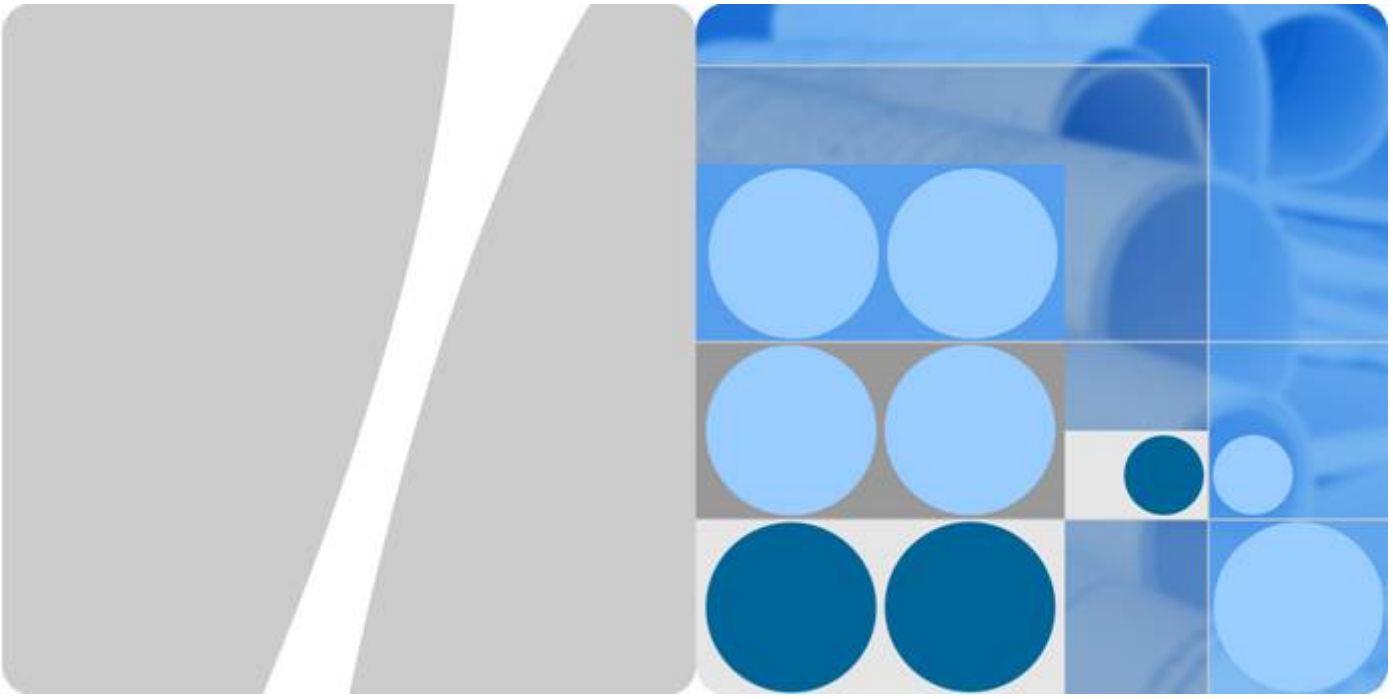

Huawei AR3200 系列企业路由器

V200R002C01

特性描述-MPLS

文档版本　01

发布日期　2012-04-20

华为技术有限公司

商标声明


和其他华为商标均为华为技术有限公司的商标。
本文档提及的其他所有商标或注册商标，由各自的所有人拥有。

注意

您购买的产品、服务或特性等应受华为公司商业合同和条款的约束，本文档中描述的全部或部分产品、服务或特性可能不在您的购买或使用范围之内。除非合同另有约定，华为公司对本文档内容不做任何明示或默示的声明或保证。

由于产品版本升级或其他原因，本文档内容会不定期进行更新。除非另有约定，本文档仅作为使用指导，本文档中的所有陈述、信息和建议不构成任何明示或暗示的担保。

华为技术有限公司

地址： 深圳市龙岗区坂田华为总部办公楼 邮编：518129

网址： http://www.huawei.com

客户服务邮箱： support@huawei.com

客户服务电话： 4008302118

前 言

读者对象

本文档针对 AR3200 支持的 MPLS 的相关特性，介绍 AR3200 支持的 MPLS 特性以及协议。包括 MPLS 基本概念和 MPLS 转发、MPLS LDP 的基本原理和特性。

通过阅读本文档，可以更好地理解和掌握 AR3200MPLS 特性产生背景、基本概念、基本原理、参考标准等。

本文档主要适用于以下工程师：

- 网络规划工程师
- 调测工程师
- 数据配置工程师
- 系统维护工程师

符号约定

在本文中可能出现下列标志，它们所代表的含义如下。

符号	说明
危险	以本标志开始的文本表示有高度潜在危险，如果不能避免，会导致人员死亡或严重伤害。
警告	以本标志开始的文本表示有中度或低度潜在危险，如果不能避免，可能导致人员轻微或中等伤害。
注意	以本标志开始的文本表示有潜在风险，如果忽视这些文本，可能导致设备损坏、数据丢失、设备性能降低或不可预知的结果。
窍门	以本标志开始的文本能帮助您解决某个问题或节省您的时间。
说明	以本标志开始的文本是正文的附加信息，是对正文的强调和补充。

命令行格式约定

格式	意义
粗体	命令行关键字（命令中保持不变、必须照输的部分）采用**加粗**字体表示。
斜体	命令行参数（命令中必须由实际值进行替代的部分）采用*斜体*表示。
[ ]	表示用“[ ]”括起来的部分在命令配置时是可选的。
{ x | y | ... }	表示从两个或多个选项中选取一个。
[x | y | ...]	表示从两个或多个选项中选取一个或者不选。
{ x | y | ... } *	表示从两个或多个选项中选取多个，最少选取一个，最多选取所有选项。
[x | y | ...] *	表示从两个或多个选项中选取多个或者不选。
&<1-n>	表示符号&前面的参数可以重复 1 ～ n 次。
#	由“#”开始的行表示为注释行。

修订记录

修改记录累积了每次文档更新的说明。最新版本的文档包含以前所有文档版本的更新内容。

文档版本 01 (2012-04-20)

第一次正式发布。

目 录

1 MPLS 基础

关于本章

1.1 介绍

MPLS 的起源

90 年代中期，基于 IP 技术的 Internet 快速普及。但由于硬件技术存在限制，基于最长匹配算法的 IP 技术必须使用软件查找路由，转发性能低下，因此 IP 技术的转发性能成为当时限制网络发展的瓶颈。

为了适应网络的发展，ATM（Asynchronous Transfer Mode）技术应运而生。ATM 采用定长标签（即信元），并且只需要维护比路由表规模小得多的标签表，能够提供比 IP 路由方式高得多的转发性能。然而，ATM 协议相对复杂，且 ATM 网络部署成本高，这使得 ATM 技术很难普及。

传统的 IP 技术简单，且部署成本低。如何结合 IP 与 ATM 的优点成为当时热门话题。多协议标签交换技术 MPLS（Multiprotocol Label Switching）就是在这种背景下产生的。

MPLS 最初是为了提高路由器的转发速度而提出的。与传统 IP 路由方式相比，它在数据转发时，只在网络边缘分析 IP 报文头，而不用在每一跳都分析 IP 报文头，节约了处理时间。

随着 ASIC（Application Specific Integrated Circuit）技术的发展，路由查找速度已经不是阻碍网络发展的瓶颈。这使得 MPLS 在提高转发速度方面不再具备明显的优势。但是 MPLS 支持多层标签和转发平面面向连接的特性，使其在 VPN（Virtual Private Network）、流量工程、QoS（Quality of Service）等方面得到广泛应用。

MPLS 概述

MPLS 位于 TCP/IP 协议栈中的链路层和网络层之间，用于向 IP 层提供连接服务，同时又从链路层得到服务。MPLS 以标签交换替代 IP 转发。标签是一个短而定长的、只具有本地意义的连接标识符，与 ATM 的 VPI/VCI 以及 Frame Relay 的 DLCI 类似。标签封装在链路层和网络层之间。

MPLS 不局限于任何特定的链路层协议，能够使用任意二层介质传输网络分组。

MPLS 起源于 IPv4（Internet Protocol version 4），其核心技术可扩展到多种网络协议，包括 IPv6（Internet Protocol version 6）、IPX（Internet Packet Exchange）、Appletalk、DECnet、CLNP（Connectionless Network Protocol）等。MPLS 中的“Multiprotocol”指的就是支持多种网络协议。

由此可见，MPLS 并不是一种业务或者应用，它实际上是一种隧道技术。这种技术不仅支持多种高层协议与业务，而且在一定程度上可以保证信息传输的安全性。

1.2 参考标准和协议

本特性的参考资料清单如下：

文档	描述	备注
RFC 3031	Multiprotocol Label Switching Architecture	-
RFC 3036	LDP Specification	-

文档	描述	备注
RFC 3032	MPLS Label Stack Encoding	-
RFC 3443	Time To Live (TTL) Processing in Multi-Protocol Label Switching (MPLS) Networks	-
RFC 3034	Use of Label Switching on Frame Relay Networks Specification	-
RFC 2702	Requirements for Traffic Engineering Over MPLS	-
RFC 3209	RSVP-TE: Extensions to RSVP for LSP Tunnels	-
RFC 2547	BGP/MPLS VPNs	-

1.3 可获得性

涉及网元

无

License 支持

无需获得 License 许可，均可获得该特性的服务。

版本支持

产品	最低支持版本
AR3200	V200R001C00

1.4 原理描述

1.4.1 MPLS 基本概念

MPLS 网络结构

MPLS 网络的典型结构如图 1-1，MPLS 网络的基本组成单元是标签交换路由器 LSR（Label Switching Router），由 LSR 构成的网络区域称为 MPLS 域（MPLS Domain）。位于 MPLS 域边缘、连接其它网络的 LSR 称为边缘路由器 LER（Label Edge Router），区域内部的 LSR 称为核心 LSR（Core LSR）。如果一个 LSR 有一个或多个不运行 MPLS 的相邻节点，那么该 LSR 就是 LER。如果一个 LSR 的相邻节点都运行 MPLS，则该 LSR 就是核心 LSR。

图 1-1 MPLS 网络结构

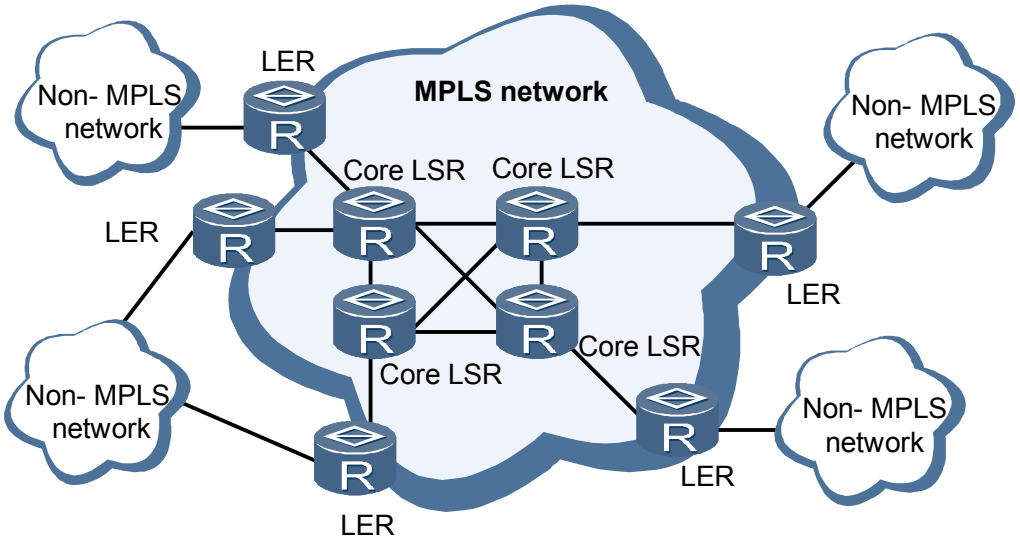

MPLS 基于标签进行转发。IP 包进入 MPLS 网络时，MPLS 入口的 LER 分析 IP 包的内容并且为这些 IP 包添加合适的标签，所有 MPLS 网络中的节点都是依据标签来转发数据的。当该 IP 包离开 MPLS 网络时，标签由出口 LER 删除。

IP 包在 MPLS 网络中经过的路径称为标签交换路径 LSP（Label Switched Path）。LSP 是一个单向路径，与数据流的方向一致。

图 1-2 MPLS LSP

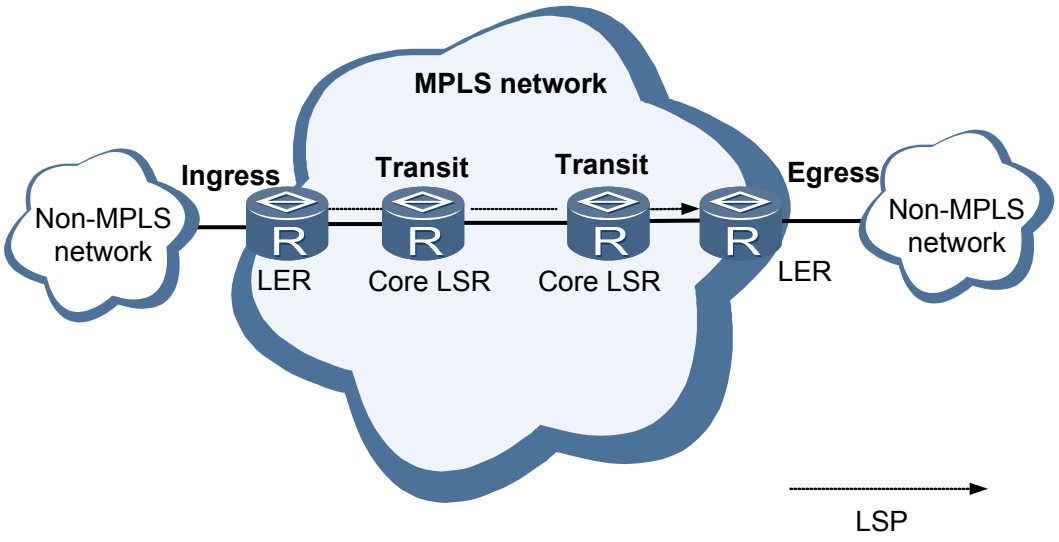

LSP 的起始节点称为入节点（Ingress）；位于 LSP 中间的节点称为中间节点（Transit）；LSP 的末节点称为出节点（Egress）。一条 LSP 可以有 0 个、1 个或多个中间节点，但有且只有一个入节点和出节点。

转发等价类

转发等价类 FEC（Forwarding Equivalence Class）是一组具有某些共性的数据流的集合。这些数据流在转发过程中被 LSR 以相同方式处理。

FEC 可以根据地址、业务类型、QoS 等要素进行划分。例如，在传统的采用最长匹配算法的 IP 转发中，到同一条路由的所有报文就是一个转发等价类。

标签

标签（Label）是一个短而定长的、只具有本地意义的标识符，用于唯一标识一个分组所属的 FEC。在某些情况下，例如要进行负载分担，对应一个 FEC 可能会有多个入标签，但是一台路由器上，一个标签只能代表一个 FEC。标签与 ATM 的 VPI/VCI 以及 Frame Relay 的 DLCI 类似，是一种连接标识符。

标签长度为 4 个字节，封装结构如图 1-3 所示。

图 1-3 MPLS 报文首部结构

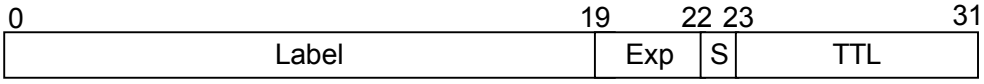

标签共有 4 个域：

- Label：20bit，标签值域。
- Exp：3bit，用于扩展。现在通常用做 CoS（Class of Service），其作用与 Ethernet802.1p 的作用类似。
- S：1bit，栈底标识。MPLS 支持多层标签，即标签嵌套。S 值为 1 时表明为最底层标签。
- TTL：8bit，和 IP 分组中的 TTL（Time To Live）意义相同。

标签封装在链路层和网络层之间。这样，标签能够被任意的链路层所支持。标签在分组中的封装位置如图 1-4 所示。

图 1-4 标签在分组中的封装位置

标签空间

标签空间就是指标签的取值范围。AR3200 实现中，标签空间划分如下：

- 0 ～ 15：特殊标签。特殊标签的详细介绍请参见表 1-1。
- 16 ～ 1023：静态 LSP 和静态 CR-LSP 共享的标签空间。
- 1024 以上：LDP、RSVP-TE、MP-BGP 等动态信令协议的标签空间。

  动态信令协议的标签空间不是共享的，而是独立且连续的，互不影响。

表 1-1 特殊标签

标签值	含义	描述
0	IPv4 Explicit NULL Label	表示该标签必须被弹出，且报文的转发必须基于 IPv4。如果出节点分配给倒数第二跳节点的标签值为 0，则倒数第二跳 LSR 需要将值为 0 的标签正常压入报文标签值顶部，转发给最后一跳。最后一跳发现报文携带的标签值为 0，则将标签弹出。0 标签只有出现在栈底时才有效。
1	Router Alert Label	只有出现在非栈底时才有效。类似于 IP 报文的“Router Alert Option”字段，节点收到 Router Alert Label 时，需要将其送往本地软件模块进一步处理。实际报文转发由下一层标签决定。如果报文需要继续转发，则节点需要将 Router Alert Label 压回标签栈顶。
2	IPv6 Explicit NULL Label	表示该标签必须被弹出，且报文的转发必须基于 IPv6。如果出节点分配给倒数第二跳节点的标签值为 2，则倒数第二跳节点需要将值为 2 的标签正常压入报文标签值顶部，转发给最后一跳。最后一跳发现报文携带的标签值为 2，则直接将标签弹出。2 标签只有出现在栈底时才有效。
3	Implicit NULL Label	倒数第二跳 LSR 进行标签交换时，如果发现交换后的标签值为 3，则将标签弹出，并将报文发给下最后一跳。最后一跳收到该报文直接进行 IP 转发或下一层标签转发。
4 ～ 13	保留	-
14	OAM Router Alert Label	MPLS OAM（Operation Administration & Maintenance）通过发送 OAM 报文检测和通告 LSP 故障。OAM 报文使用 MPLS 承载。OAM 报文对于 Transit LSR 和倒数第二跳 LSR（penultimate LSR）是透明的。
15	保留	-

标签栈

标签栈（Label stack）是指标签的排序集合。MPLS 报文支持同时携带多个标签，靠近二层首部的标签称为栈顶标签或外层标签；靠近 IP 首部的标签称为栈底标签，或内层标签。理论上，MPLS 标签可以无限嵌套。

图 1-5 标签栈

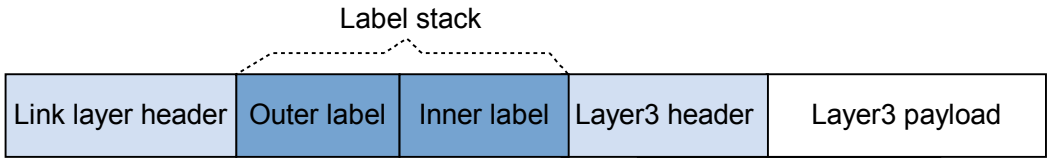

标签栈按后进先出（Last In First Out）方式组织标签，从栈顶开始处理标签。

标签操作类型

标签的操作类型包括标签压入（Push）、标签交换（Swap）和标签弹出（Pop），它们是标签转发的基本动作，是标签转发信息表的组成部分。

- Push：指当 IP 报文进入 MPLS 域时，MPLS 边界设备在报文二层首部和 IP 首部之间插入一个新标签；或者 MPLS 中间设备根据需要，在标签栈顶增加一个新的标签（即标签嵌套封装）。
- Swap：当报文在 MPLS 域内转发时，根据标签转发表，用下一跳分配的标签，替换 MPLS 报文的栈顶标签。
- Pop：当报文离开 MPLS 域时，将 MPLS 报文的标签去掉；或者 MPLS 倒数第二跳节点处去掉栈顶标签，减少标签栈中的标签数目。

倒数第二跳弹出

在最后一跳节点，标签已经没有使用价值。这种情况下，可以利用倒数第二跳弹出特性 PHP（Penultimate Hop Popping），在倒数第二跳节点处将标签弹出，减少最后一跳的负担。最后一跳节点直接进行 IP 转发或者下一层标签转发。

PHP 在 Egress 节点上配置。支持 PHP 的 Egress 节点分配给倒数第二跳节点的标签只有一种：

标签值 3：表示隐式空标签（implicit-null），这个值不会出现在标签栈中。当一个 LSR 发现自己被分配了隐式空标签时，它并不用这个值替代栈顶原来的标签，而是直接执行 Pop 操作。Egress 节点直接进行 IP 转发或下一层标签转发。

