移成本, 标记为 e , 最大值必须小于阈值 T_E 。

◆二元约束: 光交换机只与专用控制器相连。

◆代数约束: SDON中连接到控制器的光交换机

$$\text{总数 } N_s, \sum_{j=1}^{N_c} N_{C_j} = N_{S_0}$$

本文利用贝叶斯网络预测负载拥塞程度, 基于预测结果通过强化学习作出最优动作决策; 利用参数权重集合计算回报函数和值函数, 并在学习过程中利用反馈机制实现参数权重的自我调节, 调整控制器负载拥塞程度从而实现负载均衡, 提高控制器负载均衡效率。基于贝叶斯网络的SDON控制器自学习负载均衡算法伪代码如表1所示。

表1 基于贝叶斯网络的SDON控制器自学习负载均衡算法

1. POLICY INITIALISATION:
2. for $s \in S, a \in A$ do
3. Initialize the Q -table values $Q(s, a)$ and BN tables
4. end for
5. Determine current state s_c
6. previous state $s_p = s_c$, previous action $a_p = A_0$, next state s_r
7. repeat
8. Wait(Learning Interval)
9. POLICY UPDATE:
10. Read s_p, a_p, s_n, T, D .
11. Observe Virtual Network Performance and Determine reward for previous action $r(s, a)$
12. Predicting the Load Congestion Degree of the Controller by Bayesian Network (BN)
13. Change the load congestion degree of controller by adjusting parameter weights.
14. Update the Q -Table.
15. ACTION SELECTION:
16. Select action $a_c \in A$
17. Take the action, a_c and determine next state s' .
18. Set $s_p = s_c, a_p = a_c, s_r = s'$
19. until Learning is stopped

4 仿真分析及结果

4.1 算法仿真环境

本文采用的仿真语言为 python 3.6; 中央处理器为 Intel(R) Core(TM) i5-2450M CPU, 2.50 GHz; 安装内存为 4 GB 的 PC 机, 64 位 Win7 操作系统。实验拓扑采用具有较高认可度的 NSFNET 网络拓扑图, 如图4所示(图中链路中的数据为(代价, 延迟))。设置该网




图4 NSFNET网络拓扑图

络拓扑包含3个控制器和11个光交换机。11个光交换机按就近原则分别划分到3个核心控制器控制范围内。仿真参数如表2所示。在 Q -learning算法仿真过程中,学习参数 γ 与学习效率 α 在定值0.9与0.7时,算法收敛性最好。因此,基于贝叶斯网络的SDON控制器自学习负载均衡算法仿真将学习参数 γ 与学习效率 α 设为定值0.9与0.7。仿真过程中光交换机迁移次数 N 取值范围为1~22次,到达22次时控制器至负载均衡状态。仿真过程中通过参数延迟 D 、控制器负载 L_c 以及吞吐量 T 预测控制器负载拥塞程度,进而调整参数权重 w_1 、 w_2 、 w_3 的大小,使控制器负载拥塞程度最小化,实现控制器负载均衡。拓扑中每个控制器所承受的负载均有限,其负载变化超过自身所承受范围时,需选择最优策略,将周围其它核心控制器连接的光交换机迁移至该核心控制器,进行SDON控制器负载均衡。同理,其它核心控制器发生超负载情况时,该核心控制器连接的光交换机也可迁移至其它核心控制器,进行SDON控制器负载均衡。在使用本文算法模拟过

表2 仿真参数

类型	数值
学习参数 γ	0.9
学习效率 α	0.7
参数权重 w_1 、 w_2 、 w_3	依据实际情况调整至负载均衡
光交换机迁移次数 N	1~22
仿真时间	50 s
控制器数目 N_c	3
光交换机数目 N_s	10
拓扑节点总数 v	13
吞吐量 T	20~80 Mb/s

程中,为保证模拟数据的可靠性,本文进行了多次重复模拟算法,排除无关因素的干扰,并记录相关模拟数据。

4.2 迁移过程中的时延变化分析

本文将基于贝叶斯网络的SDON控制器自学习负载均衡算法与文献[10]中基于 Q -learning的SDON控制器负载均衡算法过程中的平均时延变化进行对比,其模拟结果如图5所示。可以看出,随光交换机迁移次数的增多,光交换机到控制器的平均时延都随之减少,且提出的基于贝叶斯网络的SDON控制器自学习负载均衡算法明显优于 Q -learning算法。随光交换机迁移次数的增多,可计算出 Q -learning算法的光交换机到控制器的平均时延的平均值为1.9825,而提出的算法的光交换机到控制器的平均时延的平均值为0.4976,其所用平均时延的平均值降低了74.9%。说明本文提出的基于贝叶斯网络的SDON控制器自学习负载均衡算法在时延上远远优于 Q -learning算法,很好地提高了SDON控制器负载均衡效率。




