

第 5 章 增强交换网络健壮性

项目背景

中山大学电子工程系、计算机科学技术系在学院改制前,都是独立建制学院,分别建有独立的网络,各学院早期规划网络拓扑如图 5-1 所示。




图 5-1 各独立学院早期网络拓扑

在院系改制中,学校把原电子工程系、计算机科学技术系合并成一个综合性的计算机科学技术学院。为整合教学资源,对原有院系的网络进行了改造和整合。

项目分析

网络中由于单线链路容易造成网络故障,因此在网络规划中,需要增加网络的备份和冗余,增加网络的稳定性。

冗余链路的作用是,数据在双链路同时传输,确保在一条线路出现故障的情况下,网络不会瘫痪,冗余链路可以保障数据不会因为某条单一链路的故障而中断。

改造后的网络,把原来各系分隔的网络联成一体,升级学院主干网络,整合各学院网络资源。为保证网络的稳定性,在主干网络改造过程中,增加网络冗余。

首先在网络核心增加了一台三层设备,使用双链路形成网络的冗余备份。其次,在骨干链路上,为增加网络的带宽,使用链路聚合技术,提升骨干链路的高带宽。

如图 5-2 所示网络拓扑,是改造后的学院新网络,图中虚线部分圈出的区域,是本节知识和技术主要的应用场景。




图 5-2 增加网络冗余的网络

通过本章的学习,读者将能够了解如下内容。

- (1) 掌握生成树协议 STP、RSTP。
- (2) 熟悉多生成树协议 MSTP。
- (3) 掌握链路聚合协议 IEEE 802.3ad。

5.1 生成树协议概述

随着交换技术在网络中的广泛应用,保障各种网络终端设备之间正常通信,成为一项重要的任务。绝大多数情况下,在交换网络中针对骨干链路,均采用多条链路连接以形成冗余链路备份,保证不会因为骨干链路上的单点故障,影响正常网络之间的通信。

5.1.1 交换网络中的冗余链路

在由多台交换机设备组成的交换网络环境中,通常都使用一些备份连接,以提高网络的健全性、稳定性,这些备份连接也叫备份链路、冗余链路等。典型的备份连接如图 5-3 所示,交换机与交换机的端口之间的链路形成一个闭合环,就是一个备份连接。




图 5-3 交换网络中的冗余链路

在主链路出现故障时,备份链路自动启用,从而提高网络的整体可靠性。在骨干网络

中,使用冗余备份连接,能够为交换网络带来健全性、稳定性和可靠性等好处。但是备份链路由于使用了冗余,容易使网络存在环路。一方面,环路链路为网络带来了网络稳定性;另一方面,环路链路也为网络带来很多严重问题,如广播风暴、多帧复制及 MAC 地址表的不稳定等。

5.1.2 冗余链路带来的网络影响

在局域网组建和维护过程中,为了提高骨干网络的链路连接的可靠性,经常需要提供冗余链路。冗余可以防止整个交换网络不会因为单点故障而造成网络中断;但它也会带来一些网络干扰问题,如广播风暴、多重帧复制,以及 MAC 地址表的不稳定性。

1. 广播风暴

二层交换机在接收到未知数据帧或者广播帧时,将执行泛洪操作,将该数据帧广播给除自己之外的所有二层端口。当网络中存在桥接和环路时,这样的泛洪就容易产生广播风暴。广播风暴(大量的泛洪帧)可能会迅速导致网络中断,如图 5-4 所示。




图 5-4 广播风暴示例

在较大型网络中,当大量广播流(如 MAC 地址查询 ARP)同时在网络中传播时,便会发生数据帧的碰撞。而当网络试图缓解这些碰撞,并重传更多的数据帧时,结果会导致全网的可用带宽减少,并最终使得网络失去连接而瘫痪,这一过程被称为广播风暴。