标签交换路由器

标签交换路由器 LSR（Label Switching Router）是指可以进行 MPLS 标签交换和报文转发的网络设备，也称为 MPLS 节点。LSR 是 MPLS 网络中的基本元素，所有 LSR 都支持 MPLS 协议。

LER

位于 MPLS 域边缘的 LSR 称为 LER（Label Edge Router）。如果一个 LSR 有一个不运行 MPLS 的相邻节点，那么该 LSR 就是 LER。

LER 负责对进入 MPLS 域的报文划分 FEC，并为这些 FEC 压入标签，进行 MPLS 转发。当报文离开 MPLS 域时弹出标签，恢复成原来的报文，再进行相应的转发。

标签交换路径

一个转发等价类在 MPLS 网络中经过的路径称为标签交换路径 LSP（Label Switched Path）。

LSP 在功能上与 ATM 和 Frame Relay 的虚电路相同，是从入口到出口的一个单向路径。

入节点、中间节点和出节点

标签交换路径 LSP 是一个单向路径，LSP 中的 LSR 可以分为：

- 入节点（Ingress）：LSP 的起始节点，一条 LSP 只能有一个 Ingress。
  Ingress 的主要功能是给报文压入一个新的标签，封装成 MPLS 报文进行转发。
- 中间节点（Transit）：LSP 的中间节点，一条 LSP 可能有多个 Transit。
  Transit 的主要功能是查找标签转发信息表，通过标签交换完成 MPLS 报文的转发。
- 出节点（Egress）：LSP 的末节点，一条 LSP 只能有一个 Egress。
  Egress 的主要功能是弹出标签，恢复成原来的报文进行相应的转发。

上游和下游

根据数据传送的方向，LSR 可以分为上游和下游。

- 上游：以指定的 LSR 为视角，根据数据传送的方向，所有往本 LSR 发送 MPLS 报文的 LSR 都可以称为上游 LSR。
- 下游：以指定的 LSR 为视角，根据数据传送的方向，本 LSR 将 MPLS 报文发送到的所有下一跳 LSR 都可以称为下游 LSR。

如图 1-6 所示，对于发往 192.168.1.0/24 的数据流来说，LSR-A 是 LSR-B 的上游节点，LSR-B 是 LSR-A 的下游节点。同理，LSR-B 是 LSR-C 上游节点。LSR-C 是 LSR-B 的下游节点。

图 1-6 上游和下游概念

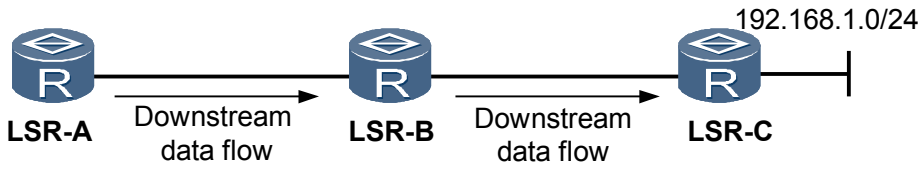

标签分发

将目的地址相同的分组报文划分为一个 FEC，然后从 MPLS 标签资源池中取出一个标签，分配给这个 FEC。LSR 记录该标签和 FEC 的对应关系，并将该对应关系封装成消息报文，通告给上游的 LSR，这个过程称为标签分发。

图 1-7 标签分发示意图

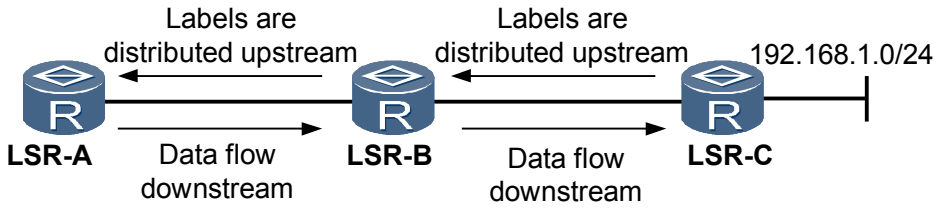

如图 1-7，LSR-B 和 LSR-C 对去往 192.168.1.0/24 的报文划分为一个 FEC，然后为该 FEC 分配标签，并向上游通告。因此标签是由下游分配的。

标签发布协议

标签发布协议是 MPLS 的控制协议（也可称为信令协议），负责 FEC 的分类、标签的分发以及 LSP 的建立和维护等一系列操作。

MPLS 可以使用多种标签发布协议，例如 LDP（Label Distribution Protocol）、RSVP-TE（Resource Reservation Protocol Traffic Engineering）和 MP-BGP（Multiprotocol Border Gateway Protocol）。

说明

AR3200 仅支持 LDP 作为 MPLS 的标签发布协议。

MPLS 的体系结构

MPLS 的体系结构由控制平面（Control Plane）和转发平面（Forwarding Plane）组成。

MPLS 体系结构如图 1-8。

图 1-8 MPLS 体系结构示意图

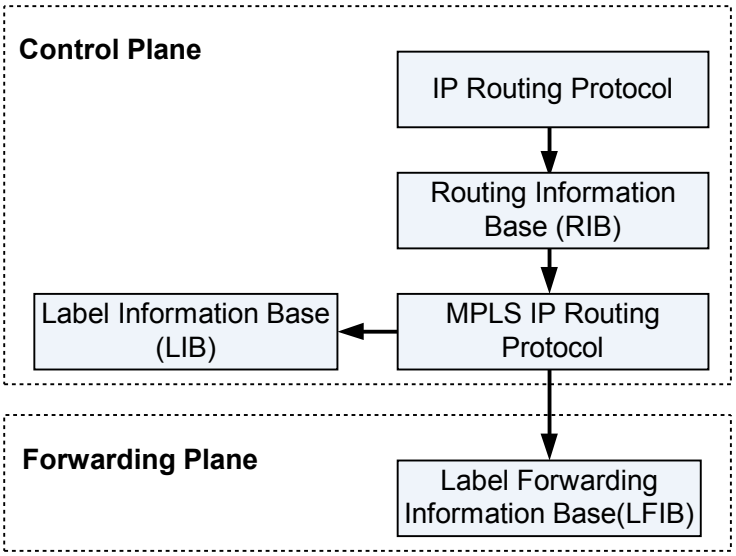

- 控制平面是无连接的，主要功能是负责标签的分配、标签转发表的建立、标签交换路径的建立、拆除等工作。
- 转发平面也称为数据平面（Data Plane），是面向连接的，可以使用 ATM、帧中继、Ethernet 等二层网络。转发平面的主要功能是对 IP 包进行标签的添加和删除，同时依据标签转发表对收到的分组进行转发。

1.4.2 LSP 的建立

LSP 的基本建立过程

MPLS 需要为报文事先分配好标签，建立一条 LSP，才能进行报文转发。

标签由下游分配，按从下游到上游的方向分发。如图 1-9，由下游 LSR 在 IP 路由表的基础上进行 FEC 的划分，并将标签分配给特定 FEC，再通过标签发布协议通知上游 LSR，以便建立标签转发表和 LSP。

图 1-9 LSP 建立

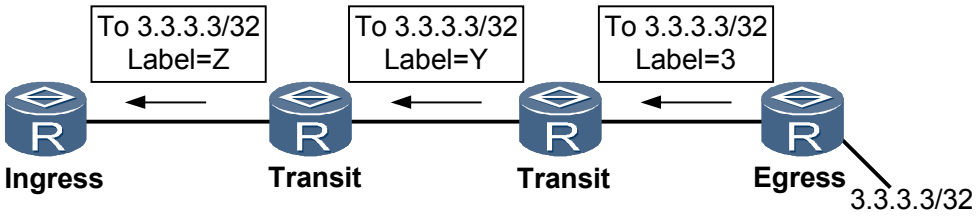

LSP 分为静态 LSP 和动态 LSP 两种。静态 LSP 由管理员手工配置，动态 LSP 则利用路由协议和标签发布协议动态建立。

静态 LSP 的建立

静态 LSP 是用户通过手工为各个转发等价类分配标签而建立的。手工分配标签需要遵循的原则是：上游节点出标签的值就是下游节点入标签的值。

由于静态 LSP 各节点上不能相互感知到整个 LSP 的情况，因此静态 LSP 是一个本地的概念。

- 配置静态 LSP 的入节点，且在出接口使能了 MPLS，如果路由可达，则静态 LSP 就为 UP 状态，无论是否有 Transit 节点或出节点。这里的“路由可达”的含义是本地路由表中存在与指定目的 IP 地址精确匹配的路由项（包括目的地址和下一跳都匹配）。
- 配置静态 LSP 的 Transit 节点，且在入接口和出接口使能了 MPLS，如果入接口和出接口的物理层及协议层状态为 Up，则该静态 LSP 就为 UP 状态，无论是否有入节点、出节点或其他 Transit 节点。
- 配置静态 LSP 的出节点，且入接口使能了 MPLS，如果入接口的物理层及协议层状态为 Up，则该静态 LSP 就为 UP 状态，无论是否有入节点或 Transit 节点。

说明

只有入节点的静态 LSP 的建立依赖于路由，中间节点和出节点无此限制。

静态 LSP 不使用标签发布协议，不需要交互控制报文，因此消耗资源比较小，适用于拓扑结构简单并且稳定的小型网络。但通过静态方式分配标签建立的 LSP 不能根据网络拓扑变化动态调整，需要管理员干预。

动态 LSP 的建立

动态 LSP 通过标签发布协议动态建立。MPLS 可以使用多种标签发布协议：

- LDP

  LDP 是专为标签发布而制定的协议。LDP 通过逐跳方式建立 LSP 时，利用沿途各 LSR 路由转发表中的信息来确定下一跳，而路由转发表中的信息一般是通过 IGP、BGP 等路由协议收集的。LDP 并不直接和各种路由协议关联，只是间接使用路由信息。

虽然 LDP 是专门用来实现标签分发的协议，但 LDP 并不是唯一的标签分发协议。通过对 BGP、RSVP 等已有协议进行扩展，也可以支持 MPLS 标签的分发。

- RSVP-TE

  资源预留协议 RSVP 是为 Integrated Service 模型而设计的，用于在一条路径的各节点上进行资源预留。RSVP 工作在传输层，但不参与应用数据的传送，是一种网络上的控制协议，类似于 ICMP。

  为了能够建立基于约束的 LSP，对 RSVP 协议进行了扩展。扩展后的 RSVP 信令协议称为 RSVP-TE 信令协议，主要用于建立 TE 隧道。它拥有普通 LDP LSP 没有的功能，如发布带宽预留请求、带宽约束、链路颜色和显式路径等。

- MP-BGP

  MP-BGP 是在 BGP 协议基础上扩展的协议。MP-BGP 引入 Community 属性，支持为 MPLS VPN 业务中私网路由和跨域 VPN 的标签路由分配标签。

说明

AR3200 仅支持 LDP 作为 MPLS 的标签发布协议。

1.4.3 MPLS 转发

基本概念

- Tunnel ID

  为了给使用隧道的上层应用（如 VPN、路由管理）提供统一的接口，系统自动为各种隧道分配了一个 ID，也称为 Tunnel ID。该 Tunnel ID 只是本地有效。

  Tunnel ID 的长度为 32 比特，不同类型的隧道，各字段的长度可能不同。Tunnel ID 的结构如图 1-10 所示。

图 1-10 Tunnel ID 的结构

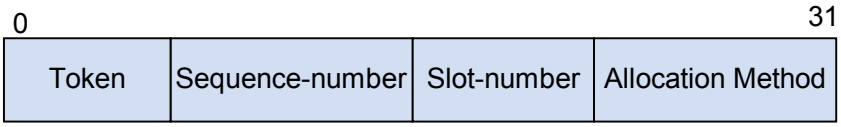

各字段含义如下：

表 1-2 Tunnel ID 各字段含义描述

字段	含义
Token	用于在 MPLS 转发表中查找指定的 MPLS 转发信息。Token 只是一个查找转发信息的索引号。
Sequence-Number	隧道 ID 的序列号。
Slot-Number	出接口槽位号，指定了实际发送报文的槽位。

字段	含义
Allocation Method	Token 的分配方式，包括： ● Global：所有隧道共用一个公共的全局空间，不可能存在两个相同的 token 值。 ● Global with reserved tokens：与 Global 方式基本相同。区别在于它会预留某些 Token 值不被隧道使用，即隧道的 Token 值起始于一个指定的数值。 ● Per slot：每一个槽位都有独立的 Token 空间。同一个槽位的 Token 值一定不同，不同槽位的 Token 值可能相同。 ● Per slot with reserved Tokens：与 Per slot 方式基本相同。区别在于它会预留某些 Token 值不被隧道使用，即隧道的 Token 值起始于一个指定的数值。 ● Per slot with different avail value：与 Per slot 方式基本相同。区别在于每个槽位的 Token 的取值范围不同。 ● Mixed：全局空间和每个槽位的空间都会被创建，然后根据出接口类型选取其中一种方式。如果是 VLANIF 或者是主干接口，则使用 Global 方式；否则使用 Per slot 方式。 ● Mixed with 2 global space：全局空间 1、全局空间 2 和每个槽位的空间都会被创建。 ● 2 global space：全局空间 1 和全局空间 2 都会被创建。

- NHLFE

  下一跳标签转发表项 NHLFE（Next Hop Label Forwarding Entry）用于指导 MPLS 报文的转发。

  NHLFE 包括：Tunnel ID、出接口、下一跳、出标签、标签操作类型等信息。

- ILM

  入标签到一组下一跳标签转发表项的映射称为入标签映射 ILM（Incoming Label Map）。

  ILM 包括：Tunnel ID、入标签、入接口、标签操作类型等信息。

  ILM 在 Transit 节点的作用是将标签和 NHLFE 绑定。通过标签索引 ILM 表，就相当于使用目的 IP 地址查询 FIB，能够得到所有的标签转发信息。

- FTN

  FEC 到一组 NHLFE 的映射称为 FTN（FEC-to-NHLFE）。

  通过查看 FIB 表中 Token 值不为 0x0 的表项，能够获得 FTN 的详细信息。FTN 只在 Ingress 存在。

MPLS 报文的基本转发过程

以支持 PHP 的 LSP 为例，说明 MPLS 报文的基本转发过程。

图 1-11 MPLS 标签分发和报文转发

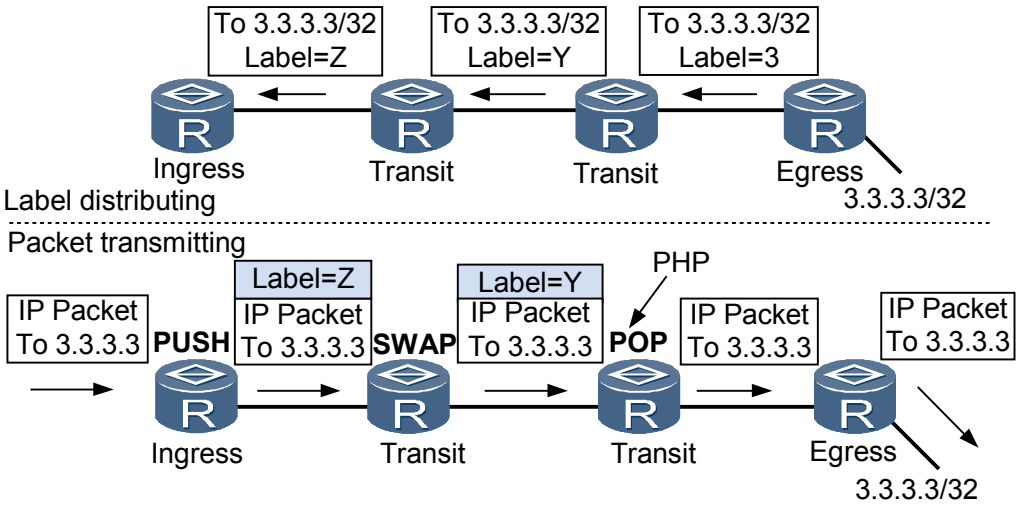

如图 1-11，MPLS 建立了一条 LSP，其目的地址为 3.3.3.3/32。则 MPLS 报文基本转发过程如下：

1. Ingress 节点收到目的地址为 3.3.3.3/32 的 IP 报文，添加标签 Z 并转发。
2. Transit 节点收到该标签报文，进行标签交换，将标签 Z 弹出，换成标签 Y。
3. 倒数第二跳 Transit 节点收到带标签 Y 的报文。因 Egress 分给它的标签值为 3，进行 PHP 操作，弹出标签 Y 并转发报文。从倒数第二跳到 Egress 之间报文以 IP 报文形式传输。
4. Egress 节点收到该 IP 报文，将其转发给目的地 3.3.3.3/32。

MPLS 转发流程

当 IP 报文进入 MPLS 域时，首先查看 FIB 表，检查目的 IP 地址对应的 Tunnel ID 值是否为 0x0。

- 如果 Tunnel ID 值为 0x0，则进入正常的 IP 转发流程。
- 如果 Tunnel ID 值不为 0x0，则进入 MPLS 转发流程。

MPLS 转发流程如图 1-12 所示。

图 1-12 MPLS 转发流程

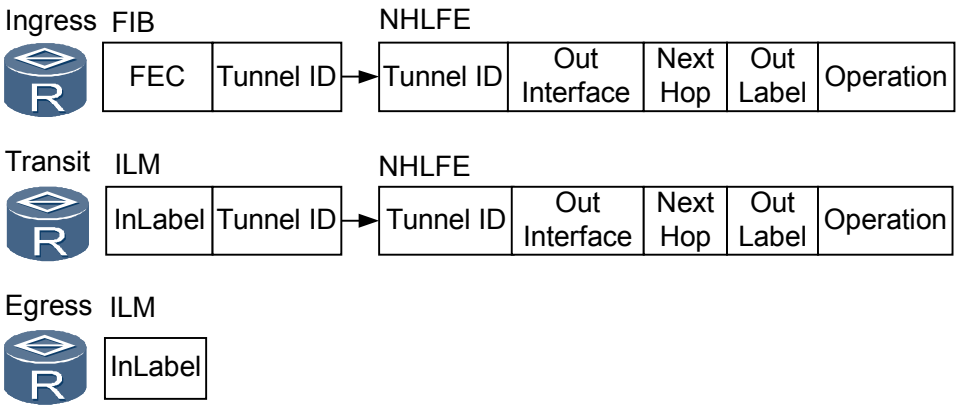

在报文转发过程中：

1. 在 Ingress，通过查询 FIB 表和 NHLFE 表指导报文的转发。
2. 在 Transit，通过查询 ILM 表和 NHLFE 表指导 MPLS 报文的转发。
3. 在 Egress，通过查询 ILM 表指导 MPLS 报文的转发。

在 MPLS 转发过程中，FIB、ILM 和 NHLFE 表项实际上是通过 Tunnel ID 中的 Token 字段关联的。

- Ingress 的处理

  Ingress 节点的处理如下：

  1. 查看 FIB 表，根据目的 IP 地址找到对应的 Tunnel ID。
  2. 根据 FIB 表的 Tunnel ID 找到对应的 NHLFE 表项，将 FIB 表项和 NHLFE 表项关联起来。
  3. 查看 NHLFE 表项，可以得到出接口、下一跳、出标签和标签操作类型，标签操作类型为 Push。
  4. 在 IP 分组报文中压入获得的标签，并根据 QoS 策略处理 EXP，同时处理 TTL，然后将封装好的 MPLS 分组报文发送给下一跳。

- Transit 的处理

  Transit 节点收到 MPLS 报文后的处理：

  1. 根据 MPLS 的标签值查看对应的 ILM 表，可以得到 Token。
  2. 根据 ILM 表的 Token 找到对应的 NHLFE 表项。
  3. 查看 NHLFE 表项，可以得到出接口、下一跳、出标签和标签操作类型。
  4. MPLS 报文的处理方式根据不同的标签值而不同。
     - 如果标签值>= 16，则用新标签替换 MPLS 分组报文中的旧标签，同时处理 EXP 和 TTL，然后将替换完标签的 MPLS 分组报文发送给下一跳。
     - 如果标签值为 3，则直接弹出标签，同时处理 EXP 和 TTL，然后进行 IP 转发或下一层标签转发。

- Egress 的处理

  Egress 节点收到 MPLS 报文后，查看 ILM 表获得标签操作类型，同时处理 EXP 和 TTL。

  - 如果标签中的 S=1，表明该标签是栈底标签，直接进行 IP 转发。
  - 如果标签中的 S=0，表明还有下一层标签，继续进行下一层标签转发。

MPLS 对 TTL 的处理

MPLS 标签中包含一个 8 位的 TTL 域，其含义与 IP 头中的 TTL 域相同。MPLS 对 TTL 的处理除了用于防止产生路由环路外，也用于实现 Traceroute 功能。