图5 光交换机的迁移次数对平均时延的影响

4.3 迁移过程中的负载均衡度变化分析

本文模拟了光交换机迁移次数的变化对控制器负载均衡度的影响,对比分析了光交换机迁移次数变化时 Q -learning算法与提出的基于贝叶斯网络的SDON控制器自学习负载均衡算法的负载均衡度的变化,其模拟结果图6所示。可以看出,随光交换机迁移次数的增加, Q -learning算法与提出的算法的负载均衡度都随之减小。在整个模拟过程中,随迁移次数的增多, Q -learning算法的曲线收敛速度慢,曲线收敛值为0.672,而提出的算法的曲线收敛值为0.545,相比 Q -learning算法,降低了19%。模拟过程中计算出 Q -learning算法的负载均衡度的平均值为 1.918×10^2 kb/s,而提出的算法引入了贝叶斯网络进行预测控制器负载拥塞程度,进一步结合 Q -learning算法更快




图6 光交换机迁移次数对控制器负载均衡度的影响

地进行控制器负载均衡,因此其负载均衡度的平均值为 1.391×10^2 kb/s,相比 Q -learning 算法,降低 27.5%。由此可见,本文提出的算法曲线收敛速率更快、收敛值更小,负载均衡程度更好,更好地实现了控制器负载均衡功能。

4.4 迁移过程中平均延迟随负载均衡度的变化分析

本文记录了提出的基于贝叶斯网络的 SDN 控制器自学习负载均衡算法在每次迁移之后的 SDN 控制器负载均衡度,以及每次迁移之后的光交换机到控制器的平均时延,其影响如图 7 所示。可以看出,控制器负载均衡度越小,其对应的光交换机到控制器的平均时延也随之越小, Q -learning 算法的光交换机到控制器的平均时延的平均值为 1.471 ms,而提出的平均时延的平均值为 0.296 ms,相比 Q -learning 算法降低了 73%。对比分析曲线也易看出,本文提出的算法远优于 Q -learning 算法。




图7 控制器负载均衡度对平均时延的影响

5 结束语

本文提出了一种基于贝叶斯网络的 SDN 控制器自学习负载均衡算法,贝叶斯网络用于预测 SDN 控制器负载拥塞程度,依据预测结果结合强化学习算法作出最优动作策略,实现 SDN 控制器负载均衡,并且解决了单独使用 Q -learning 算法易使 Q 值陷入局部最大的问题。算法仿真模拟结果表明:与 Q -learning 算法相比,本文提出的算法中光交换机迁移时的平均时延降低了 74.9%,SDN 控制器负载均衡度的平均值与其收敛值分别降低了 27.5%和 19%。本文算法有效降低了光交换机到控制器的平均时延和控制器负载均衡度,在很好地实现了控制器负载均衡功能的基础上,更快地提高了控制器负载均衡效率。

参考文献:

- [1] 纪越峰,张杰,赵永利. 软件定义光网络(SDN)发展前瞻[J]. 电信科学,2014(8):19-22.
- [2] 梁思远,杨武军. SDN 中路径建立和资源分配研究 [J]. 光通信技术,2017,41(9):9-12.
- [3] 李忠军. 5G 时代背景下 SDN 智能光传输网络研究 [J]. 中国新通信,2018,20(14):130-135.
- [4] THYAGATURU A, MERCIAN A, MCGARRY M P, et al. Software Defined Optical Networks (SDONs): A Comprehensive Survey [J]. IEEE Communications Surveys & Tutorials, 2015, 18(4): 2738-2786.
- [5] CAO Xiaoyuan, YOSHIKANE N, POPESCU I, et al. Software-Defined Optical Networks and Network Abstraction With Functional Service Design [Invited][J]. IEEE/OSA Journal of Optical Communications & Networking, 2017, 9(4): 65-75.
- [6] 李堃,欧清海,刘柱,等. 基于控制器集群的 SDN 多域互联互通技术[J]. 光通信技术,2017,41(9):13-16.
- [7] WANG K, WONG W C, CHAI T Y. A MANET routing protocol using Q-learning method integrated with Bayesian network[C]//2010 IEEE International Conference on Communication Systems, November 21-23, 2012, Singapore, Singapore. Piscataway: IEEE, 2012: 270-274.
- [8] KIM S, SON J, TALUKDER A, et al. Congestion prevention mechanism based on Q-learning for efficient routing in SDN [C]// International Conference on Information NETWORKING, January 13-15, 2016, Kota Kinabalu, Malaysia. Piscataway: IEEE Computer Society, 2016: 124-128.
- [9] 姚娜,范红. 面向流媒体业务的软件定义光网络负载均衡研究[J]. 光通信技术,2017,41(12):9-12.
- [10] MIN Z, HUA Q, ZHAO J. Dynamic switch migration algorithm with Q-learning towards scalable SDN control plane [C]// International Conference on Wireless Communications and Signal Processing (WCSP), October 11-13, 2017, Nanjing, China. Piscataway: IEEE, 2017: 1-4.
- [11] 王丽霞,曲桦,赵季红,等. 软件定义网络中应用二值粒子群优化的控制器部署策略[J]. 西安交通大学学报,2015(6):67-71.