在一个较大规模的交换网络中,由于拓扑结构的复杂性,会有许多大大小小的环路产生。由于以太网第二层协议中,均没有控制环路机制,因此,各个小型环路产生广播风暴,将不断扩散到全网中,造成整个网络瘫痪。所以广播风暴是发生在二层网络中灾难性的故障。

而在如图 5-5 所示大型交换网络中,可能存在多个环路。在这样的网络中,所生成的广播帧的数量,可能会在几秒钟之内,以指数形式迅速增长,网络会变得不堪重负。

2. 多重帧的复制

交换机在接收到不确定单播帧时(MAC 地址表没有目的地址记录),将执行泛洪操作。这意味着在环路中,一个单播帧在传输中被复制为多个副本。

如图 5-6 所示,网络中的终端设备 X 主机,发出一个目的 MAC 地址为 Y 的单播帧到交换机 A。假若交换机 A 的 MAC 地址表查询不到 Y 的记录,该数据帧会被交换机 A 的接口广播至交换机 B,再广播至路由器 Y。这样,路由器 Y 将接收到多重来自计算机 X 的复制帧,帧的多重复制会浪费有限的网络带宽。




图 5-5 冗余链路中的桥接环路




图 5-6 多重帧的复制

3. MAC 地址表的不稳定

两台交换机在接收到该数据帧后,就会以泛洪的形式从端口 1 转发出该帧,这样它们将会在端口 1 再次接收到对方交换机发送的该帧,交换机将再次把计算机 X 的 MAC 地址和端口 1 建立关联(刷新 MAC 地址记录)……这时,交换机本身无法判断出计算机 X,究竟是连接在交换机的端口 0 上还是端口 1 上?

这个流程将会一直重复下去,导致每台交换机的 MAC 地址表被多次刷新,处于动荡状态,两台交换机的 MAC 地址表都将变得不稳定,如图 5-7 所示。这种持续的更新、刷新过程,会严重耗用内存资源,影响该交换机的交换能力。

MAC 地址表的不稳定将严重影响网络性能,同时降低整个网络的运行效率。严重时,将耗尽整个网络资源,并最终造成网络瘫痪。




图 5-7 MAC 地址表不稳定

5.2 生成树协议介绍

为了能确保网络连接的可靠性和稳定性,在骨干网络组建过程中,需要为骨干网络提供冗余链路连接,局域网中的冗余链路提高了网络连接的可靠性。如果主链路出现故障,就启用备份链路。但是,如果交换机不知道如何处理冗余环路带来的一系列问题,将造成网络中出现广播风暴等现象,并导致网络瘫痪。

为了保持一个冗余网络的安全优势,同时防止因为环路所导致的各种问题,网络中的交换机设备必须具有下列功能。

- (1) 发现环路的存在;
- (2) 将冗余链路中的一条链路设为主链路,其他设为备用链路;
- (3) 只通过主链路交换流量;
- (4) 定期检查链路的状况;
- (5) 如果主链路发生故障将流量自动切换到备用链路。

为了解决冗余链路引起的问题,IEEE 组织通过了 IEEE 802.1d 协议,即生成树协议(Spanning Tree Protocol,STP),生成树协议很好地完成了这些要求。生成树 STP 协议的基本思想十分简单,就是在网络组建过程中,构建一个树状结构、无环的网络。自然生长的树不会出现环路,如果网络也能够像树一样构建,也不会出现环路。

在具有冗余结构的网络中,生成树 IEEE 802.1d 协议通过在交换机上运行一套复杂的算法,使冗余端口置于“阻塞状态”。使得网络中的计算机在通信时,只有一条链路生效。而当这个链路出现故障时,IEEE 802.1d 协议将会重新计算出网络的最优链路,将处于“阻塞状态”的端口重新打开,保障网络正常通信,从而确保网络连接稳定可靠。