RFC3443 中定义了两种 MPLS 对 TTL 的处理模式：Uniform 和 Pipe。缺省情况下，MPLS 对 TTL 的处理模式为 Uniform。

- Uniform 模式

  IP 分组经过 MPLS 网络时，在入节点，IP TTL 减 1 映射到 MPLS TTL 字段，此后报文在 MPLS 网络中按照标准的 TTL 处理方式处理。在出节点将 MPLS TTL 减 1 后映射到 IP TTL 字段。如图 1-13 所示。

图 1-13 Uniform 模式下 TTL 的处理

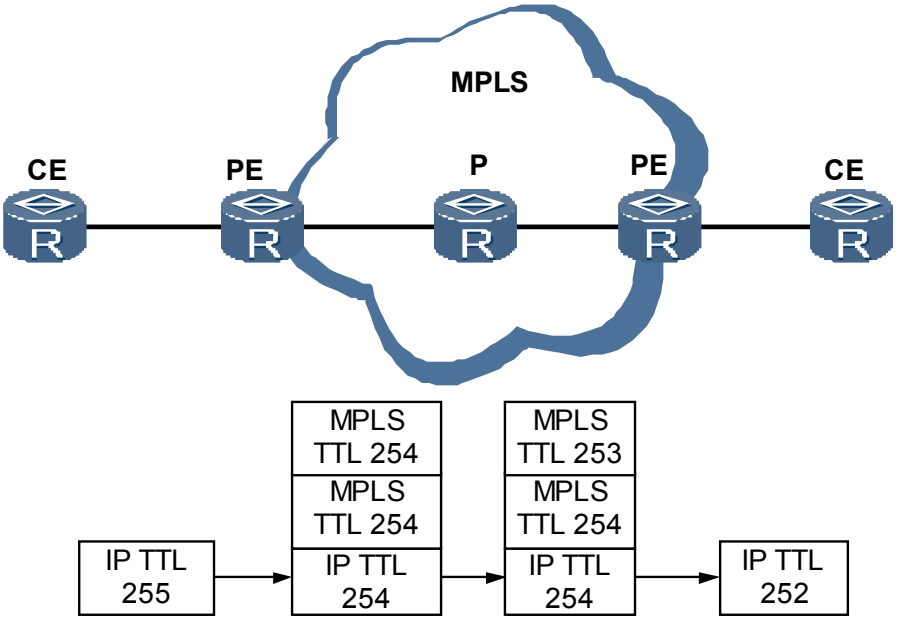

- Pipe 模式

  在入节点，IP TTL 值减 1，MPLS TTL 字段为固定值，此后报文在 MPLS 网络中按照标准的 TTL 处理方式处理。在出节点会将 IP TTL 字段的值减 1。即 IP 分组经过 MPLS 网络时，无论经过多少跳，IP TTL 只在入节点和出节点分别减 1。如图 1-14 所示。

图 1-14 Pipe 模式下 TTL 的处理

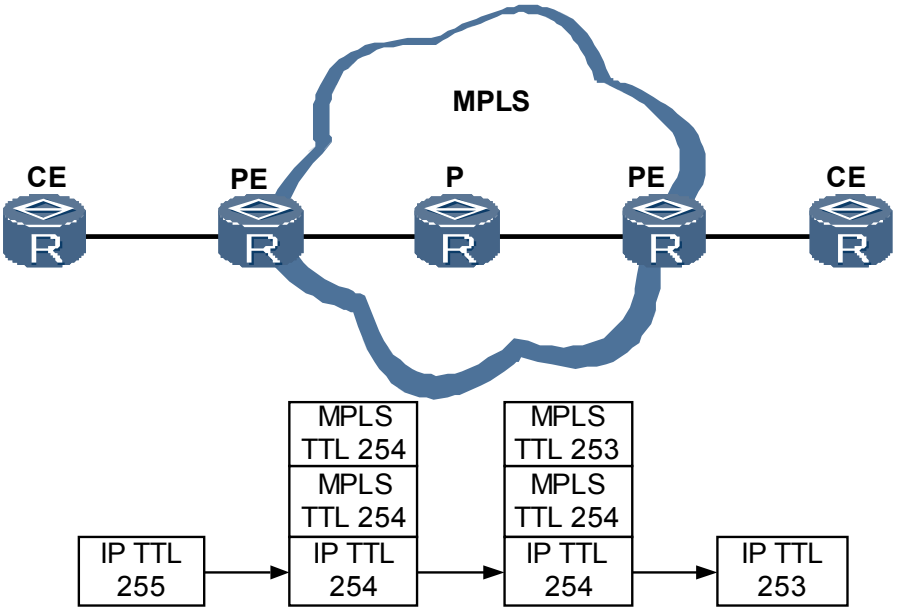

1.4.4 MPLS Ping/Traceroute

概述

在 MPLS 中，如果 LSP 转发数据失败，负责建立 LSP 的 MPLS 控制平面将无法检测到这种错误，这会给网络维护带来困难。

MPLS Ping/Traceroute 为用户提供了发现 LSP 错误、并及时定位失效节点的机制。

MPLS Ping 主要用于检查网络连接及主机是否可达。MPLS Traceroute 在检查网络连接是否可达的同时，还可以分析网络什么地方发生了故障。

类似于普通 IP 的 Ping/Traceroute，MPLS Ping/Traceroute 使用 MPLS Echo Request 和 MPLS Echo Reply 检测 LSP 的可用性。这两种消息以 UDP 报文格式发送，端口号为 3503。接收端通过 UDP 端口号识别出 MPLS Echo Request 和 MPLS Echo Reply 报文。

MPLS Echo Request 中携带需要检测的 FEC 信息，和其他属于此 FEC 的报文一样沿 LSP 发送，从而实现对 LSP 的检测。MPLS Echo Request 通过 MPLS 转发给目的端，而 MPLS ECHO-REPLY 则按照一般 IP 报文的方式转发给源端。

为了防止消息到达 Egress 节点后又被转发给其他节点，Echo Request 消息的 IP 头中目的地址设置为 127.0.0.1/8（本机环回地址），IP 头中的 TTL 值＝ 1。

MPLS Ping

图 1-15 MPLS 网络

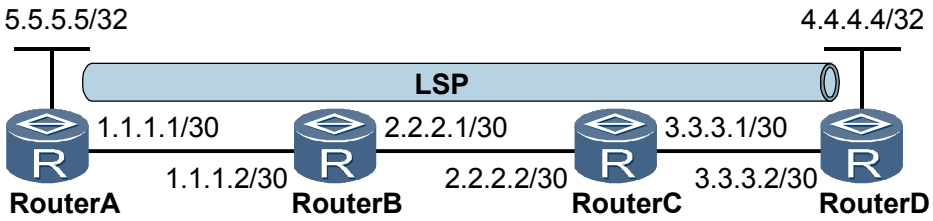

如图 1-15，RouterA 上建立了一条目的地为 RouterD 的 LSP。从 RouterA 对该 LSP 进行 MPLS Ping 时的处理如下：

1. RouterA 查找该 LSP 是否存在。如果不存在，返回错误信息，停止 Ping。如果存在，则继续进行以下操作。
2. RouterA 构造 MPLS Echo Request 报文，IP 首部目的地址为 127.0.0.1/8，IP TTL ＝ 1。查找相应的 LSP，压入 LSP 的标签（标签的 TTL ＝ 255），将报文发送给 RouterB。
3. 中间节点 RouterB 和 RouterC 对 MPLS Echo Request 报文进行普通 MPLS 转发。

   如果中间节点 MPLS 转发失败，则中间节点返回带有错误码的应答消息。
4. 当 MPLS 转发路径无故障，则 MPLS Echo Request 报文到达 LSP 的出节点 RouterD。RouterD 处理后返回 MPLS Echo Reply 报文。

MPLS Traceroute

如图 1-15，从 RouterA 对 4.4.4.4/32 进行 MPLS traceroute 时的处理如下：

1. RouterA 检查 LSP 是否存在，如果不存在，返回错误消息，停止 Traceroute，否则继续进行如下处理。
2. RouterA 构造 MPLS Echo Request 报文，IP 首部目的地址为 127.0.0.1/8，IP TTL ＝ 1。查找相应的 LSP，压入 LSP 的标签（标签的 TTL ＝ 1），将报文发送给 RouterB。RouterB 收到此报文，标签的 TTL 超时，因此返回 MPLS Echo Reply 消息。MPLS Echo Reply 消息的目的 UDP 端口和目的 IP 地址就是 MPLS Echo Request 报文的源 UDP 端口和源 IP 地址，IP TTL ＝ 255。
3. RouterA 收到 MPLS Echo Reply 消息后发送 MPLS Echo Request 报文，其中标签的 TTL ＝ 2。RouterB 对该报文进行普通 MPLS 转发。RouterC 收到此报文，标签的 TTL 超时，返回 MPLS Echo Reply 消息。

   如果中间节点 MPLS 转发失败，则没有 MPLS Echo Reply 消息返回。
4. RouterA 收到 MPLS Echo Reply 消息后发送 MPLS Echo Request 报文，其中标签的 TTL ＝ 3。RouterB 和 RouterC 对该报文进行普通 MPLS 转发。RouterD 收到此报文，发现报文目的地址为本机回环地址，返回 MPLS Echo Reply 消息。

1.5 应用

1.5.1 基于 MPLS 的 VPN

传统 VPN 一般是通过 GRE（Generic Routing Encapsulation）、L2TP（Layer 2 Tunneling Protocol）、PPTP（Point to Point Tunneling Protocol）等隧道协议来实现私有网络间数据在公网上的传送。

基于 MPLS 的 VPN 可以创建一个同 FR 网络具备的安全性很相似的专用网。用户设备一般不需要使用 IPSec 等安全技术，也无需为 VPN 配置 GRE、L2TP 等隧道，网络时延被降到最低，因为数据包不再经过封装或者加密。

基于 MPLS 的 VPN 通过 LSP 将私有网络的不同分支联结起来，形成一个统一的网络，如图 1-16 所示。基于 MPLS 的 VPN 还支持对不同 VPN 间的互通控制。图 1-16 中：

- CE（Customer Edge）是用户边缘设备，可以是路由器，也可以是交换机或主机；
- PE（Provider Edge）是服务商边缘节点，位于骨干网络。
- P（Provider）是服务提供商网络中的骨干设备，不与 CE 直接相连。P 设备只需要具备基本 MPLS 转发能力，不维护 VPN 信息。

图 1-16 基于 MPLS 的 VPN

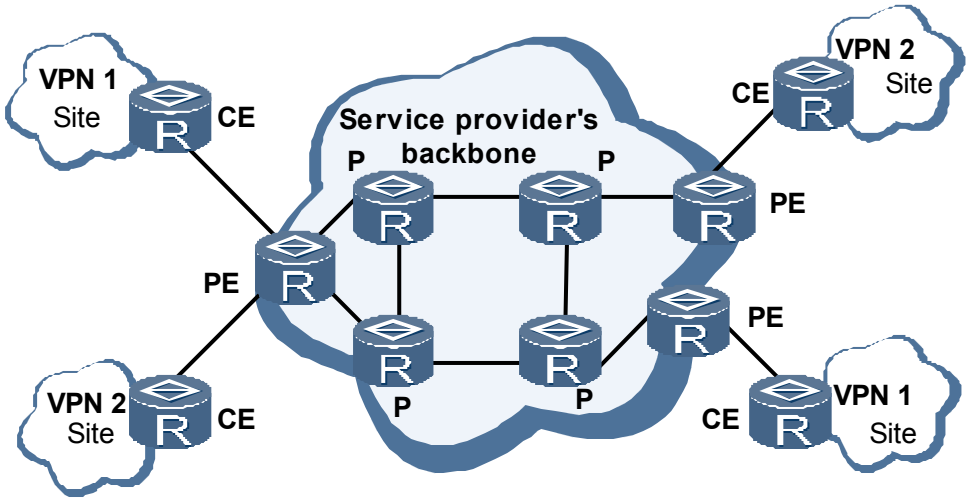

基于 MPLS 的 VPN 具有以下特点：

- PE 负责对 VPN 用户进行管理、建立各 PE 间 LSP 连接、同一 VPN 用户各分支间路由分派。
- PE 间的路由分派通常是用 LDP 或 MBGP 协议实现。
- 支持不同分支间 IP 地址复用和不同 VPN 间互通。

说明

AR3200 仅支持 MPLS L3VPN。

1.6 术语与缩略语

术语

术语	解释
标签空间	分配标签的数值范围称为标签空间（Label Space）。
ILM	入标签到一组下一跳标签转发表项的映射称为入标签映射 ILM（Incoming Label Map）。ILM 包括 Tunnel ID、入标签、入接口等信息。
LDP 对等体	LDP 对等体是指相互之间存在 LDP 会话、使用 LDP 来交换标签/FEC 映射关系的两个 LSR。
LDP 标识符	LDP 标识符（LDP Identifier）用于标识特定 LSR 的标签空间范围。

术语	解释
NHLFE	下一跳标签转发表项 NHLFE（Next Hop Label Forwarding Entry）用于指导 MPLS 报文的转发。NHLFE 包括：Tunnel ID、出接口、下一跳、出标签、标签操作类型等信息。
PHB	用来描述拥有相同 DSCP 值的报文的下一步转发动作。一般 PHB 包括延时、丢包率等流量特性。
控制平面	无连接的，主要功能是负责标签的分配、标签转发表的建立、标签交换路径的建立、拆除等工作。
转发平面	也称为数据平面（Data Plane），是面向连接的，可以使用 ATM、帧中继、Ethernet 等二层网络。转发平面的主要功能是对 IP 包进行标签的添加和删除，同时依据标签转发表对收到的分组进行转发。

缩略语

缩略语	英文全称	中文全称
DoD	Downstream-on-Demand	下游按需方式
DU	Downstream Unsolicited	下游自主方式
LSP	Label switched path	标签转发路径
FEC	Forwarding Equivalence Class	转发等价类
ILM	Incoming Label Map	入标签映射
LAM	Label Advertisement Mode	标签发布模式
LDP	Label Distribution Protocol	标记分发协议/标签分发协议
LER	Label Edge Router	标记边缘路由器
LFIB	Label Forward Information Base	转发信息库
LSP	Label Switched Path	标签交换路径
LSR	Label Switching Router	标签交换路由器
MPLS	Multiprotocol Label Switching	多协议标签交换
NHLFE	Next Hop Label Forwarding Entry	下一跳标签转发项
PHP	Penultimate Hop Popping	倒数第二跳弹出

2 MPLS LDP

关于本章

2.1 介绍

定义

标签分发协议 LDP（Label Distribution Protocol）是多协议标签交换 MPLS（Multi-Protocol Label Switching）的一种控制协议，相当于传统网络中的信令协议，负责转发等价类 FEC（Forwarding Equivalence Class）的分类、标签的分配以及标签交换路径 LSP（Label Switched Path）的建立和维护等操作。LDP 规定了标签分发过程中的各种消息以及相关处理过程。

目的

MPLS 支持多层标签，并且转发平面面向连接，故具有良好的扩展性，使在统一的 MPLS/IP 基础网络架构上为客户提供各类服务成为可能。通过 LDP 协议，标签交换路由器 LSR（Label Switched Router）可以把网络层的路由信息直接映射到数据链路层的交换路径上，建立起网络层的 LSP。目前，LDP 广泛地应用于 VPN 服务，具有组网和配置简单、支持路由拓扑驱动建立 LSP、支持大容量 LSP 等优点。

2.2 参考标准和协议

本特性的参考资料清单如下：

文档	描述	备注
RFC5036	LDP Specification	不支持环路检测。
RFC3215	LDP State Machine	-
RFC5443	LDP IGP Synchronization	不支持 end-of-lib 消息，其它支持。
RFC3478	Graceful Restart Mechanism for Label Distribution Protocol	-
RFC1321	The MD5 Message-Digest Algorithm	-
RFC3037	LDP Applicability	-
RFC3988	Maximum Transmission Unit Signalling Extensions for the Label Distribution Protocol	-
RFC5561	LDP Capabilities	-
RFC5283	LDP Extension for Inter-Area Label Switched Paths (LSPs)	-
RFC3813	LSR MIB	-
RFC3814	FTN MIB	-

文档	描述	备注
RFC3815	MPLS-LDP-STD-MIB/MPLS-LDP-GENERIC-STD-MIB	-
RFC4182	Removing a Restriction on the use of MPLS Explicit NULL	-
RFC5082	GTSM for LDP	-
RFC3031	Multiprotocol Label Switching Architecture	-
RFC3032	MPLS Label Stack Encoding	-

2.3 可获得性

涉及网元

需要其他网元也要支持 LDP 功能。

License 支持

无需获得 License 许可，均可获得该特性的服务。

版本支持

产品	最低支持版本
AR3200	V200R001C00

2.4 原理描述

2.4.1 LDP 基本概念

MPLS 体系有多种标签发布协议，LDP（Label Distribution Protocol）是其中使用较广的一种。

LDP（Label Distribution Protocol）规定了标签分发过程中的各种消息以及相关的处理过程。LSR 之间将依据本地转发表中对应于一个特定 FEC 的入标签、下一跳节点、出标签等信息联系在一起，从而形成标签交换路径 LSP。

关于 LDP 的详细介绍可以参考 RFC5036（LDP Specification）。

LDP 邻接体

当一台 LSR 接收到对端发送过来的 hello 消息，意味着可能存在 LDP 对等体，此时 LSR 会建立维护对端存在的 LDP 邻接体。LDP 邻接体存在两种类型：本地邻接体（Local Adjacency）和远端邻接体（Remote Adjacency）。

LDP 对等体

LDP 对等体是指相互之间存在 LDP 会话、使用 LDP 来交换标签消息的两个 LSR。

LDP 对等体通过它们之间的 LDP 会话获得对方的标签。

LDP 会话

LDP 会话用于 LSR 之间交换标签映射、释放等消息。LDP 会话分为两种类型：

- 本地 LDP 会话（Local LDP Session）：建立会话的两个 LSR 之间是直连的；
- 远端 LDP 会话（Remote LDP Session）：建立会话的两个 LSR 之间可以是直连的，也可以是非直连的。

本地 LDP 会话和远端 LDP 会话可以共存。

LDP 动态能力通告功能

LDP 动态能力通告功能可以确保在不中断会话的情况下，动态的使能或者去使能 LDP 新的扩展能力，保证 LSP 的稳定性。

LDP 邻接体/对等体/会话之间的关系

LDP 通过邻接体来维护对等体的存在，对等体的类型取决于维护它的邻接体的类型。一个对等体可以由多个邻接体来维护，如果由本地邻接体和远端邻接体两者来维护，则对等体类型为本远共存对等体。只有存在对等体才能建立 LDP 会话。

LDP 消息类型

LDP 协议主要使用四类消息：

- 发现（Discovery）消息：用于通告和维护网络中 LSR 的存在。
- 会话（Session）消息：用于建立、维护和终止 LDP 对等体之间的会话。
- 通告（Advertisement）消息：用于创建、改变和删除 FEC 的标签映射。
- 通知（Notification）消息：用于提供建议性的消息和差错通知。

为保证 LDP 消息的可靠发送，除了 Discovery 消息使用 UDP 外，LDP 的 Session 消息、Advertisement 消息和 Notification 消息都使用 TCP 传输。

标签空间与 LDP 标识符

- 标签空间

  LDP 对等体之间分配标签的数值范围称为标签空间（Label Space）。可以分为：

  - 全局标签空间（Per-Platform Label Space）：整个 LSR 使用一个标签空间。
  - 接口标签空间（Per-Interface Label Space）：为 LSR 的每个接口指定一个标签空间。

- LDP 标识符

  LDP 标识符（LDP Identifier）用于标识特定 LSR 的标签空间范围。LDP 标识符的格式为<LSR ID>：<Label space ID>，长度为六字节，其中：

  - LSR ID：表示 LSR 标识符，占四字节。
  - Label space ID：表示标签空间标识符，占两字节。

2.4.2 LDP 会话

LDP 发现机制

LDP 发现机制用于 LSR 发现潜在的 LDP 对等体。LDP 有两种发现机制：

- 基本发现机制：用于发现链路上直连的 LSR。

  LSR 通过周期性的发送 LDP Hello 报文，实现 LDP 基本发现机制，建立本地 LDP 会话。

  Hello 报文中携带 LDP Identifier 及一些其他信息（例如 hold time、transport address）。如果 LSR 在特定接口接收到 LDP Hello 消息，表明该接口存在 LDP 对等体。
- 扩展发现机制：用于发现链路上非直连 LSR。

  LSR 周期性的发送 Targeted Hello 消息到指定地址，实现 LDP 扩展发现机制，建立远端 LDP 会话。

  Targeted Hello 消息使用 UDP 报文，目的地址是指定地址，目的端口是 LDP 端口（646）。Targeted Hello 消息同样携带 LDP Identifier 及一些其他信息（例如：transport address、hold time）。如果 LSR 在特定接口接收到 Targeted Hello 消息，表明该接口存在 LDP 对等体。

LDP Session 建立过程

两台 LSR 之间交换 Hello 消息触发 LDP session 的建立。

LDP Session 的建立过程如图 2-1 所示：

图 2-1 LDP Session 建立过程

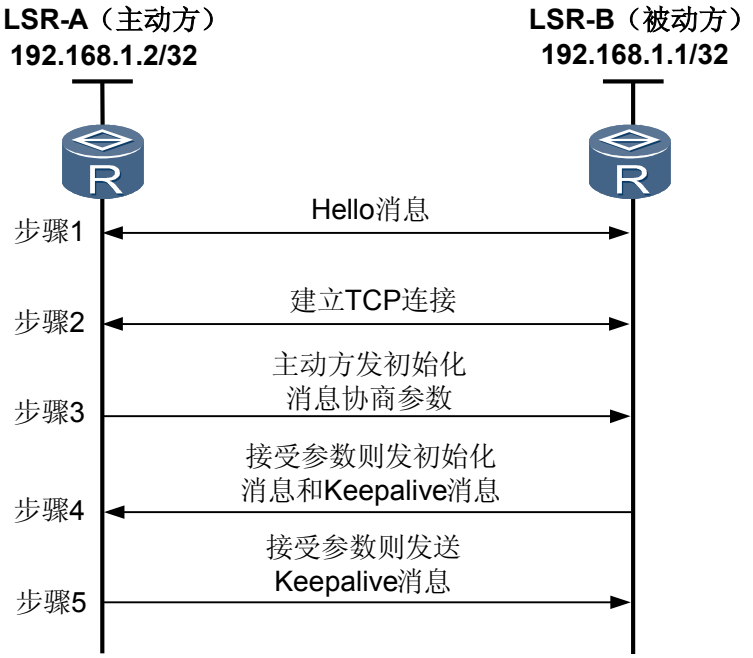

1. 两个 LSR 之间互相发送 Hello 消息。Hello 消息中携带传输地址，双方使用传输地址建立 LDP 会话。首先选择传输地址较大的一方作为主动方，发起建立 TCP 连接。如图 2-1 所示，LSRA 作为主动方发起建立 TCP 连接，LSRB 作为被动方等待对方发起连接。
2. TCP 连接建立成功后，由主动方 LSRA 发送 Initialization 消息，协商建立 LDP 会话的相关参数，包括 LDP 协议版本、标签分发方式、Keepalive 保持定时器的值、最大 PDU 长度和标签空间等。
3. 被动方 LSRB 收到 Initialization 消息后，如果不能接受相关参数，则发送 Notification 消息终止 LDP 会话的建立；如果被动方 LSRB 能够接受相关参数，则发送 Initialization 消息，同时发送 Keepalive 消息给主动方 LSRA。
4. 主动方 LSRA 收到 Initialization 消息后，如果不能接受相关参数，则发送 Notification 消息给被动方 LSRB 终止 LDP 会话的建立；如果能够接受相关参数，则发送 Keepalive 消息给被动方 LSRB。

当双方都收到对端的 Keepalive 消息后，LDP 会话建立成功。

2.4.3 标签的发布和管理

LDP 会话建立后，LDP 协议开始交换标签映射等消息用于建立 LSP。RFC5036 分别定义了标签发布方式、标签分配控制方式、标签保持方式来决定 LSR 如何发布和管理标签。

AR3200 支持的组合方式为：下游自主方式（DU）＋有序标签控制方式（Ordered）＋自由标签保持方式（Liberal）。

标签发布方式

在 MPLS 体系中，由下游 LSR 决定将标签分配给特定 FEC，再通知上游 LSR。即标签由下游指定，标签的分配按从下游到上游的方向分发。

标签发布方式（Label Advertisement Mode）可以分为以下两种：

- 下游自主方式

  下游自主方式 DU（Downstream Unsolicited）是指对于一个特定的 FEC，LSR 无须从上游获得标签请求消息即进行标签分配与分发。

  如图 2-2 所示，对于目的地址为 192.168.1.1/32 的 FEC，根据主机方式触发，下游（Egress）通过标签映射消息主动向上游（Transit）通告自己的主机路由 192.168.1.1/32 的标签。

  图 2-2 DU 方式

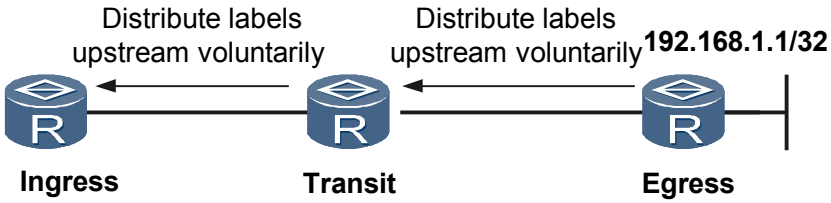

- 下游按需方式

  下游按需方式 DoD（Downstream on Demand）是指对于一个特定的 FEC，LSR 获得标签请求消息之后才进行标签分配与分发。

  如图 2-3 所示，对于目的地址为 192.168.1.1/32 的 FEC，根据主机方式触发，上游（Ingress）向下游发送标签请求消息，下游（Egress）收到标签请求消息后，才会向上游发送标签映射消息。

  图 2-3 DoD 方式

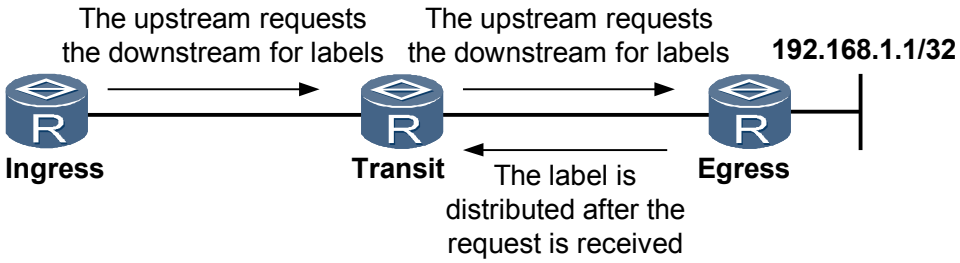

具有标签分发邻接关系的上游 LSR 和下游 LSR 必须对使用的标签发布方式达成一致。

说明

AR3200 不支持 DoD 方式的标签发布方式。

标签分配控制方式

标签分配控制方式（Label Distribution Control Mode）是指在 LSP 的建立过程中，LSR 分配标签时采用的处理方式。

标签分配控制方式可以分为以下两种：

- 独立标签分配控制

独立标签分配控制（Independent）是指本地 LSR 可以自主地分配一个标签绑定到某个 FEC，并通告给上游 LSR，而无需等待下游的标签。

- 如**图 2-2** 所示，如果标签发布方式为 DU，且标签分配控制方式为 Independent，则 LSR（Transit）无需等待下游（Egress）的标签，就会直接向上游（Ingress）分发标签。
- 如**图 2-3** 所示，如果标签发布方式为 DoD，且标签分配控制方式为 Independent，则发送标签请求的 LSR（Ingress）的直连下游（Transit）会直接回应标签，而不必等待来自最终下游（Egress）的标签。

- 有序标签分配控制

  有序标签分配控制（Ordered）是指对于 LSR 上某个 FEC 的标签映射，只有当该 LSR 已经具有此 FEC 下一跳的标签映射消息、或者该 LSR 就是此 FEC 的出节点时，该 LSR 才可以向上游发送此 FEC 的标签映射。

  - 如**图 2-2** 所示，如果标签发布方式为 DU，且标签分配控制方式为 Ordered，则 LSR（Transit）只有收到下游（Egress）的标签映射消息，才会向上游（Ingress）分发标签。
  - 如**图 2-3** 所示，如果标签发布方式为 DoD，且标签分配控制方式为 Ordered，则发送标签请求的 LSR（Ingress）的直连下游（Transit）只有收到最终下游（Egress）的标签映射消息，才会向上游（Ingress）分发标签。

说明

AR3200 不支持独立标签分配控制。

标签保持方式

标签保持方式（Label Retention Mode）是指 LSR 对收到的、但目前暂时不需要的标签映射的处理方式。

LSR 收到的标签映射可能来自下一跳，也可能来自非下一跳。

标签保持方式可以分为以下两种：

- 自由标签保持方式

  自由标签保持方式（Liberal）是指对于从邻居 LSR 收到的标签映射，无论邻居 LSR 是不是自己的下一跳都保留。

- 保守标签保持方式

  保守标签保持方式（Conservative）是指对于从邻居 LSR 收到的标签映射，只有当邻居 LSR 是自己的下一跳时才保留。

当网络拓扑变化引起下一跳邻居改变时：

- 使用自由标签保持方式，LSR 可以直接利用原来非下一跳邻居发来的标签，迅速重建 LSP（关于 LDP LSP 的建立，请参见 **LDP LSP 的建立**），但需要更多的内存和标签空间。
- 使用保守标签保持方式，LSR 只保留来自下一跳邻居的标签，节省了内存和标签空间，但 LSP 的重建会比较慢。

  保守标签保持方式通常与 DoD 方式一起，用于标签空间有限的 LSR。

已经被分配标签，但是没有建立成功的 LSP 叫做 Liberal LSP。

说明

AR3200 不支持保守标签保持方式。

2.4.4 LDP LSP 的建立

LSP 的建立过程实际就是将 FEC 和标签进行绑定，并将这种绑定通告 LSP 上的相邻 LSR。下面结合下游自主标签发布方式和有序标签控制方式来说明其主要步骤：

1. 当网络的路由改变时，如果有一个边缘节点发现自己的路由表中出现了新的目的地址，并且这一地址不属于任何现有的 FEC，则该边缘节点需要为这一目的地址建立一个新的 FEC。
2. 如果 MPLS 网络的出节点有可供分配的标签，则为 FEC 分配标签，并主动向上游发出标签映射消息，标签映射消息中包含分配的标签和绑定的 FEC 等信息。
3. 收到标签映射消息的 LSR 在其标签转发表中增加相应的条目，然后主动向上游 LSR 发送对于指定 FEC 的标签映射消息。
4. 当入节点 LSR 收到标签映射消息时，它也需要在标签转发表中增加相应的条目。这时，就完成了 LSP 的建立，接下来就可以对该 FEC 对应的数据分组进行标签转发。

2.4.5 LDP 跨域扩展

本特性可以使能 LDP 建立跨越多个 IGP 区域的 LDP LSP，提供穿越公网的隧道。

图 2-4 LDP 跨域扩展组网拓扑

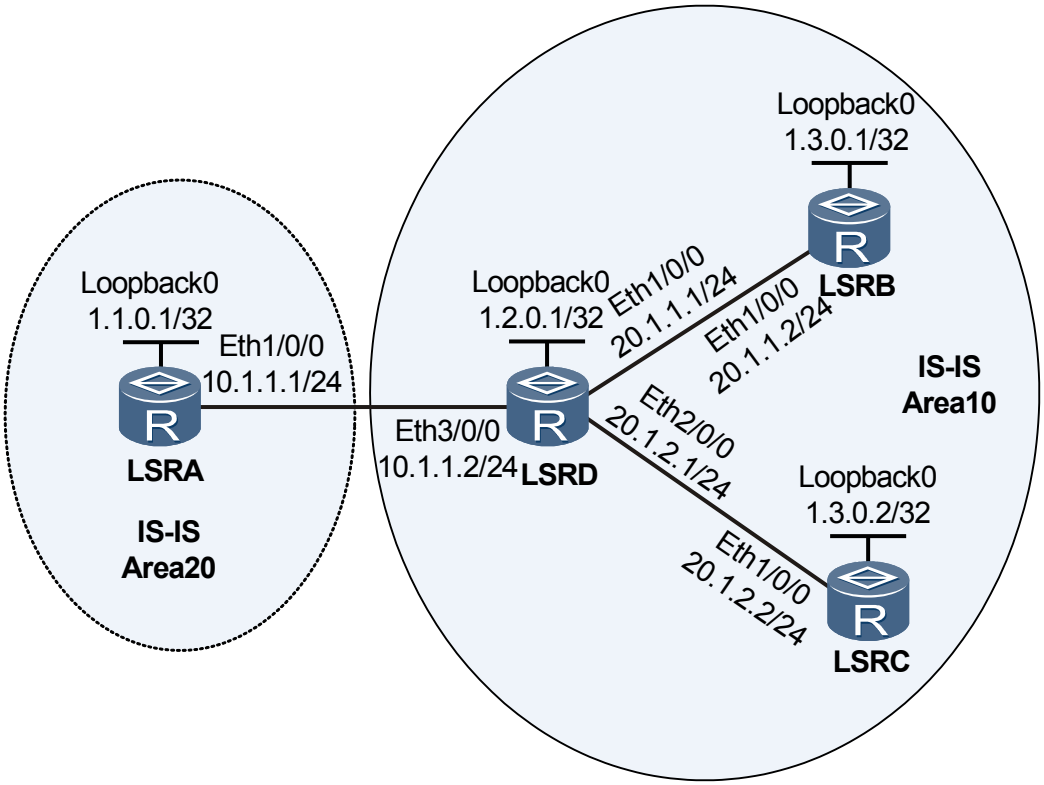

如图 2-4 所示，存在 Area 10 和 Area 20 两个 IGP 区域。

在 Area 10 区域边缘的 LSRD 的路由表中，存在到 LSRB 和 LSRC 的两条主机路由。通常，为了避免路由数量多而引起的对资源的过多占用，在 LSRD 上可以通过 ISIS 路由协议将这两条路由聚合为 1.3.0.0/24 发送到 Area 20 区域，那么 LSRA 的路由表中只有这

条聚合后的路由，而没有 32 位的主机路由。然而，缺省情况下，LDP 在建立 LSP 的时候，会在路由表中查找与收到的标签映射消息中携带的 FEC 精确匹配的路由，对于图 2-4 中的情况，LSRA 的路由表项信息和 FEC 携带的路由信息如表 2-1 所示。

表 2-1 LSRA 的路由表项信息和 FEC 携带的路由信息

LSRA 路由表项信息	FEC
1.3.0.0/24	1.3.0.1/32
	1.3.0.2/32

对于聚合路由，LDP 只能建立 Liberal LSP，无法建立跨越 IGP 区域的 LDP LSP，以至于无法给 VPN 业务提供必要的骨干网隧道。

因此，在图 2-4 的应用中，需要使能 LDP 按照最长匹配方式查找路由建立 LSP。在 LSRA 的路由表中，已经存在聚合路由 1.3.0.0/24。当 LSRA 收到 Area 10 区域的标签映射消息时（例如携带的 FEC 为 1.3.0.1/32），按照 RFC5283 使用最长匹配的查找方式，LSRA 能够找到聚合路由 1.3.0.0/24 的信息，把该路由的出接口和下一跳作为到 FEC 1.3.0.1/32 的出接口和下一跳。这样，LDP 就可以建立跨越 IGP 区域的 LDP LSP。

2.4.6 LDP Outbound 策略和 Inbound 策略

一般情况下，LSR 对于标签映射消息的接收和发送没有限制，导致大量的 LSP 的建立。这对于性能较低的设备，会造成资源的大量消耗，设备将无法承受。配置 LDP Outbound 策略和 Inbound 策略，可以限制标签映射消息的发送和接收，减少 LSP 的数量，节省内存。

LDP Outbound 策略

LDP Outbound 策略可以用于过滤向对等体发送的标签映射消息，只过滤路由 FEC 的标签映射消息，不会过滤 L2VPN 的标签映射消息，支持对 BGP 标签路由和非 BGP 路由分别指定 FEC 范围。

如果一组对等体或者全部对等体发送标签映射消息时，对 FEC 的限制范围是相同的，则可以对这一组或全部对等体应用相同的 Outbound 策略。

LDP Outbound 策略还支持水平分割策略，即只向上游 LDP 对等体分配标签。

LSR 在向对等体发送路由 FEC 的标签映射消息前会查看本地是否配置了对应路由类型（BGP 标签路由或非 BGP 路由）的 Outbound 策略。

- 如果本地没有配置 Outbound 策略，则发送标签映射消息。
- 如果本地配置了 Outbound 策略，则根据策略中指定的路由 FEC 的范围来确定是否发送该路由 FEC 的标签映射消息。

如果路由 FEC 没有通过任何 Outbound 策略，则不允许建立 Transit LSP 或 Egress LSP。

LDP Inbound 策略

LDP Inbound 策略可以用于过滤从对等体接收的标签映射消息，只过滤路由 FEC 的标签映射消息，不会过滤 L2VPN 的标签映射消息，支持对非 BGP 路由指定 FEC 范围。

如果一组对等体或者全部对等体接收标签映射消息时，对 FEC 的限制范围是相同的，则可以对这一组或全部对等体应用相同的 Inbound 策略。

LSR 在接收对等体发送的路由 FEC 的标签映射消息前会查看本地是否配置了 Inbound 策略。

- 如果本地没有配置 Inbound 策略，则接收标签映射消息。
- 如果本地配置了 Inbound 策略，则根据策略中指定的路由 FEC 的范围来确定是否接收该路由 FEC 的标签映射消息。

如果路由 FEC 没有通过本地任何 Inbound 策略，则不接收标签映射消息。

在不接收标签映射消息的情况下：

- 如果本地和邻居建立的是 DU 会话，则建立 Liberal LSP，且此 Liberal LSP 不可以被 LDP FRR 选作备份 LSP。
- 如果本地和邻居建立的是 DoD 会话，则发送 Release 消息拆除标签绑定。

2.4.7 LDP GR

LDP GR（Graceful Restart）是借助邻居设备（Helper）的帮助，实现主备倒换的设备（Restarter）转发不中断。

在没有 GR 能力的情况下，发生主备倒换时，邻居会因为会话进入 Down 状态而删除 LSP，产生流量短时间中断、业务短时间中断。对于以上情况，如果配置了 LDP GR 能力，可以保证意外主备倒换前后的标签保持一致，即保持了 MPLS 转发不中断。具体过程如图 2-5 所示：

1. 主备倒换前，LDP 邻居在建立 LDP 会话时进行 GR 能力协商。
2. Helper 感知到 Restarter 进行主备倒换后，启动 GR Reconnect 定时器，在该定时器超时前保留 Restarter 相关的转发表项。其中转发不中断的前提是 Restarter 保留了 MPLS 转发表项。
3. 如果在 Helper 的 GR Reconnect 定时器超时前 Restarter 和 Helper 之间的 LDP 会话重建完成，则 Helper 会删除 GR Reconnect 定时器，并启动 GR Recovery 定时器。
4. 在 Helper 的 GR Recovery 定时器超时前，Helper 会协助 Restarter 恢复转发表项，Restarter 也会协助 Helper 恢复转发表项，该定时器超时后，Helper 会删除所有未恢复的与 GR Restarter 相关的转发表项。
5. 与此同时，Restarter 进行主备倒换后，会启动 Forwarding State Holding 定时器。该定时器超时前，Restarter 保留重启前的转发表项，并在 Helper 的协助下进行转发表项的恢复工作。该定时器超时后，Restarter 将删除所有未恢复的转发表项。