在生成树协议发展过程中,旧的缺陷不断被克服,新的特性不断被开发出来。按照功能点的改进情况,生成树协议的发展过程经历过以下三代革新。

第一代生成树协议:STP/RSTP。

第二代生成树协议:PVST/PVST+。

第三代生成树协议:MISTP/MSTP。

5.2.1 生成树协议

STP 协议的主要功能就是解决由于网络的备份链接所产生的环路问题。

STP 最初由美国数字设备公司(Digital Equipment Corp,DEC)开发,后经过电气电子工程师学会(Institute of Electrical and Electronics Engineers,IEEE)修改,最终规范为相应的 IEEE 802.1d 标准。

STP 的主要思想是:当网络中存在备份链路时,只允许主链路激活,如果主链路因故障而被断开后,备用链路才会被打开。

生成树协议检测到网络上存在环路时,自动启用算法关闭一个端口,断开环路链路。当交换机间存在多条链路时,生成树算法只启动最主要的一条链路连接,而将其他链路都阻塞

掉,将这些链路变为备用链路。当主链路出现问题时,生成树协议则自动启用备用链路,接替主链路工作,保障骨干网络的连通,不需要人工干预。

为保障生成树协议的正常运行,STP 中定义了根交换机(Root Bridge)、根端口(Root Port)、指定端口(Designated Port)等,目的就在于通过路径开销(Path Cost)计算,构造树状结构的网络,达到阻塞冗余环路的目的,同时实现链路备份和路径最优化。

STP 的本质就是利用图论中的生成树算法,对网络的物理结构不进行改变,而通过阻塞某些交换机端口,在逻辑上切断环路的方法,提取连通图,构建一个树状网络结构,以解决网络环路所造成的严重后果。

1. 网桥协议数据单元

要实现这些功能,交换机之间必须要进行一些信息的交流,这些信息交流单元就称为网桥协议数据单元(Bridge Protocol Data Unit,BPDU)。

网桥协议单元 BPDU 帧是一种二层报文,其目的 MAC 是多播地址 01-80-C2-00-00-00。所有支持 STP 的交换机,都会接收并处理收到的 BPDU 报文。该报文的数据区里携带了用于生成树计算的所有有用的信息。交换机通过交换 BPDU 来获得建立最佳树状拓扑结构所需的信息。生成树协议运行时,交换机使用共同的组播地址来发送 BPDU。

BPDU 数据帧的报文结构组成如图 5-8 所示。

0	7	15	23	31
协议ID(0)		版本号(0)	BPDU类型	
标志				
根桥ID(8B:优先级2B,MAC地址6B)				
根桥ID(8B:优先级2B,MAC地址6B)				
根路径费用(4B)				
发送网桥ID(8B)				
发送网桥ID(8B)				
端口ID (2B)		消息年龄 (报文老化时间)		
信息年龄 (生存期,2B)		根Hello时间		
转发时延 (2B)				

图 5-8 BPDU 报文结构

(1) 版本号: 00(IEEE 802.1d STP)、02(IEEE 802.1w RSTP)。

(2) 类型: 00(配置 BPDU)。其他常见的代码: 80 表示 TCA;10 表示 NTC;01 表示 TC;81 表示 TCA&TC。

(3) Root ID: 根交换机 ID。

(4) Root Path Cost: 到达根的路径开销。

(5) Bridge ID: 交换机 ID=交换机优先级+交换机 MAC 地址。

(6) Port ID: 发送 BPDU 的端口 ID=端口优先级+端口编号。

(7) Hello Time: 定期发送 BPDU 的时间间隔。

(8) Max-Age Time: 保留对方 BPDU 消息的最长时间。

(9) Forward-Delay Time: 发送延迟,端口状态改变的时间间隔。

2. 根交换机选举

冗余网络中交换机在运行生成树协议时,首先要进行根交换机的选举。根交换机的选举通过 BPDU 帧完成,选举依据是:交换机优先级和交换机 MAC 地址组合成的交换机 ID (Bridge ID),交换机 ID 最小的交换机将成为网络中的根交换机。

当冗余网络中的一台交换机的一个端口接收到高优先级的 BPDU(更小的 Bridge ID, 更小的 Root Path Cost 等),就在该端口保存这些信息,同时,向所有端口更新并传播信息。如果收到比自己低优先级的 BPDU,交换机就丢弃该信息。