图 2-5 LDP GR 实现原理

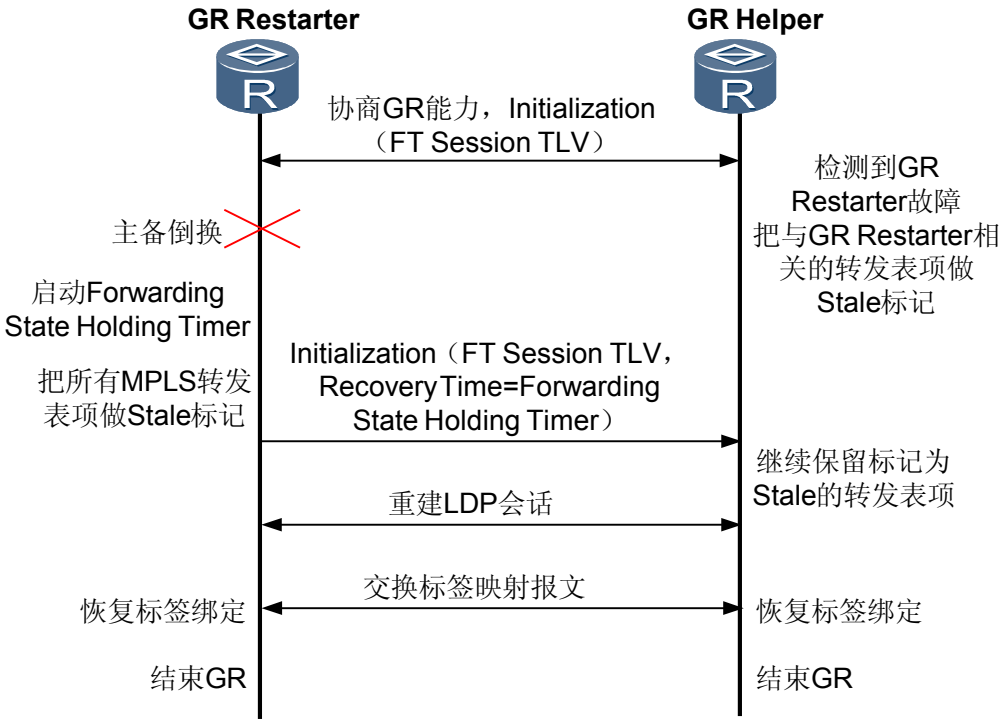

2.4.8 LDP MTU

MTU 称为最大传输单元（Maximum Transmission Unit）。当同一个网络上的两台设备进行互通时，该网络的 MTU 是非常重要的。MTU 的大小决定了发送端一次能够发送报文的最大字节数，如果 MTU 设置的超过了接收端所能够承受的最大值，或者是超过了发送路径上途经的某台设备所能够承受的最大值，这样就会造成报文分片甚至丢弃，加重网络传输的负担。所以设备在进行通信之前必须要把 MTU 计算明确，才能保证每次发送的报文都能够畅通无阻的到达接收端，确保报文发送一次成功。

基本原理

LDP LSP 的转发和普通的 IP 转发虽然在实现方式上存在很大不同，但是 LDP LSP MTU 和普通的 IP 转发涉及的 MTU 在原理上有很多类似的地方。它们都是使得发送出去的报文能够畅通无阻的途经每一台中转设备，不需要报文重组就能直接到达接收端。

MPLS MTU 和接口 MTU 一样，有系统默认值，也可以通过命令行配置。LDP MTU 的计算方法是，LSR 针对某个 FEC，把所有下游设备通告的 MTU 和本机出接口 MTU 做比较，取出最小值通告给上游。通告方式为，把计算出来的 MTU 值放在 Label Mapping 消息的 MTU TLV 里面，然后把 Label Mapping 消息发送给上游。如果 MTU 发生变动，如本机出接口改变或者配置变更，那么 LSR 就应该再次通过 Label Mapping 消息，把重新计算过的 MTU 通告给它的所有上游。

2.4.9 LDP 认证

LDP MD5

MD5 称为 Message-Digest Algorithm 5，是 RFC 1321 定义的国际标准摘要密码算法。MD5 的典型应用是针对一段信息计算出对应的信息摘要，从而防止信息被篡改。MD5

信息摘要是通过不可逆的字符串变换算法产生的，结果唯一。因此，不管信息内容在传输过程中发生任何形式的改变，只要重新计算就会产生不同的信息摘要，接收端就可以由此判定收到的是一个不正确的报文。

LDP MD5 应用其对同一信息段产生唯一摘要信息的特点来实现 LDP 报文防篡改校验，比一般意义上 TCP 校验和更为严格。

LDP MD5 验证是在 TCP 发出去之前进行的：LDP 消息在经 TCP 发出前，会在 TCP 头后面填充一个唯一的信息摘要再发出。而这个信息摘要就是把 TCP 头、LDP 消息、以及用户设置的密码一起作为原始信息，通过 MD5 算法计算出的。

当接收端收到这个 TCP 报文时，首先会取得报文的 TCP 头、信息摘要、LDP 消息，并结合 TCP 头、LDP 消息以及本地保存的密码，利用 MD5 计算出信息摘要，然后与报文携带的信息摘要进行比较，从而检验报文是否被篡改过。

在用户设置密码时有明文和密文两种形式选择，这里的明文密文是对用户设置的密码在配置文件中的记录形式而言的。明文就是直接在配置文件中记录用户设置的字符串，密文就是在配置文件中记录经过特殊算法加密后的字符串。

但无论用户选择密码记录形态是明文还是密文形式，参与摘要计算时都是直接使用用户输入的字符串，也就是说私有加密算法计算出的密码并不会参与 MD5 摘要计算。由于明文和密文的转化算法各厂商私有，此种实现做到了私有算法对其他厂商设备透明。

LDP Keychain

Keychain 是一种增强型加密算法，类似于 MD5，Keychain 也是针对同一段信息计算出对应的信息摘要，实现 LDP 报文防篡改校验。

Keychain 允许用户定义一组密码，形成一个密码串，并且分别为每个密码指定加解密算法（包括 MD5，SHA-1 等）及密码使用的有效时间。在收发报文时，系统会按照用户的配置选出一个当前有效的密码，并按照与此密码相匹配的加密解密算法以及密码的有效时间，进行发送时加密和接收时解密报文。此外，系统可以依据密码使用的有效时间，自动完成有效密码的切换，避免了长时间不更改密码导致的密码易破解问题。

Keychain 的密码、所使用的加解密算法以及密码使用的有效时间可以单独配置，形成一个 Keychain 配置节点，每个 Keychain 配置节点至少需要配置一个密码，并指定加解密算法。

Keychain 节点配置完成后，在全局 MPLS LDP 视图下指定需要引用 Keychain 节点的对等体和 Keychain 节点名称，对 Keychain 进行引用，即可实现对 LDP 会话的加密。不同的对等体可以引用同一个 Keychain 配置节点。

2.4.10 LDP 为 BGP 分标签

LDP 为 BGP 分标签是指：LDP 为带标签的公网 32 位掩码的 BGP 路由建立 LDP Egress LSP，以及 LDP 为公网 BGP 路由建立 Transit LSP。

LDP 为 BGP 路由分标签主要应用在 L3VPN 跨域 Option C 场景，实现 LDP 为 BGP 路由分标签之后，跨域 Option C 场景中 PE 和 ASBR 之间不用再建立 full-mash 的 IBGP 邻居关系，易于扩展。

L3VPN 跨域 Option C

图 2-6 L3VPN 跨域 OptionC 组网拓扑

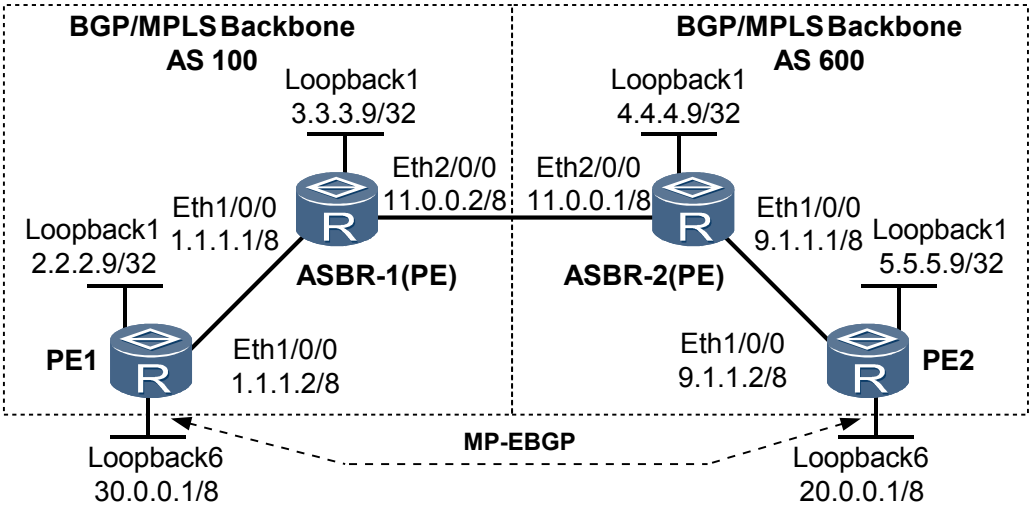

- 配置部署：

  与普通 L3VPN 跨域 OptionC 的配置不同的是，PE1 和 ASBR1 之间，以及 PE2 和 ASBR2 之间不需要建立 IBGP 邻居，而是在两个 ASBR 上分别配置 LDP 为 BGP 分标签策略，并将 BGP 路由引入 IGP 协议发布，最终使 PE 上建立目的地址是到对端 PE 的 LDP ingress LSP 作为 L3VPN 的公网隧道。

- 路由发布过程：

  以 PE1 的 Loopback 地址为例。PE1 将 2.2.2.9 / 32 通过 IGP 协议发布给 ASBR-1；ASBR-1 学到 2.2.2.9 / 32 的路由后，分配一个 BGP 标签，并通过 BGP 协议发布到 EBGP 邻居 ASBR-2；ASBR-2 学到 2.2.2.9 / 32 的带标签的公网 BGP 路由后，LDP 会为 2.2.2.9 / 32 建立 LDP Egress LSP，并将 2.2.2.9 / 32 通过 IGP 协议（此时已将 BGP 路由 2.2.2.9 引入 IGP 协议）发布给 PE2；PE2 学到 2.2.2.9 / 32（此时是 IGP 路由），会为 2.2.2.9 建立 LDP Ingress LSP。

- 标签操作类型：

  以私网路由 30.0.0.1 / 8 发出的报文为例，在 PE1 上压入一层 BGP 标签，再压入一层 LDP 标签；在 ASBR-1 上弹出外层 LDP 的标签，进入到 BGP LSP，并压入一层 BGP 标签；在 ASBR-2 上弹出外层的 BGP 标签，进入到 LDP LSP，并压入一层 LDP 标签；在 PE2 上弹出外层的 LDP 标签，弹出内层的 BGP 标签，走 IP 转发到 20.0.0.1 / 8。

2.4.11 LDP GTSM

通用 TTL 安全保护机制 GTSM（Generalized TTL Security Mechanism）是一种通过检查 IP 报文头中的 TTL 值是否在一个预先定义好的范围内来实现对 IP 业务进行保护的机制。使用 GTSM 的两个前提：

- 设备之间正常报文的 TTL 值确定
- 报文的 TTL 值很难被修改

GTSM 的应用范围包括 BGP（含 IPV6）、OSPF、LDP、RSVP、OSPFv3 等。

基本原理

LDP GTSM 是 GTSM 在 LDP 方面的具体应用。

GTSM 通过判定报文的 TTL 值，确定报文是否有效，从而保护设备免受攻击。GTSM For LDP 即是对相邻或相近（基于只要跳数确定的原则）设备间的 LDP 消息报文应用此种机制，预先在各路由上设定好针对其他设备报文的有效范围，使能 GTSM，这样当相应设备之间应用 LDP 时，如果 LDP 消息报文的 TTL 不符合之前设置的范围要求，就认为此报文为非法攻击报文予以丢弃，进而实现对上层协议的保护。

应用场景

GTSM 在实际应用中，主要服务于保护建立在 TCP/IP 层上的控制层面免受 CPU-utilization（CPU overload）类型的攻击。应用于 LDP，就是将 GTSM 应用于 LDP 各种消息报文，以免 LDP 协议在收到大量伪装报文时，因处理报文导致 CPU-utilization 等情况的攻击。

图 2-7 LDP GTSM 组网拓扑

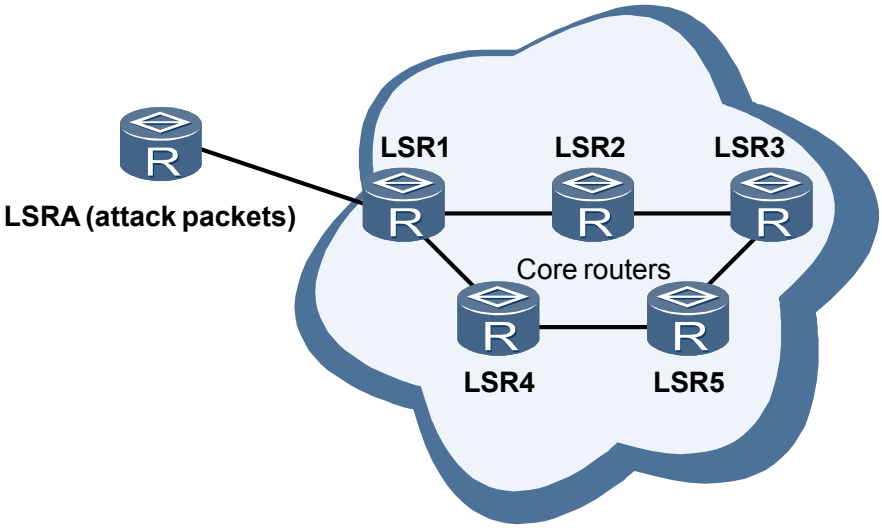

如图 2-7 所示，LSR1-LSR5 为骨干网中核心路由器，当 LSRA 通过其他设备与核心路由器间接相连时，LSRA 可能会伪造 LSR1 ～ LSR5 之间的 LDP 相关报文来达到攻击的目的。

当 LSRA 经过其他设备接入后，伪造报文中携带的 TTL 值被认为是不可伪造的，这就是 GTSM 的前提。

在 LSR1 ～ LSR5 上分别配置到各个可能邻居的 GTSM 策略：如在 LSR5 上配置 LSR2 发送的报文有效跳数为 1 ～ 2，有效 TTL 值为 254 ～ 255。当 LSRA 发送的伪造报文到达 LSR5 时，由于经过多跳中间设备，导致 TTL 比预先设置的有效范围小，因此 LSR5 可以直接把伪造报文丢弃，避免了攻击。

2.4.12 LDP 为所有 Peer 分标签

本子特性主要是为了解决目字形组网发生链路故障收敛比较慢的问题而提出的。

在只给上游 Peer 分标签的情况下，发送标签 Mapping 消息的时候，要根据路由信息对会话的上下游关系进行确认。对于某一条路由，上游节点不向下游节点发送标签 Mapping

消息；如果发生路由变化，上下游关系倒换，新的下游需要重新给上游节点发送标签 Mapping 消息，收敛比较慢。

在本子特性完成后，对所有符合条件的对等体都要发送标签 Mapping 消息，不再区分上下游关系。即每个节点都可以向所有的对等体发送标签 Mapping 消息。

如图 2-8 所示，P2 原来到 PE3 的路径为 P2－>P1－>P3－>PE3 和 P2－>P4－>PE4－>PE3，对于 PE3 上的 Loopback 接口路由，P1 是 P2 的路由的下一跳。当 P2 从 P1 上接收到标签 Mapping 消息之后，只向上游分标签的情况下，P2 不会向 P1 发送关于这个路由的标签 Mapping 消息，这样当 P1P3 之间发生链路故障，从 PE1 到 PE3 的路径由 PE1－>P1－>P3－>PE3 切换为 PE1－>P1－>P2－>P4－>P3－>PE3，P2 切换为 P1 的下游，但是由于 P2 没有向 P1 发送标签 Mapping 消息，必须等待重新发送标签 Mapping 消息后才能使 LSP 重新收敛，速度比较慢。

在 LDP 为所有 Peer 分标签的情况下，P2 从 P1 上接收到标签 Mapping 消息之后，会直接向 P1 发送关于这个路由的标签 Mapping 消息，并在 P1 上生成一个 Liberal LSP。这样当 P1P3 之间发生链路故障，从 PE1 到 PE3 的路径由 PE1－>P1－>P3－>PE3 切换为 PE1－>P1－>P2－>P4－>P3－>PE3，P2 切换为 P1 的下游，Liberal LSP 直接变化为 Normal LSP，LSP 收敛速度加快。

另外，通过配置水平分割命令可以用来决定为哪些下游对等体发送标签 Mapping 消息，对哪些下游对等体不能发送标签 Mapping 消息。

图 2-8 LDP 为所有 Peer 分标签组网拓扑

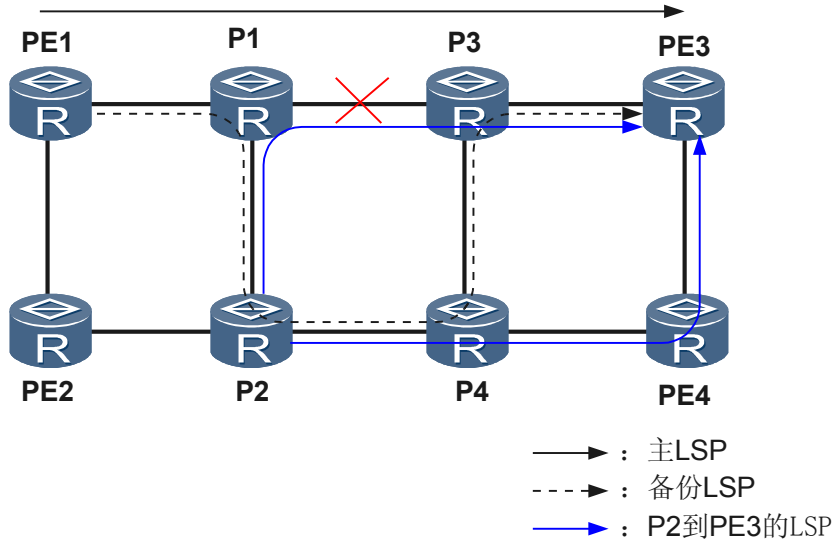

2.5 术语与缩略语

缩略语

缩略语	英文全称	中文全称
LDP	Label distribution protocol	标签分发协议

缩略语	英文全称	中文全称
LSP	Label switched path	标签转发路径
FEC	Forwarding Equivalence Class	转发等价类
GTSM	Generalized TTL Security Mechanism	通用 TTL 安全保护机制
TTL	Time to Live	报文生命周期
MTU	Maximum Transmission Unit	最大传输单元

3 MPLS TE

关于本章

3.1 介绍

目的

传统的 IP 网络中，节点选择最短的路径作为路由，不考虑带宽等因素。这样，容易出现流量集中于最短路径而导致拥塞。其他可选的路径则较为空闲。

图 3-1 传统路由的困难

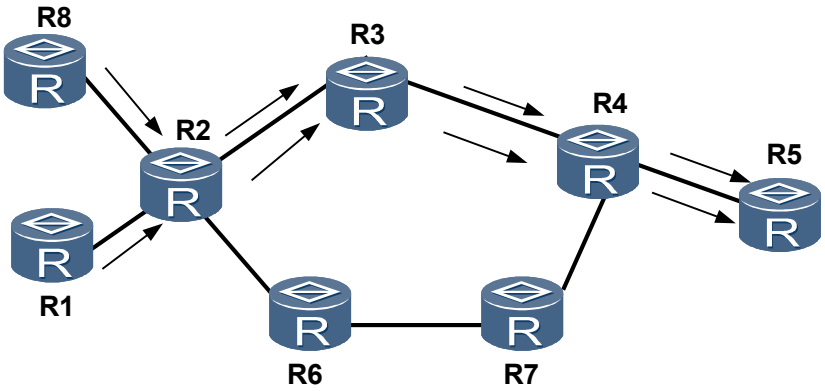

如图 3-1 所示，假设每个链路的 metric 值相同。R1（R8）到 R5 的最短路径为 R1（R8）→R2→R3→R4→R5，尽管存在其他到达 R5 的路径，数据转发也走 R1（R8）→R2→R3→R4→R5 这条最短路径。这样，就可能出现一条链路 R1（R8）→R2→R3→R4→R5 过载而出现拥塞，而另外一条链路 R1（R8）→R2→R6→R7→R4→R5 空闲的情况。

网络拥塞是影响骨干网络性能的主要问题。拥塞的原因可能是网络资源不足，也可能是网络资源负载不均衡，导致局部拥塞。流量工程解决的是由于负载不均衡导致的拥塞。为解决网络拥塞，传统的流量工程通常采取如下方法：

- 通过调整路径 Metric 而控制网络流量：这种解决方法能够解决某些链路上的拥塞，但是可能会引起另外的链路拥塞。另外，在拓扑结构复杂的网络上，Metric 值的调整比较困难，往往一条链路的改动会影响多条路由，难以把握和权衡。
- 采用叠加的网络模型，建立虚连接引导部分流量：现有的 IGP 协议都是拓扑驱动，如果只考虑网络的连接情况，不能灵活反映带宽和流量特性这类动态状况。

  解决 IGP 缺点的一种方法是使用重叠模型（Overlay），如 IP over ATM、IP over FR 等。重叠模型在网络的物理拓扑结构上提供了一个虚拟拓扑结构，从而容易实现流量的合理调配和良好的 QoS 功能。然而，重叠模型的额外开销大，可扩展性差。

为了在大型骨干网络中部署流量工程，必须采用一种可扩展性好、简单的解决方案。MPLS（Multiprotocol Label Switching）作为一种叠加模型，可以方便地在物理的网络拓扑上建立一个虚拟的拓扑，然后将流量映射到这个拓扑上。因此，MPLS 与流量工程相结合的技术——MPLS TE（Traffic Engineering）应运而生。

定义

MPLS TE（MPLS Traffic Engineer），即 MPLS 流量工程。可以通过 RSVP-TE 协议建立基于约束的 LSP（CR-LSP）隧道，这些约束可以包括：带宽、优先级、亲和属性、显

式路径、CSPF 仲裁策略、metric 类型、跳数限制、SRLG 等；也可以通过静态配置 LSP 来建立 CR-LSP，我们称之为静态 CR-LSP。

MPLS TE 的特征：MPLS TE 结合了 MPLS 技术与流量工程，通过建立经过指定路径的 LSP 进行资源预留，使网络流量绕开拥塞节点，达到平衡网络流量的目的。

MPLS 有实现流量工程所需要的特征，例如：

- 支持建立显式 LSP，可以对路径进行控制；
- 通过信令建立 LSP，配置起来比较简单，容易维护；
- 建立 LSP 的负荷小，不会影响网络的其它业务；
- 网络流量可以方便地映射到某条 LSP 上；
- LSP 有优先级、抢占等多种属性，可以方便地控制 LSP 的行为；
- 管理组和亲和属性可以控制 LSP 经由的路径；
- MPLS 允许流量聚合和非聚合两种方式，比 IP 灵活；
- MPLS 容易集成约束路由。

通过 MPLS TE，可以解决一部分路径过载而另一部分路径空闲的问题，充分利用现有的带宽资源。同时，MPLS TE 在建立 LSP 的过程中，可以通过预留资源来保证服务质量。

为了保证服务的连续性，MPLS TE 还引入路径备份和快速重路由 FRR（Fast Reroute）的机制，在链路故障时可及时进行切换。

MPLS TE 主要包括如下相关属性。

- CR-LSP

  基于一定约束条件建立的 LSP 称为 CR-LSP（Constraint-based Routed Label Switched Path）。与普通 LSP 不同，CR-LSP 的建立不仅依赖路由信息，还需要满足其他一些条件，比如指定的带宽、颜色、建立优先级、保持优先级、显式路径和 QoS 参数。

  CR-LSP 可分为两类：

  - 静态 CR-LSP：通过手工配置转发信息和资源信息，不涉及信令协议和路径计算。由于不需要交互 MPLS 相关控制报文，消耗资源比较小，但静态 CR-LSP 不能根据网络的变化动态调整，实际应用有限。
  - 动态 CR-LSP：通过信令机制建立和维护，需要进行路径计算。

- RSVP-TE

  为了能够建立 CR-LSP，对 RSVP 协议进行了扩展。扩展后的 RSVP（Resource Reservation Protocol）信令协议称为 RSVP-TE 信令协议。

- 带宽

  带宽是 MPLS TE 的基本属性之一，在建立 CR-LSP 时，可以指定其带宽，根据带宽要求确定合适的路径。RSVP-TE 信令可以携带带宽信息，在沿路径的各个节点实施带宽预留。CR-LSP 建立成功后，能够为对应的业务提供所要求的带宽保证。

- 显式路径

  CR-LSP 能够按照指定的路径建立，该路径称为显式路径。显式路径可以分为如下两种：

  - 严格显式路径

    所谓的严格显式路径，就是路径上每个节点都至少有一个接口的 IP 地址被指定。通过严格显式路径，可以最精确地控制 LSP 所经过的路径。

图 3-2 严格显式路径

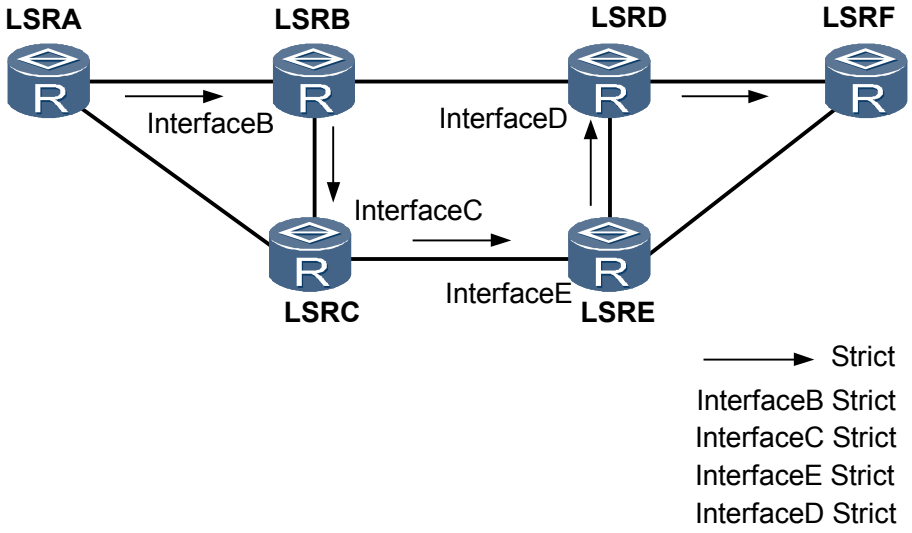

在图 3-2 中，LSRA 作为 LSP 的入节点，LSRF 作为出节点，从 LSRA 到 LSRF 用严格显式路径建立一条 LSP。“InterfaceB strict”表示该 LSP 必须经过 LSRB 的 InterfaceB 接口，并且 LSRB 的前一跳是 LSRA，“InterfaceC strict”表示该 LSP 必须经过 LSRC 的 InterfaceC 接口，并且 LSRC 的前一跳是 LSRB，依此类推，就可以精确控制该条 LSP 所经过的路径。

- 松散显式路径

  松散方式可以指定路径上必须经过哪些节点，而不严格指定路径。

图 3-3 松散显式路径

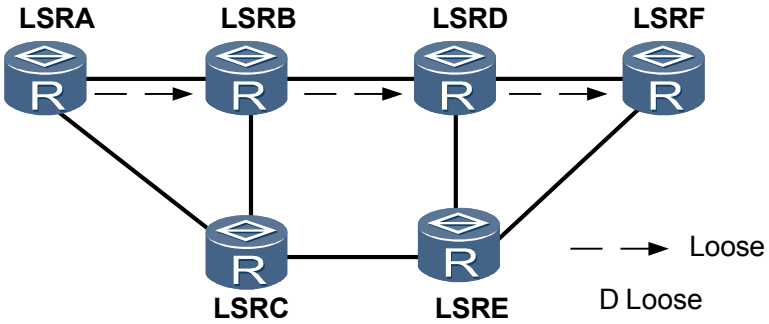

在图 3-3 中，从入节点 LSRA 到出节点 LSRF 用松散显式路径建立一条 LSP。“D loose”表示该 LSP 必须经过 LSRD，但是 LSRD 与 LSRA 之间可以存在其他 LSR 节点，不必直接相连。

MPLS TE 信令能够携带显式路径及其严格或松散属性，按照指定的路径建立 CR-LSP。

ERO（Explicit Route Object）描述 LSP 经过的路径信息，可以为严格显式路径也可以是松散显式路径。Path 消息沿 ERO 指定的路径转发，不受 IGP 最短路径约束。

- CSPF 仲裁策略

CSPF 在计算路径的过程中，如果遇到多条权值相同的路径，将根据策略选择其中的一条。这个过程称为仲裁（tie-breaking）。可用的仲裁策略有：

- Most-fill：选择已用带宽和最大可预留带宽的比值最大的链路，使链路带宽资源高效使用；
- Least-fill：选择已用带宽和最大可预留带宽的比值最小的链路，使各条链路的带宽资源均匀使用；
- Random：随机选取，使每条链路上的 LSP 数量均匀分布，不考虑带宽因素。

在比率相同的情况下，比如没有利用保留带宽，或者利用的份额都是一样，此时不管配置的是 least-fill 还是 most-fill，选择的是首先发现的链路。

- 优先级和抢占

  如果在建立 CR-LSP 的过程中，无法找到满足所需带宽要求的路径，则拆除另外一条优先级较低的 CR-LSP，占用为它分配的带宽资源，这种处理方式称为抢占（Preemption）。

  CR-LSP 使用两个优先级属性来决定是否可以进行抢占：建立优先级（Setup Priority）、保持优先级（Holding Priority）。优先级的取值为从 0 到 7 的整数。值越小，优先级越高。7 为最低优先级。

- 链路管理组和亲和属性

  链路管理组是一个表示链路属性的 32 位向量。

  亲和属性是一个 32 位向量，表示隧道链路的颜色。为隧道配置亲和属性后，隧道选择链路时，将亲和属性和链路管理组属性进行比较，决定选择还是避开特定属性的链路。

  在隧道入节点配置隧道亲和属性后，亲和属性将通过 RSVP-TE 信令协议传递给 CR-LSP 途经各节点。

- 跳数限制

  跳数限制值作为 CR-LSP 建立时的选路条件之一，就像管理组和亲和属性一样，可以限制一条 CR-LSP 允许选择的路径跳数不超过限制值。

- SRLG

  共享风险链路组 SRLG（Shared Risk Link Group）是一组共享一个公共的物理资源（或是共享一根光纤）的链路。同一个 SRLG 的链路具有相同的风险等级，即如果 SRLG 中的一条链路失效，组内的其他链路也失效。

  SRLG 主要用在 CR-LSP 热备份和 TE FRR 组网中增强 TE 隧道的可靠性。共享相同物理资源的多个链路具有相同的风险。例如，当主接口 Down 时，其子接口也通常变为 Down，所以子接口和主接口通常具有相同的风险。如果主隧道所在的链路和其备份隧道所在链路具有相同的风险，则主隧道变为 Down 时，备份隧道也很可能变为 Down。所以 SRLG 应该作为备份隧道路径计算的限制条件。

3.2 参考标准和协议

本特性的参考资料清单如下：

文档编号	描述	备注
RFC 2205	Resource ReSerVation Protocol	-
RFC 2209	Resource ReSerVation Protocol (RSVP) -- Version 1 Message Processing Rules	-

文档编号	描述	备注
RFC 2370	The OSPF Opaque LSA Option	-
RFC 2547	BGP/MPLS VPNs	-
RFC 2702	Requirements for Traffic Engineering Over MPLS	-
RFC 2747	RSVP Cryptographic Authentication	-
RFC 2961	RSVP Refresh Overhead Reduction Extensions	-
RFC 3031	Multiprotocol Label Switching Architecture	-
RFC 3032	MPLS Label Stack Encoding	-
RFC 3034	Use of Label Switching on Frame Relay Networks Specification	-
RFC 3209	RSVP-TE: Extensions to RSVP for LSP Tunnels	-
RFC 3210	Applicability Statement for Extensions to RSVP for LSP-Tunnels	-
RFC 3473	Generalized Multi-Protocol Label Switching (GMPLS) Signaling Resource ReserVation Protocol-Traffic Engineering (RSVP-TE) Extensions	-
RFC 3630	Traffic Engineering (TE) Extensions to OSPF Version 2	-
RFC 3784	Intermediate System to Intermediate System (IS-IS) Extensions for Traffic Engineering (TE)	-
RFC 4124	Protocol Extensions for Support of Diffserv-aware MPLS Traffic Engineering	-
RFC 4127	Russian Dolls Bandwidth Constraints Model for Diffserv-aware MPLS Traffic Engineering	-
RFC4128	Bandwidth Constraints Models for Differentiated Services (Diffserv)-aware MPLS Traffic Engineering: Performance Evaluation	-
RFC 4139	Requirements for Generalized MPLS (GMPLS) Signaling Usage and Extensions for Automatically Switched Optical Network (ASON)	-
draft-ietf-mpls-rsvp-lsp-fastreroute-02	Fast Reroute Extensions t o RSVP-TE for LSP Tunnels	-
draft-ietf-mpls-nodeid-subobject-01	Definition of an RRO node-id subobject	-
draft-ietf-tewg-diff-te-proto-02	Protocol extensions for support of Diff-Serv-aware MPLS Traffic Engineering	-

文档编号	描述	备注
draft-ietf-mpls-diff-te-reqts-00	Requirements for support of Diff-Serv-aware MPLS Traffic Engineering	-
draft-ietf-mpls-diff-ext-07	MPLS Support of Differentiated Services	-

3.3 原理描述

MPLS TE 通过建立一条保证带宽的 TE 隧道来进行标签转发及流量保证。

3.3.1 RSVP-TE 协议

资源预留协议 RSVP（Resource Reservation Protocol）是为 Integrated Service 模型而设计的，用于在一条 LSP 的各节点上进行资源预留。RSVP 工作在传输层，但不参与应用数据的传送，是一种网络上的控制协议。RSVP-TE 是对 RSVP 的扩展，通过扩展对象支持 TE（Traffic Engineering）的相关属性，用于基于约束的 LSP 的建立和删除。

简单来说，RSVP 具有以下几个主要特点：

- 单向；
- 面向接收者，由接收者发起对资源预留的请求，并维护资源预留信息；
- 使用“软状态”（soft state）机制维护资源预留信息。

RSVP-TE 对 RSVP 扩展的内容主要有：

- 在 RSVP 的 PATH 消息中引入 Label Request 对象，支持发起标签请求；在 RSVP Resv 消息中引入 Label 对象支持标签分配。这样就可以建立 CR-LSP 了。
- 扩展的消息除了可以携带标签绑定信息外，还可以携带限制信息，从而支持 CR-LSP 约束路由的功能。
- 此外，RSVP-TE 通过扩展对象支持 MPLS-TE 相关的属性，使其具有资源预留功能。

RSVP-TE 主要消息

RSVP-TE 消息有：Path 消息、Resv 消息、PathErr 消息、ResvErr 消息、PathTear 消息、ResvTear 消息、ResvConfirm 消息、Hello 消息、Ack 消息、Srefresh 消息、GRPath 消息和 Recovery Path 消息。

RSVP-TE 主要包括如下消息：

- Path 消息：Path 消息用于发送者请求下游节点为此路径分配标签。途经每一个节点时记录路径信息，并且建立路径状态块 PSB（Path State Block）。
- Resv 消息：Resv 消息用于在各个节点预留资源。Resv 消息携带了发送者申请的资源预留信息，沿着数据流的反方向发送，在沿途节点创建预留状态块 RSB（Reserved State Block），记录分配的标签信息。

- PathErr 消息：RSVP 节点在处理 Path 消息的时候，如果发生错误，就向上游发送 PathErr 消息。中间节点收到 PathErr 消息后，继续向上游转发，直至入节点。
- ResvErr 消息：RSVP 节点在处理 Resv 消息时，如果发生错误，就向下游发送 ResvErr 消息；中间节点收到 ResvErr 消息后，继续向下游转发消息，直至出节点。
- PathTear 消息：由入节点向下游发送，用于删除各个节点创建好的本地状态。
- ResvTear 消息：由出节点向上游发送，用于删除对应的本地资源等。入节点收到 ResvTear 消息后，向下游发送 PathTear 消息。

LSP 建立过程

图 3-4 LSP 建立过程图

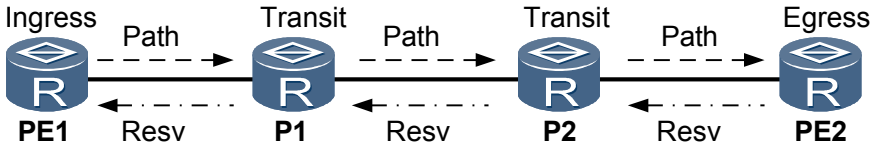

如图 3-4 所示，LSP 的建立过程如下：

1. Ingress 节点收到建立 LSP 的消息后创建 PSB，向下游发送 Path 消息。
2. Transit 节点处理并转发 Path 消息，在各个节点根据 Path 消息创建 PSB。
3. Egress 节点收到 Path 消息后创建 PSB，根据 Path 消息生成 Resv 消息，同时创建 RSB 等状态块，并且向上游发送 Resv 消息。
4. Transit 节点处理并转发 Resv 消息，创建 RSB 等状态块。
5. Ingress 节点收到 Resv 消息后，创建 RSB 等状态块，确认资源预留成功。

至此，一条 LSP 建立成功。

软状态

RSVP 节点周期性的发送 RSVP 刷新消息，用于在 RSVP 邻居节点进行状态（包括 PSB 和 RSB）同步，或恢复丢失的 RSVP 消息，这就是 RSVP 的“软状态”机制。对于某个状态，如果在指定刷新周期内没有收到刷新消息，这个状态将被删除。

当有状态需要刷新时，节点会创建对应的刷新消息，并发送给它的后续节点。当路由发生变化时，如果使能隧道重优化，下一个 Path 消息会基于新的路由初始化路径状态，之后的 Resv 消息将在新路径上建立预留状态。不再使用的路径状态将会超时删除。

预留风格

资源预留风格是指 RSVP 节点处理上游节点的资源预留请求时的资源预留方式。当前华为支持的资源预留风格包括：

- FF（Fixed Filter）：即固定过滤风格，为每个发送者创建固定的预留，每个发送者的预留都是相互独立的，并且分配唯一的标签。
- SE（Shared Explicit）：即共享显式风格，为接收者显式地指定一个预留中的发送者，这些发送者共享同一个预留，分配不同的标签。

3.3.2 Make-before-break

Make-before-break 是一种高可靠性的 CR-LSP 切换技术。在创建新的 CR-LSP 时，先不删除原有的 CR-LSP。当新的 CR-LSP 建立成功后，先将流量切换到新的 CR-LSP 上，再删除原来的 CR-LSP，保证业务流量不中断。

图 3-5 Make-before-break 基本原理

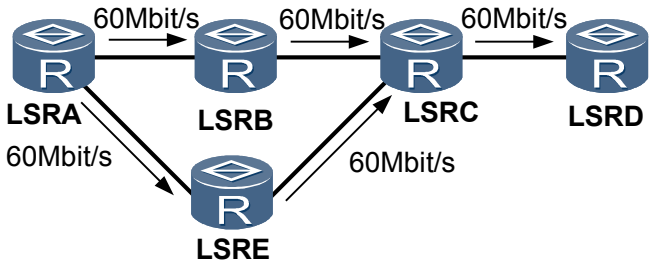

Make-before-break 机制常用的方式如下：

- 修改路径

  如图 3-5，假设所有链路最大可预留带宽为 60Mbit/s。新建一条 LSRA 到 LSRD 的 CR-LSP，路径是 LSRA→LSRB→LSRC→LSRD，带宽为 40Mbit/s。现在希望将路径改为 LSRA→LSRE→LSRC→LSRD，通过负载较轻的 LSRE 进行数据转发。但是 LSRC→LSRD 上剩余的可预留带宽只有 20Mbit/s，不足 40Mbit/s。这时可以通过 Make-before-break 机制来解决。

  通过 Make-before-break，新建立的路径 LSRA→LSRE→LSRC→LSRD 在 LSRC→LSRD 上进行资源预留时采用原路径使用的带宽。新隧道建立成功后，流量转到新路径上后拆除原路径。

- 增加隧道的带宽

  只要共用链路的可预留带宽满足增量要求，新的 CR-LSP 就可以建立成功。如图 3-5，假设所有链路最大可预留带宽为 60Mbit/s。新建一条 LSRA 到 LSRD 的 CR-LSP，带宽为 30Mbit/s，路径是 LSRA→LSRB→LSRC→LSRD。现在希望将路径改为 LSRA→LSRE→LSRC→LSRD，通过负载较轻的 LSRE 进行数据转发，并将带宽增大为 40Mbit/s。但是 LSRC→LSRD 上剩余的可预留带宽只有 30Mbit/s，不足 40Mbit/s。这时可以通过 Make-before-break 机制来解决。

  通过 Make-before-break，新建立的 CR-LSP 的路径 LSRA→LSRE→LSRC→LSRD 在 LSRC→LSRD 上进行资源预留时采用原路径使用的带宽，并追加 10Mbit/s 增量带宽。新的 CR-LSP 建立成功后，流量转到新路径上后拆除原路径。

3.3.3 重优化

重优化是重新计算隧道需要的路径，完成对隧道路径的优化。

流量工程一个主要的目标就是优化网络上流量的分布。隧道建立之后，可以根据网络上的带宽变化、流量变化、管理策略变化等对已经建立的 CR-LSP 进行优化。当某条隧道发现更优的路径时，可以对其进行优化。即当出现了 Metric 值更小的路径时，会重新建立 CR-LSP。

隧道重优化有两种方式：

- 自动重优化：根据自动重优化机制，用户可以指定路径优化的时间间隔。在时间到达时，CR-LSP 会主动发现更优的路径来进行优化。
- 手工重优化：除了自动重优化，用户也可以通过配置方式直接触发 CR-LSP 进行优化，重新请求计算更优路径来建立 CR-LSP。

在优化时，用户的业务流不中断是非常重要的。即新的 CR-LSP 必须先建立，业务在旧的 CR-LSP 被拆除前切换到新的 CR-LSP 上。在新旧 CR-LSP 共享的链路上，由于旧的 CR-LSP 使用的资源不能在新的 CR-LSP 建立前释放，共享链路上资源是否被计算两次非常关键。这是因为可能会由于资源的缺乏而造成新的 CR-LSP 无法建立。