在如图 5-9 所示的网络场景中,各交换机都默认启动生成树协议,所有交换机的默认优先级都一样(默认优先级是 32 768),因此,MAC 地址最小的交换机将成为根交换机。因而计算出左边交换机为根,它的所有端口的角色都成为指定端口,进入转发状态,右边的交换机其中一个端口有可能会被阻塞。




图 5-9 根交换机的选举

3. STP 选举过程

STP 通过相互之间交换 BPDU 帧中携带的消息,进行生成树的选举过程,主要的过程如下所示。

- (1) 网络中选择了一台交换机为根交换机(Root Bridge)。
- (2) 每台交换机都计算出了到根交换机的最短路径。
- (3) 除根交换机外的每台交换机都有一个根端口(Root Port),即提供最短路径到 Root Bridge 的端口。
- (4) 每个 LAN 都有指定交换机(Designated Bridge),位于该 LAN 与根交换机之间的最短路径中。指定交换机和 LAN 相连的端口称为指定端口(Designated Port)。
- (5) 根端口和指定端口(Designated Port)进入转发(Forwarding)状态。
- (6) 其他的冗余端口就处于阻塞(Discarding)状态。

1) 根交换机

首先进行根交换机的选举,根交换机的选举如上所示。如图 5-10 所示,假设在交换机优先级都相同的情况下,经过比较,交换机 SW1 的 MAC 地址最小,因此交换机 SW1 被选举为根交换机。

2) 根端口

接下来,其他交换机将各自选择一条“最粗壮”(高带宽)的树枝(链路),作为非根交换机到根交换机的最短路径,其相应端口的角色就成为根端口,根端口直接进入转发状态,不阻塞。

假设在图 5-10 中,交换机 SW2 和交换机 SW1、SW3 之间的链路是千兆链路,而交换机




图 5-10 STP 的选举工作过程

SW1 和 SW3 之间的链路是百兆链路,通过计算可以得出:交换机 SW3 从端口 1 到根交换机 SW1 的路径开销的值是 19 (百兆链路的路径开销默认值为 19);而从交换机 SW3 端口 2→交换机 SW2→根交换机 SW1 的路径开销是 8(千兆链路的路径开销默认值为 4,则 $4+4=8$),因此该条链路成为最短路径,则交换机 SW3 的端口 2 成为根端口(非根交换机到根交换机的最短路径接口),进入转发状态。

同理,交换机 SW2 的端口 2 到根交换机 SW1 也具有最短路径,成为根端口,进入转发状态。

3) 路径开销

这里的路径开销计算,主要是依据交换机的端口速率计算出该端口路径开销。

网络中每台交换机端口都有一个根路径开销(Root Path Cost),根路径开销是某交换机到根交换机所经过的路径开销的总和。在计算出最短根路径开销后,交换机对应的端口成为根端口,进入转发状态。

如表 5-1 所示,列出了不同标准的路径开销取值范围。

表 5-1 路径开销


带 宽	IEEE 802.1d	IEEE 802.1w
10Mb/s	100	2 000 000
100Mb/s	19	200 000
1000Mb/s	4	20 000

在图 5-11 中,交换机 B 和根交换机 R、交换机 C 之间的链路是百兆链路,交换机 A 和根交换机 R、交换机 C 之间的链路是十兆链路,各交换机端口路径开销的默认值如图 5-11 所示。对于交换机 C 而言,通过交换机 A 到达根交换机的路径开销是 $2\,000\,000+2\,000\,000=4\,000\,000$,通过交换机 B 到达根交换机的路径开销是 $200\,000+200\,000=400\,000$,显然 C—B—R 成为最短路径。同理,对于交换机 A 而言,A—C—B—R 为最短路径。