RSVP-TE 信令的 SE 预留风格能够非常好的解决这个问题，SE 预留风格允许新旧 CR-LSP 共享资源，使新的 CR-LSP 不会因为链路资源缺乏而必须等到旧的 CR-LSP 拆除才能完成。

说明

- 缺省情况下，不进行重优化。定时重优化的缺省时间间隔是 3600 秒。
- 如果使用自动重优化，则不能同时使用自动带宽调整。
- 如果隧道的资源预留为固定过滤风格 FF，则不能配置 CR-LSP 重优化。
- 当 Bypass 隧道保护的主 LSP 处于 FRR Inuse 状态时，Bypass 隧道不进行重优化处理。
- 静态 LSP 和静态 CR-LSP 不支持重优化。

隧道重优化的实现如下：

- 对于自动重优化，是根据用户配置的时间，重新触发 CSPF 计算该隧道的路径。如果 CSPF 计算出来的路径比现有路径的 Metric 值更小，则以新的路径创建 CR-LSP。若建立成功则通知转发层面进行流量切换，删除原 CR-LSP，重优化完成。若建立不成功，则流量还按照原路径转发。
- 对于手动重优化，是在用户视图下输入重优化命令，触发进行重优化。

3.3.4 TE FRR

TE FRR 是 MPLS TE 中的一种局部性保护机制，用于保护 CR-LSP 的链路和节点故障，而且可以对主 LSP 配置带宽保护或非带宽保护。

TE FRR 通过预先建立绕过故障的链路或者节点的 Bypass 隧道达到保护主 CR-LSP 的目的。当 CR-LSP 链路或节点故障时，允许流量继续从旁路隧道传输，同时头节点可以在数据传输不受影响的同时继续发起主路径的重建。

FRR 中涉及的概念：

- 主 CR-LSP：被保护的 CR-LSP。
- Bypass CR-LSP：保护主 CR-LSP 的 CR-LSP。Bypass CR-LSP 的入节点是 PLR，出节点是 MP。Bypass CR-LSP 一般处于空闲状态，不承载业务。如果需要使用 Bypass CR-LSP 保护主 CR-LSP 的同时承载业务数据的转发，需要为 Bypass CR-LSP 分配足够的带宽。
- PLR（Point of Local Repair）：本地修复节点。Bypass CR-LSP 的入节点，必须在主 CR-LSP 的路径上，可以是主 CR-LSP 的入节点，但不能是主 CR-LSP 的出节点。
- MP（Merge Point）：汇聚点。Bypass CR-LSP 的出节点，必须在主 CR-LSP 的路径上，并且不能是主 CR-LSP 的入节点。
- 链路保护：如图 3-6，PLR 和 MP 之间有直连链路（LSRB→LSRC）连接，主 CR-LSP 经过这条链路。当这条链路失效时，流量可以切换到 Bypass CR-LSP（LSRB→LSRF→LSRC）上。

图 3-6 链路保护示意图

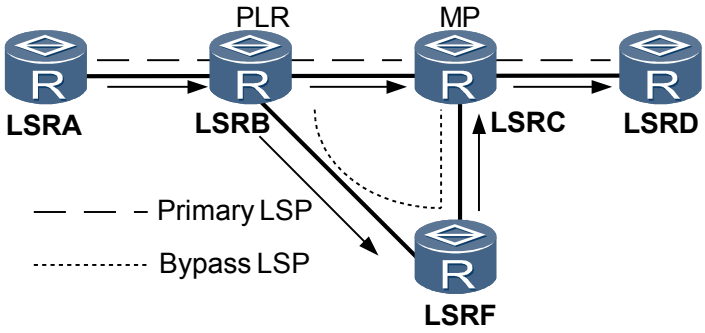

- 节点保护：如图 3-7，PLR 和 MP 之间存在一台 LSR（LSRB→LSRC→LSRD），主 CR-LSP 经过该节点（LSRC）。当该节点失效时，流量可以切换到 Bypass CR-LSP（LSRB→LSRF→LSRD）上。

图 3-7 节点保护示意图

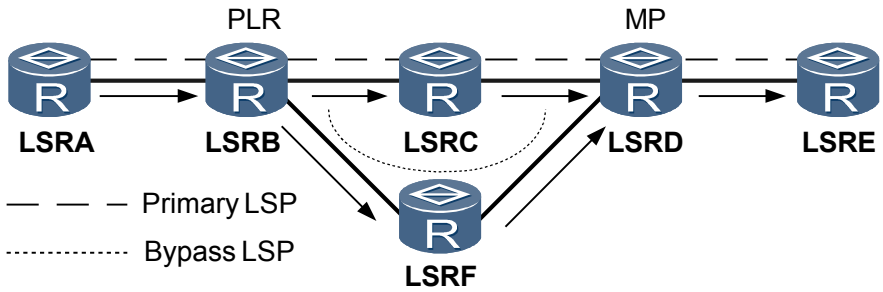

- 主 CR-LSP 的建立

  主 CR-LSP 的建立过程与普通 CR-LSP 的建立过程一致，不同之处主要是：建立主 CR-LSP 过程中，隧道入节点会在 Path 消息中添加局部保护标记、记录路由标记和 SE 风格标记。如果需要进行带宽保护，则在该对象中添加带宽保护标记。

- 绑定旁路隧道

  为主 CR-LSP 寻找合适的 Bypass CR-LSP 的过程称为绑定。只有具有局部保护标记的主 CR-LSP 才会触发绑定策略，绑定是在隧道切换之前完成的。绑定过程中，节点需要计算出 Bypass CR-LSP 的出接口、NHLFE、MP 的 LSR ID、MP 分配的标签及保护的类型等信息。

  对于入节点和中间节点而言，主 LSP 的下一跳（NHOP）或下下一跳（NNHOP）是已知的。如果 Bypass LSP 的 Egress LSR ID 与 NHOP 的 LSR ID 相等，就可以形成链路保护；如果 Bypass CR-LSP 的 Egress LSR ID 与 NNHOP 的 LSR ID 相等，就可形成节点保护。

  当有多条 Bypass CR-LSP 可以保护同一条 CR-LSP 时，首先选择满足用户带宽配置需求的 Bypass CR-LSP，如果同时满足用户带宽配置需求，则节点保护优于链路保护，手工保护优于自动保护。

如果旁路隧道绑定成功，主 CR-LSP 的下一跳标签转发项 NHLFE（Next Hop Label Forwarding Entry）表项中记录 Bypass CR-LSP 的 NHLFE 表项索引以及 MP 为上一个节点分配的标签，即内层标签。内层标签用于 FRR 切换时的流量转发。

- 故障检测

  链路保护直接使用链路层协议实现故障检测和通告，链路层发现故障的速度与链路类型直接相关。节点保护则使用链路协议检测链路故障，在链路没有故障的情况下，可以通过配置 BFD 机制检测被保护节点的故障。

  对于节点保护，只保护被保护节点及其与 PLR 之间的链路。对于被保护节点和 MP 之间的链路故障，PLR 无法感知。

  无论是检测到链路故障还是节点故障，最终都会导致 PLR 上的出接口被置为老化状态。出接口老化就会触发 FRR 的流量切换。

- 切换

  切换是指主 CR-LSP 故障后，业务流量和 RSVP 消息从主 CR-LSP 切换到 Bypass CR-LSP 上，并向上游通告切换已经发生。在切换的时候，主 CR-LSP 的 NHLFE 表项会被置上切换标志。

- 回切

  切换后，PLR 会向上游发送携带切换标记的 PathError 消息。Ingress 收到该消息，试图重建主 CR-LSP，但不拆除主 CR-LSP，而是借用 Bypass CR-LSP 作为主 CR-LSP 继续转发数据，直到主 CR-LSP 重建成功。尝试重建的 CR-LSP 称为 Modified CR-LSP。

  当主 CR-LSP 重建成功后，业务流量和 RSVP 消息需要从 Bypass CR-LSP 回切到主 CR-LSP 上。此过程，TE FRR（包括 Auto FRR）采用 Make-before-break 机制，即只有 Modified CR-LSP 建立成功后，原来的 Primary CR-LSP 才能被删除。

图 3-8 TE FRR 示意图

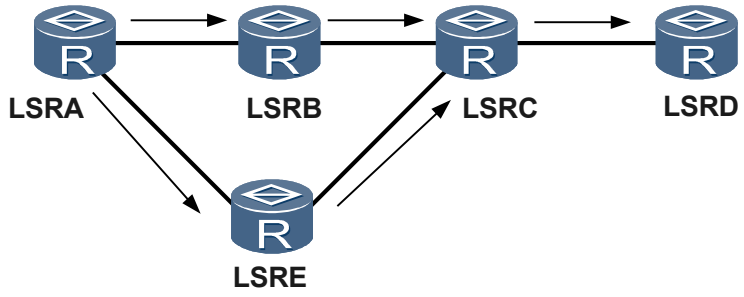

例如图 3-8，TE FRR 的主路径为 LSRA→LSRB→LSRC→LSRD；旁路隧道的路径为 LSRA→LSRE→LSRC；LSRB 为被保护节点。

当主路径故障时，借用 Bypass CR-LSP 作为主 CR-LSP 继续转发数据 LSRA→LSRE→LSRC→LSRD，并尝试建立 Modified CR-LSP。Modified CR-LSP 使用原路径建立成功后，流量转到 Modified CR-LSP 上，重新切回主路径 LSRA→LSRB→LSRC→LSRD，原来的主 CR-LSP 拆除。

Auto TE FRR

TE FRR 要求在配置被保护隧道的时候，需要手工配置一条旁路隧道来与之绑定，当出现链路或节点故障时，可以将数据切换到旁路隧道。

这种 FRR 保护需要手工配置旁路隧道，如果没有配置，或者旁路隧道配置不符合要求，将无法对被保护隧道进行保护。为了简化配置并保持 FRR 特性，Auto TE FRR 在这样的情形下应运而生。

在使能了 Auto TE FRR 的节点上建立一条要求 FRR 保护的主隧道，并且可以为主隧道配置带宽保护或非带宽保护，系统将自动尝试建立一条符合条件并最优的 Auto Bypass CR-LSP。在建立成功后，所建立的 Auto Bypass CR-LSP 也能对主 CR-LSP 进行保护。

Auto TE FRR 实现原理与手工配置的 TE FRR 一样，区别仅在于手工 TE FRR 需要手工配置 Bypass Tunnel，而 Auto FRR 的 Bypass Tunnel 是由系统根据策略自动计算生成的，此处不再赘述。

TE FRR 几种保护的优先顺序

FRR 可分为：

- 节点保护与链路保护
- 手工保护与自动（Auto）保护

其中，带宽保护与非带宽保护是根据用户配置，没有优先级之分。如果需要选择，则首先选择满足用户带宽配置需求的 Bypass CR-LSP，如果同时满足用户带宽配置需求，则节点保护优于链路保护，手工保护优于自动保护。

部署 TE FRR

TE FRR 是 MPLS TE 中的一种局部性保护机制。在配置 Bypass CR-LSP 时，应该规划好它所保护的链路或节点，并确保该 Bypass CR-LSP 不会经过它所保护的链路或节点，否则不能真正起到保护作用。

FRR 不支持多点故障。即，如果发生了 FRR 切换，数据从主 CR-LSP 切换到 Bypass CR-LSP，在数据通过 Bypass CR-LSP 转发期间，Bypass CR-LSP 的状态必须始终保持 UP。一旦 Bypass CR-LSP 在此期间出现故障，被保护的数据将不能通过 MPLS 转发，从而可能出现流量中断，FRR 功能失效。即使 Bypass CR-LSP 重新建立，流量也无法转发，只能等待主 CR-LSP 恢复或重新创建后，流量才恢复转发。

TE FRR 支持 N:1 的保护模式，即一条 Bypass 隧道可以保护多条主隧道。

另外，FRR 的 Bypass 隧道需要预先建立，这需要占用额外的带宽。在网络带宽余量不多的情况下，只能对关键的链路或节点进行 FRR 保护。

3.3.5 SRLG

SRLG（Shared Risk Link Group，共享风险链路组）是具有相同故障风险的一组链路集合。即如果其中一条链路失效，那么组内的其他链路也可能失效，这种情况下使用组内的其他链路作为失效链路的热备份 CR-LSP 或 FRR Bypass 隧道，将起不到保护的作用。

SRLG 是链路属性，用数值表示，数值相同的链路表示属于同一个共享风险链路组。部署 SRLG 可以约束热备份 CR-LSP 和 FRR Bypass 隧道路径的选择，避免了主、备隧道建立在具有相同故障风险的链路上。

图 3-9 SRLG 示意图

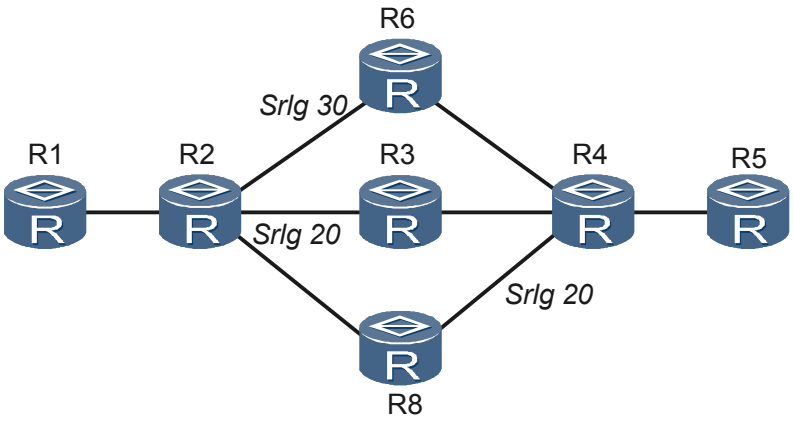

如图 3-9 所示，以 TE FRR 为例，主隧道路径为 R1-R2-R3-R4-R5，其中链路 R2-R3-R4 需要 FRR Bypass 隧道保护。而在 R2 上满足要求的 Bypass 隧道共有两条，路径分别是 R2-R6-R4 和 R2-R8-R4。

在部署的时候发现，当链路 R2-R3 发生故障时，链路 R8-R4 通常也会发生故障，即两条链路存在相同的故障风险。如果选择 R2-R8-R4 作为 Bypass 隧道，当链路 R2-R3 出现故障时，链路 R8-R4 也可能出现故障，这样就失去了保护的意义。

因此在配置隧道之前，建议先收集并配置链路的 SRLG 信息。将 R2-R3 和 R8-R4 之间的链路配置相同的 SRLG 值，即两条链路处于相同的共享风险链路组，这样就可以保证主隧道优先选择与其不在相同共享风险链路组的 Bypass 隧道。

实现原理

SRLG 是通过 IGP 协议对 TE 属性的扩展来发布的。根据 CSPF 计算路径时，不仅会考虑带宽等约束条件，同时将 SRLG 作为约束条件来计算。

MPLS TE SRLG 具有两种操作模式：

- 严格 SRLG 模式（strict mode）：对热备份 LSP 和 FRR Bypass 隧道路径的计算，必须考虑 SRLG 的约束条件；
- 首选 SRLG 模式（preferred mode）：对热备份 LSP 和 FRR Bypass 隧道计算路径时候可以不考虑 SRLG 的约束条件。例如，当 Tunnel 配置了 hot-standby 时，如果第一次 CSPF 考虑 SRLG 约束计算备份路径失败，那么第二次进行算路的时候将不会考虑 SRLG 的约束条件。

SRLG 的操作模式及接口的 SRLG 信息都是在本地配置的。但是链路的 SRLG 信息可以通过 IGP 路由通告给整个域，即相同域中的节点能够获取域内所有链路的 SRLG 信息。CSPF 在计算路径的时候，根据当前节点配置的操作模式及 SRLG 约束信息进行路径计算。

3.3.6 CR-LSP 备份

同一条隧道下对主 CR-LSP 进行路径备份的 CR-LSP 称为备份 CR-LSP。

备份 CR-LSP 用于实现对重要 LSP 的流量保护。作为流量保护的一个重要组成部分，在主 CR-LSP 失败后，流量需要及时被切换到备份隧道上。

当入节点感知到主 CR-LSP 不可用时，将流量切换到备份路径上，当主 CR-LSP 路径恢复后再将流量切换回来，以实现对主 CR-LSP 路径的备份保护。

CR-LSP 的备份有热备份和普通备份两种方式。

- 热备份（Hot-standby）：指主 CR-LSP 成为 Up 状态后创建备份 CR-LSP。主 CR-LSP 失效时，将业务切换至备份 CR-LSP。当主 CR-LSP 恢复时，将业务切回到主 CR-LSP。热备份 CR-LSP 可以支持逃生路径。
- 普通备份：指主 CR-LSP 失效后创建备份 CR-LSP。主 CR-LSP 失效时，将业务切换至备份 CR-LSP。当主 CR-LSP 恢复时，将业务切回到主 CR-LSP。
- 逃生路径

  热备份方式支持逃生路径。在主、备 CR-LSP 都故障时，可触发建立一条临时的 CR-LSP，称为逃生路径，流量将切换到逃生路径上。

  如图 3-10，主 CR-LSP 路径为 PE1→P1→PE2；备份 CR-LSP 路径为 PE1→P2→PE2。当主备 CR-LSP 都故障时，PE1 触发建立逃生路径 PE1→P2→P1→PE2。

图 3-10 逃生路径示意图

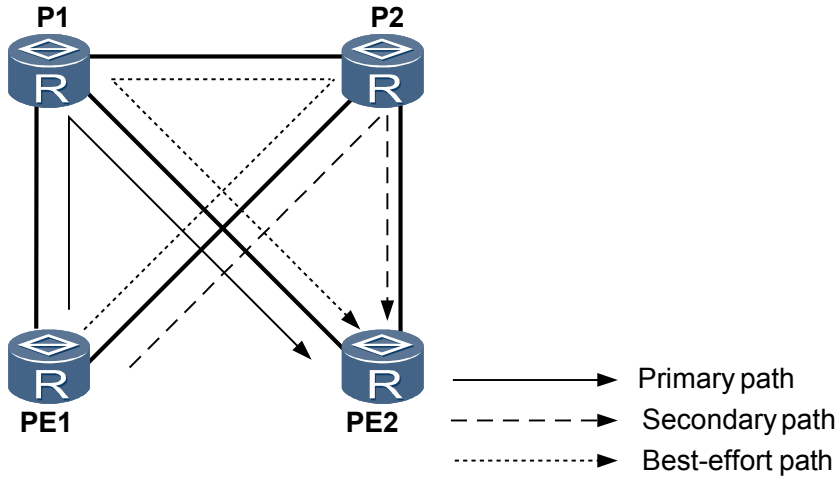

说明

逃生路径没有带宽保证，可以根据需要配置逃生路径的亲和属性和跳数限制。

与其他特性的比较

1. CR-LSP 备份与 TE FRR 的区别
   - CR-LSP 备份是一种端到端的路径保护（Path Protection，End-to-End Protection），提供整条 LSP 的保护。
   - FRR 则是一种局部保护措施，只能保护 LSP 中的某条链路和某个节点，并且，FRR 是一种快速响应的临时性保护措施，对于切换时间有严格要求。
2. 隧道备份常常和快速重路由联合部署

   在普通的联合部署网络中：
   - CR-LSP 热备份与 TE FRR 结合使用：快速重路由可以及时响应链路故障，将流量在最短的时间内切换到旁路隧道上。链路故障信息通过信令带到入口节点，然后将流量切换到备份隧道上。

- CR-LSP 普通备份与 TE FRR 结合使用：快速重路由可以及时响应链路故障，将流量在最短的时间内切换到旁路隧道上。当 TE FRR 的主隧道和旁路隧道都出现故障之后，才会建立备份隧道并将流量切换到备份隧道上。

  说明

  如果主隧道使能了旁路保护隧道与备份 CR-LSP 同步功能，当主 CR-LSP 出现故障时，流量会切换到 TE FRR 的旁路保护隧道并尝试恢复主 CR-LSP 的同时，也会尝试创建备份 CR-LSP。当备份 CR-LSP 创建成功，并且主 CR-LSP 未恢复时，流量会切换到备份 CR-LSP。

3.3.7 BFD For TE CR-LSP

传统的检测机制，依靠包括 RSVP Hello 检测或者依靠 RSVP 刷新超时等检测，都具有检测速度缓慢的缺点。BFD 检测机制很好的克服了这些缺点，BFD 采用快速收发报文的机制，完成对隧道链路故障的快速检测，从而引导隧道上承载业务的快速切换，达到业务保护的目的。

图 3-11 BFD 检测示意图

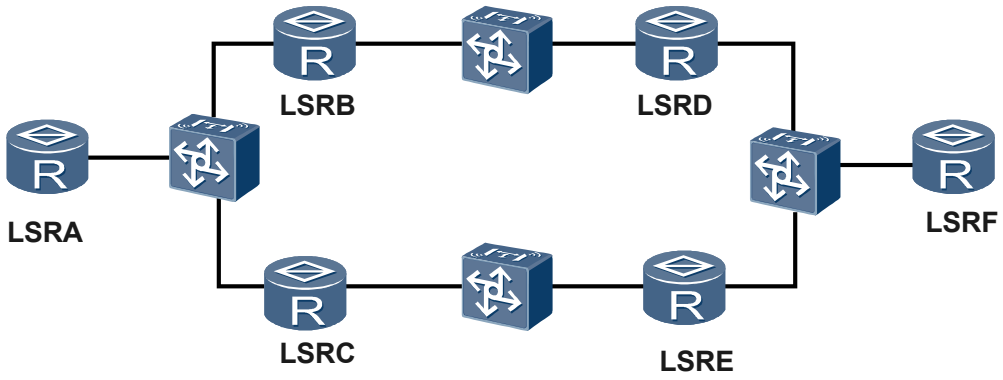

如图 3-11 所示，如果没有应用 BFD 检测，在 LSRE 发生故障时，由于二层交换机的出现，导致 LSRA 和 LSRF 无法立刻感知到故障发生；转而由 Hello 协议来检测，但会出现检测时间长的问题。

如果 LSRA、LSRB、LSRC、LSRD、LSRE 和 LSRF 全部应用 BFD，当 LSRE 发生故障时，LSRA 和 LSRF 会在很短的时间内检测到故障发生，并使数据流切换到 LSRA→LSRB→LSRD→LSRF。

BFD for TE CR-LSP 是对 CR-LSP 的检测，能够快速检测到 CR-LSP 的故障，并及时通知转发层面，从而保证流量的快速切换。BFD for TE CR-LSP 通常与 hot-standby CR-LSP 或者隧道保护组配合使用。

BFD 中涉及的基本概念：

- 静态 BFD 会话：本端标识符和对端标识符都需要手工指定，两端标识符必须匹配，否则会话无法建立。会话建立后，发送和接收时间间隔参数可以修改。
- 动态 BFD 会话：不需要指定本端标识符和对端标识符。路由协议邻居关系建立后，RM 会下发参数通告 BFD 建立会话，会话通过协商来确定本端标识符、对端标识符、发送和接收时间间隔参数。
- 检测周期：用于检测 BFD 会话是否正常的时间间隔。如果在检测周期内没有收到远端系统发送来的报文，则认为会话 down。

BFD 会话与 CR-LSP 绑定，即在入节点和出节点之间建立 BFD 会话。BFD 报文从源端开始经过 CR-LSP 转发到达宿端；宿端再对该 BFD 报文进行回应，通过此方式在源端可以快速检测出 CR-LSP所经过链路的状态。

当检测出链路故障以后，BFD 将此信息上报给产品转发模块。转发模块查找备份 LSP，然后将业务流量切换到备份 CR-LSP 上。然后产品转发模块再将故障信息上报给控制层面，如果采用的是动态 BFD for TE CR-LSP，控制层面会主动去创建备份 CR-LSP 的 BFD 会话。如果采用的是静态 BFD for TE CR-LSP 时且需要对备份 CR-LSP 进行检测，则可以为其配置 BFD 检测。

图 3-12 BFD 会话切换前后示意图

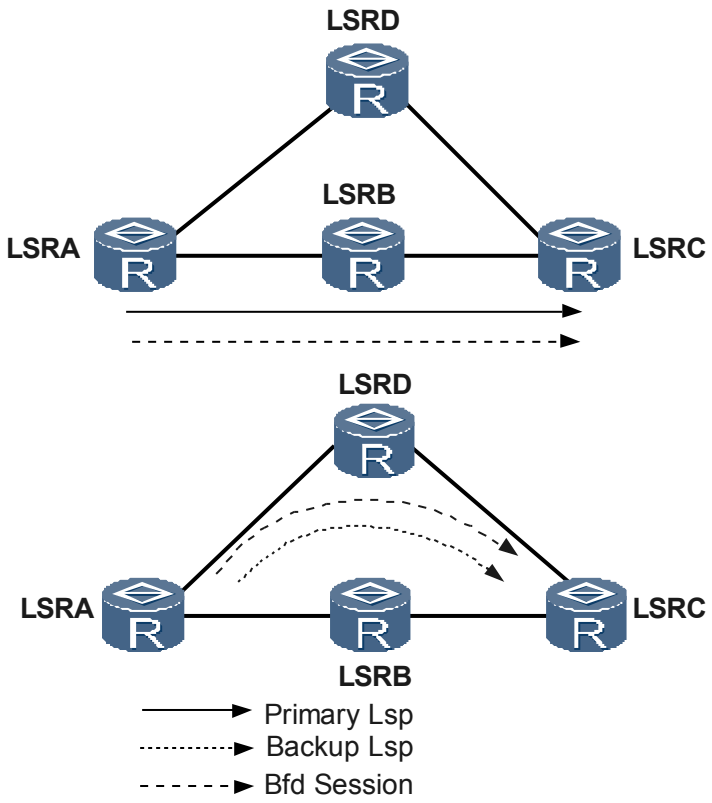

如图 3-12 所示，BFD 建立会话检测主 CR-LSP 所经过的链路。当主 CR-LSP 所经过的链路出现故障以后，在源端 BFD 会立即通告该故障信息。然后入节点将流量切换至备份 CR-LSP，同时在备份 CR-LSP 所经过的路径上建立新的 BFD 会话，用于检测备份 CR-LSP 所经过的链路状态。

BFD for TE 的部署

图 3-13 BFD for TE 部署

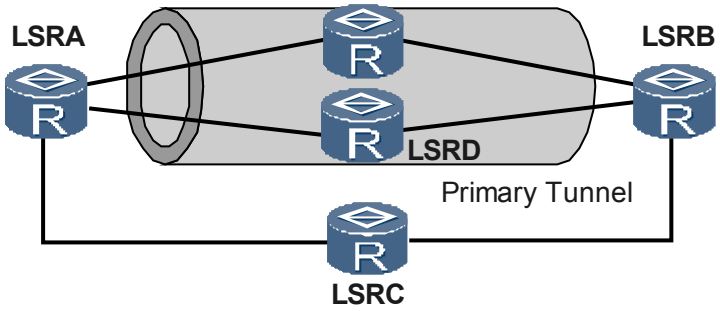

1. 主 CR-LSP 和热备份 CR-LSP 之间的切换

   如图 3-13，在 LSRA→LSRB 之间建立一条主隧道，同时配置热备份 CR-LSP。在 LSRA 上建立一个到 LSRB 的 BFD 会话，用于检测该隧道中的主 CR-LSP。当主 CR-LSP 链路出现故障时，BFD 会快速通知 LSRA。LSRA 收到故障信息以后，立即将流量切换到热备份 CR-LSP 上，从而保证流量不中断。

2. 主隧道和备份隧道之间的切换

   如图 3-13，在 LSRA→LSRD→LSRB 之间建立一条主隧道，同时在 LSRA→LSRC→LSRB 之间建立一条备份隧道。在路径 LSRA→LSRD→LSRB 上建立一个 BFD 会话，用于检测主隧道的路径。当主链路出现故障时，BFD 会快速通知 LSRA。LSRA 收到故障信息以后，立即将流量切换到备份隧道上，从而保证流量不中断。

3.3.8 BFD for TE Tunnel

双向转发检测 BFD（Bidirectional Forwarding Detection）主要用于检测转发引擎之间的通信故障。具体来说，BFD 是对两个系统间的、同一路径上的一种数据协议（data protocol）的连通性进行检测。这条路径可以是物理链路或逻辑链路，其中就包括 TE 隧道。

BFD for TE Tunnel 是使用 BFD 检测整条 TE 隧道，可触发 VPN FRR 应用在主路径故障时进行快速流量切换，以减少对业务的影响。

VPN FRR 的技术场景下，在 PE1 和 PE2 之间部署隧道，且对该隧道进行 BFD 检测。如果 BFD 检测出该隧道故障，则实现 VPN FRR 毫秒级的快速倒换。

TE 隧道在部署 BFD for TE Tunnel 业务后，无法再部署 MPLS OAM 检测业务。

3.3.9 RSVP 认证

RSVP 使用 RawIP 传递协议报文，而 RawIP 本身不提供安全性，报文容易被篡改，设备容易受到攻击。RSVP 消息通过验证摘要信息的正确性，来防止消息被篡改或伪造的恶意攻击，增强网络的可靠性和安全性。

基本原理

在需要认证的两个节点上，用户需要配置相同的密钥。在发送报文时，节点使用密钥为报文计算得到一个摘要（通过 HMAC-MD5 算法），摘要信息作为报文的一个对象

（Integrity 对象），随着报文一起发送到对端节点。对端节点使用相同的密钥、相同的算法重新计算报文摘要，然后比较两个摘要是否相同，如果相同则接受，否则丢弃。

RSVP 认证不能防止回放攻击，也无法解决因 RSVP 报文的失序导致邻居之间认证关系终止的问题。为了解决该问题，引入了 RSVP 认证增强功能。RSVP 认证增强是在基于原有认证的基础上增加了认证生存时间、握手和消息滑窗等特性，这样使得 RSVP 自身的安全性得到很大的提高，并大大加强了在网络阻塞等恶劣网络环境时对用户进行身份验证的能力。

RSVP 密钥管理方式

RSVP 密钥管理包括以下两种方式：

- MD5 密钥

  用户可以在 RSVP 接口、邻居下，以明文或者密文的方式输入密钥，密钥算法为 MD5。这种密钥管理方式的特点是：

  - 每个协议特性都需要配置自己的密钥，密钥不能共享。
  - 每个接口、邻居只能配置一个密钥，要更换密钥必须重新配置。

- Keychain 密钥

  Keychain 是一种增强型加密算法，允许用户定义一组密码，形成一个密码串，并且分别为每个密码指定加解密算法及密码使用的有效时间。在收发报文时，系统会按照用户的配置选出一个当前有效的密码，并按照与此密码相匹配的加密解密算法，进行发送时加密和接收时解密报文。此外，系统可以依据密码使用的有效时间，自动完成有效密码的切换，避免了长时间不更改密码导致的密码易破解问题。

  这种密钥管理方式的特点是：

  - Keychain 的密码、所使用的加解密算法以及密码使用的有效时间可以单独配置，形成一个 Keychain 配置节点，每个 Keychain 配置节点至少需要配置一个密码，并指定加解密算法。
  - Keychain 可以被各个协议特性引用，实现密钥集中管理、多特性共享。

  RSVP 支持在接口、邻居下引用 Keychain，并仅支持 HMAC-MD5 算法。

RSVP 的认证级别

RSVP 的认证级别分为两种：

- 面向邻居的认证

  该级别的认证是指用户可以根据不同的邻居地址配置认证密钥等信息，RSVP 会针对每个邻居进行单独的认证。

  有两种配置方式：

  - 以邻居设备的某接口的 IP 地址作为邻居地址进行配置。
  - 以邻居设备的 LSR ID 作为邻居地址进行配置。

- 面向接口的认证

  用户在接口上配置认证，RSVP 会根据消息的入接口进行认证处理。

这两个认证级别的优先级顺序由高到低依次为：面向邻居的认证、面向接口的认证。只有当高优先级没有使能认证的情况下才会进行低优先级的认证处理，一旦高优先级认证没有通过，则丢弃该报文。

3.3.10 RSVP GR

RSVP GR（Graceful Restart）是 RSVP-TE 的一种状态恢复机制。

RSVP GR 功能基于无间断转发 NSF（Non-Stop Forwarding）思想设计。当节点控制层面发生故障时，通过上下游邻居发送消息对节点的 RSVP 软状态进行恢复，而转发层面则不感知故障也不受故障影响，从而保证了流量的稳定性和可靠性。

RSVP GR 通过 Hello 特性扩展来检测邻居的 GR 状态，关于 Hello 特性的相关描述请参见 **RSVP Hello**。

RSVP GR 的实现机制如下：

如图 3-14，重启节点 GR 后，将停止向邻居节点发送 Hello 消息。使能了 GR 的邻居节点在连续 3 次未收到 Hello 消息后，认为邻居在做 GR，所有的转发信息都将继续保持。同时接口板继续传输业务，并等待重启节点进行 GR 恢复。

在重启节点启动后，如果收到邻居的 Hello 消息，会向邻居节点发送 Hello 消息，处于隧道上游和下游节点的处理方式是不一样的：

- 上游的支持节点收到该消息后，向重启节点（自己的下游）发出 GR Path 消息。
- 下游的支持节点收到该消息后，向重启节点（自己的上游）发出 Recovery Path 消息。

图 3-14 通过 GR Path 消息和 RecoveryPath 消息重建示意图

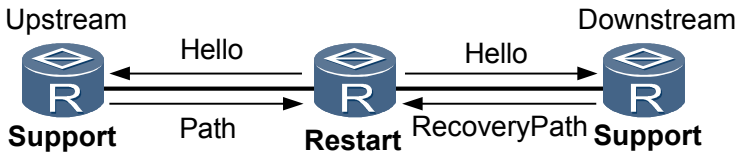

当重启节点收到 GR Path 消息和 Recovery Path 消息时，根据这两个消息重新建立 LSP 相关的状态信息，这样本地控制层面信息就恢复了。

若下游支持节点不能发送 Recovery Path 消息，则本地状态仅通过 GR Path 消息来重建。

3.3.11 RSVP 摘要刷新

在不用传输整个 RSVP 刷新消息的情况下，仅传输刷新消息对应的很小的摘要来维护 RSVP 软状态，同时响应 RSVP 状态变化。

每个 RSVP 会话都需要在每个刷新周期内产生、传送、接收和处理 RSVP 的 Path 消息和 Resv 消息。随着 RSVP 会话的不断增加，会产生大量的刷新消息来维持 RSVP 软状态。当一个非 RSVP 刷新消息在传输时丢失，就会产生可靠性和延迟问题。摘要刷新机制的引入，可以解决上述这两个问题。在减少大量刷新消息的同时，提高了 RSVP 消息传输的可靠性，并提高资源的利用率。

摘要刷新 Srefresh（Summary Refresh）可以不传送标准的 Path 或 Resv 消息，而仍能实现对 RSVP 状态的刷新。使用摘要刷新的好处主要是它减少了维持 RSVP 状态所需传输及处理的信息量。使用摘要刷新消息更新 RSVP 状态时，常规的刷新消息就被抑制了。

摘要刷新消息承载了一系列 Message_ID 对象，用于识别需要被刷新的 Path 及 Resv 状态。摘要刷新需要与 Message_ID 扩展配合使用。只有那些已经包含 Message_ID 的 Path 和 Resv 消息发布过的状态才能使用摘要刷新机制刷新。

当节点接收到一条摘要刷新消息时，与本地状态块（PSB 或 RSB）进行匹配。

- 如果匹配，就更新本地状态，就象接收到一个标准的 RSVP 刷新消息一样。
- 如果不匹配，节点将发送一个 NACK 消息来通知摘要刷新消息的发送者。并根据 Path 或 Resv 消息刷新相应的 PSB 或 RSB，同时更新 Message_ID。

Message_ID 对象中包含了 Message_ID 序列号。当 LSP 发生变化时，相应的 Message_ID 序列号增大。节点收到 Path 消息时，将其中的 Message_ID 序列号与本地状态块中保存的 Message_ID 序列号比较：

- 如果相等，则保持状态不变。
- 如果大于，则表示状态已更新。

RSVP 目前支持全局使能摘要刷新和接口使能摘要刷新。如果使能了全局摘要刷新，则整台设备支持 RSVP 摘要刷新能力，如果只使能接口摘要刷新能力，则该接口对应的链路上支持 RSVP 摘要刷新能力。

3.3.12 RSVP Hello

RSVP 节点给邻居发送 Hello 消息来检查邻居是否可达。

Hello 机制提供了节点到节点的缺陷检测方式。当发现节点间链路故障时，它的处理类似于链路层缺陷的处理。当链路层缺陷的通告不可用，或链路层提供的这个缺陷检测机制对节点缺陷检测不充分时，就可以使用 Hello 检测机制。

- 当使用快速重路由功能时，若 Hello 检测到邻居不可达时，会触发流量切换到 Bypass 路径上，防止因为下一跳不可达而造成流量丢失。
- 当使用 RSVP GR 功能时，Hello 还可以检测邻居节点是否重启，只有检测到邻居节点重启才能支持邻居节点恢复 RSVP 状态。

RSVP Hello 的实现原理如下：

1. Hello 握手机制

   图 3-15 Hello 握手机制

   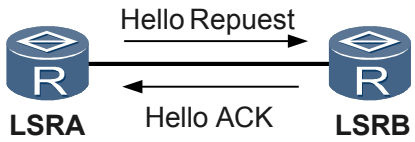

   如图 3-15，LSRA、LSRB 之间有链路直接相连。

   - 当 LSRA 接口下使能了 RSVP Hello 时，LSRA 会向 LSRB 发送 Hello Request 消息。
   - 若 LSRB 收到了 Hello 消息，并且 LSRB 也使能了 RSVP Hello，就会给 LSRA 节点回复 Hello ACK 消息。
   - LSRA 收到 LSRB 的 Hello ACK 消息后，就确认 LSRA 的邻居 LSRB 是可达的。

2. 检测邻居丢失

   在 LSRA 向 LSRB 发送 Hello Request 握手成功后，LSRA 与 LSRB 就开始互通 Hello 消息。当 LSRA 连续三次向 LSRB 发送 Hello Request 消息后，LSRB 仍然没

有给 LSRA 回 Hello ACK 消息，此时就认为 LSRB 邻居丢失，重新初始化 RSVP Hello。

当 LSRA 和 LSRB 之间存在 LSP 时，

- 如果没有使能 GR 功能，但使能了快速重路由功能，则 Hello 检测到邻居丢失时，会触发流量切到 Bypass 路径上，保证流量不中断。
- 如果使能了 GR 功能，则优先按照 GR 方式处理。

3. 检测邻居重启

当 LSRA 和 LSRB 都使能 RSVP GR 功能时，在 Hello 检查到邻居 B 丢失后，LSRA 就等待 LSRB 发送有 GR 扩展的 Hello Request 消息，此时 LSRA 开始支持 B 恢复 RSVP 状态。LSRB 收到 LSRA 回复的 Hello ACK 消息后，知道 LSRA 开始支持 LSRB 做 GR。然后 LSRA 和 LSRB 互通 Hello 消息，维持 GR 恢复状态。

3.3.13 BFD for RSVP

BFD for RSVP 使用 BFD 检测 RSVP 邻居关系。当 RSVP 相邻节点之间存在二层设备比如 HUB 时，这两个节点只能根据 Hello 机制感知链路故障，故障时间为秒级，这将导致数据大量丢失。BFD for RSVP 可实现毫秒级故障监测时间，并配合 RSVP 协议快速的发现 RSVP 邻接故障。BFD for RSVP 一般用在 TE FRR 中 PLR 节点与主路径的 RSVP 邻居之间存在二层设备的情况。

图 3-16 BFD for RSVP 示意图

如图 3-16，BFD for RSVP 主要是在 RSVP 邻居之间建立 BFD 会话，用以检测这两个邻居之间的链路状态，让 RSVP 模块快速感知到链路失效。

BFD for RSVP 的检测对象与 BFD for CR-LSP 和 BFD for TE 不同。BFD for RSVP 是对 IP 层的检测，在 RSVP 邻居之间只能建立单跳 BFD 会话。在应用场景上，BFD for RSVP 也与 BFD for Tunnel 和 BFD for TE 不同，BFD for Tunnel 和 BFD for TE 主要是端到端的检测，而 BFD for RSVP 则是检查邻居节点间的链路状态。

BFD for RSVP 可以与 BFD for OSPF、BFD for ISIS 和 BFD for BGP 共享会话。如果本地的 BFD for RSVP 与其他协议共享 BFD 会话时，则本地节点分别选择所有共享 BFD 会话的协议的发送时间间隔、接收时间间隔、本地检测倍数的最小值做为本地的 BFD 会话参数。

3.4 术语与缩略语

缩略语

缩略语	英文全名	中文解释
RSVP	Resource Reservation Protocol	资源预留协议

缩略语	英文全名	中文解释
FRR	Fast Re-Route	快速重路由
CSPF	Constrained Shortest Path First	基于约束的路径最短优先
TE	Traffic Engineering	流量工程
MP	Merge Point	聚合点
PLR	Point of Local Repair	本地修复节点
CT	Class Type	分类，这里是指带宽类型
PSB	Path State Block	路径状态块
RSB	Reserved State Block	预留状态块