4) 指定端口

根端口是各台交换机通往根交换机的根路径开销最低的端口,若有多个端口具有相同的根路径开销,则端口标识符小的端口为根端口。

此外,生成树协议还规定,在每个 LAN 中,都有一台交换机被称为指定交换机



(Designated Bridge), 它是该 LAN 中与根交换机连接而且根路径开销最低的交换机。指定交换机和 LAN 连接的端口被称为指定端口 (Designated Port), 指定端口不要阻塞。

如果指定交换机中有两个以上的端口连在这个 LAN 上, 则具有最高优先级的端口被选为指定端口。按照生成树协议规定, 根交换机上的所有端口都默认是指定端口。

交换机完成生成树计算后, 所有根端口和指定端口进入转发 (Forwarding) 状态, 其他的冗余端口则处于阻塞 (Discarding) 状态。

以图 5-12 为例, 网络中所有的链路带宽均为百兆链路, 所有交换机的优先级均相同, STP 的工作过程如下。




图 5-12 根端口和指定端口的确认

- (1) 通过比较交换机 MAC, 交换机 Z 成为根交换机, 它的端口 0 默认成为指定端口。
- (2) 通过计算链路最短根路径开销, 交换机 X 和 Y 的端口 0 成为根端口。
- (3) 交换机 X 和交换机 Y 的端口 1, 都同时连接在同一个 LAN 上, 通过比较优先顺序, 交换机 X 的端口 1 成为指定端口。
- (4) 所有根端口和指定端口进入转发状态, 其他端口 (交换机 Y 的端口 1) 被禁用, 进入阻塞状态。

这样, 当根交换机确定之后, 通过最短根路径开销的优先顺序比较, 根端口和指定端口被确定下来, 之后一棵树就生成了。

4. STP 的端口状态和拓扑变化

在一个启用 STP 的网络中, 所有交换机端口在启动之后, 都将经历阻塞状态以及侦听和学习这两种过渡状态。

正确配置的端口最终会稳定在转发状态或者阻塞状态, 处于转发状态的端口提供了到

达根交换机的最短路径开销,处于阻塞状态的端口则作为备份链路随时待命。当交换机识别出网络拓扑变化时,交换机端口的状态变化过程如图 5-13 所示。




图 5-13 STP 的端口状态

其中,在生成树收敛的过程中,STP 各端口状态如下。

- (1) 阻塞状态(Blocking): 不转发数据帧、接收 BPDU。
- (2) 侦听状态(Listening): 不转发数据帧、侦听数据帧。
- (3) 学习状态(Learning): 不转发数据帧、学习地址。
- (4) 转发状态(Forwarding): 转发数据帧、学习地址。
- (5) 禁止状态(Disable): 不转发数据帧、不接收 BPDU。

STP 初始化时,所有端口处于阻塞状态,当交换机启用时会把自己作为根交换机而处于侦听阶段;或者在 Max-Age Time 内没有收到新的 BPDU,交换机也会把端口从阻塞状态转换到侦听状态。

在侦听状态下,交换机不传送用户数据。在此状态下,交换机完成根交换机的选举,确认根端口和指定端口。经过 15s 转发延迟之后,如果有端口被确定为根端口或指定端口,则它将进入学习阶段;否则,仍然转回阻塞阶段。

为了减少数据转发前的泛洪数量,防止临时环路出现,默认情况下学习状态也是转发延迟时间 15s。当学习状态结束后,那些依然是根端口或指定端口的将进入转发状态,从而“实时”地适应网络拓扑的变化。

5.2.2 快速生成树协议

1. STP 的问题

早期的 STP 解决了交换链路冗余带来的广播风暴等问题,但在拓扑发生改变时,新的 BPDU 帧要经过一定的时延,才能传播到整个网络,这个时延称为 Forward Delay,协议默认为 15s。在所有交换机收到这个变化的消息之前,若旧拓扑结构中部分交换机由于收敛速度慢,仍处于转发状态的端口,还没有发现自己应当在新的拓扑中停止转发,则可能存在临时环路。

在默认状态下,BPDU 帧的报文周期为 2s,最大保留时间为 20s,端口状态改变(由侦听