答疑（一）| 第1~5讲思考题答案

2022-03-14 杨胜辉

《网络排查案例课》 课程介绍 >

讲述：杨胜辉
时长 13:29 大小 12.36M

你好，我是胜辉。

不知不觉，咱们已经完成预习篇、实战一的 TCP 真实案例篇，还有实战二的应用层真实案例篇的学习了。一路走来，我自己完成了 20 多讲的备课，过程中是辛劳和满足相伴。当然你也很不容易，坚持学完 20 多讲，一共投入的时间也接近 20 个小时，这个过程本身就是一种小小的成就。

由于课程涉及的网络知识面还是比较广泛的，如果你还有不少没看懂的地方，也别着急，这是很正常的情况。就我自己来说，最初看那些 TCP/IP 概念的时候也是摸不到头脑，我就是反复看，从不同的资料、不同的案例来入手，才逐步建立起自己的理解。

正因为**通过问题来理解概念**是一种很好的学习方法，所以我在每节课的后面，都留有一两个思考题，希望可以促进思考。这些问题，有些比较容易，有些可能略有难度。所以我整理了答疑篇，一方面给出答案供你参考，一方面也正好把课程里没有覆盖到的细节给你展开一下，作为内容上的补充。总之，我希望通过这个答疑环节，能帮助你把看过的知识都真的消化掉，成为你自己知识体系的一部分。

01 讲的答疑

思考题

1. traceroute 默认是用 UDP 来做探测的，那这个又是基于什么原理呢？通和不通，我们会收到怎样的回复？
2. 有时候运行 telnet 后命令就挂起，没有响应了，这说明了什么问题呢？

答案

关于第一个问题，我看到很多同学的回答都已经很到位了，比如以 **@webmin** 同学的回答为例：

> traceroute 使用 UDP 探测时，初始时把 TTL 设置为 1，经过路由器时 TTL 会被减 1，当 TTL 变为 0 时，包被丢弃，路由器向源地址发回一个 ICMP 超时通知（ICMP Time Exceeded Message）。源收到这个通知，就会把下一次发送的包的 TTL 在原来的基础加 1，这样就可以多前进一步。探测时使用了一个大于 30000 的端口号去连接，随着 TTL 的增加端口也会加 1，目地服务器在收到这个数据包的时候，会返回一个端口不可达的 ICMP 错误信息（ICMP Port Unreachable），当源地址收到 ICMP Port Unreachable 包时，会停止 traceroute。

在我的 Ubuntu 虚拟机上，traceroute 使用的起始 UDP 目的端口是 33434，然后每次探测的 TTL 加一的同时，UDP 目的端口也加一，每次探测会发送 3 次探测报文。也就是下图这样：

No.	Time	Source	Destination	TTL	TCP Seglen	Info
1	0.000000	10.0.2.15	180.101.49.11	1		43060 → 33434 Len=9
2	0.000079	10.0.2.2	10.0.2.15	255,1		Time-to-live exceeded (Time to live exceeded in transit)
3	0.000087	10.0.2.15	180.101.49.11	1		43060 → 33434 Len=9
4	0.000145	10.0.2.2	10.0.2.15	255,1		Time-to-live exceeded (Time to live exceeded in transit)
5	0.000145	10.0.2.15	180.101.49.11	1		43060 → 33434 Len=9
6	0.000106	10.0.2.2	10.0.2.15	255,1		Time-to-live exceeded (Time to live exceeded in transit)
7	0.000216	10.0.2.15	180.101.49.11	2		43060 → 33435 Len=9
8	0.004597	192.168.1.1	10.0.2.15	1,1		Time-to-live exceeded (Time to live exceeded in transit)
9	0.000145	10.0.2.15	180.101.49.11	2		43060 → 33435 Len=9
10	0.001774	192.168.1.1	10.0.2.15	1,1		Time-to-live exceeded (Time to live exceeded in transit)
11	0.000150	10.0.2.15	180.101.49.11	2		43060 → 33435 Len=9
12	0.001453	192.168.1.1	10.0.2.15	1,1		Time-to-live exceeded (Time to live exceeded in transit)
13	0.000177	10.0.2.15	180.101.49.11	3		43060 → 33436 Len=9
14	0.009934	100.65.0.1	10.0.2.15	2,2		Time-to-live exceeded (Time to live exceeded in transit)
15	0.000153	10.0.2.15	180.101.49.11	3		43060 → 33436 Len=9
16	0.011554	100.65.0.1	10.0.2.15	2,2		Time-to-live exceeded (Time to live exceeded in transit)
17	0.000199	10.0.2.15	180.101.49.11	3		43060 → 33436 Len=9
18	0.006144	100.65.0.1	10.0.2.15	2,2		Time-to-live exceeded (Time to live exceeded in transit)
19	0.000181	10.0.2.15	180.101.49.11	4		43060 → 33437 Len=9
20	0.016566	61.152.54.…	10.0.2.15	3,3		Time-to-live exceeded (Time to live exceeded in transit)
21	0.000145	10.0.2.15	180.101.49.11	4		43060 → 33437 Len=9

当时的 traceroute 命令行的输出是这样的：

复制代码

```
traceroute www.baidu.com
traceroute to www.a.shifen.com (180.101.49.11), 64 hops max
  1   10.0.2.2  0.082ms  0.177ms  0.088ms
  2   192.168.1.1  4.634ms  1.811ms  1.488ms
  3   100.65.0.1  9.972ms  11.511ms  6.189ms
  4   61.152.54.125  16.296ms  3.576ms  4.095ms
  5   61.152.24.102  7.329ms  6.786ms  11.987ms
  6   202.97.71.6  28.938ms  10.568ms  10.069ms
  7   58.213.95.2  15.036ms  9.831ms  17.043ms
  8   *  *  *
  9   58.213.96.54  16.843ms  10.329ms  15.989ms
 10   *  *  *
 11   *  *  *
 12   *  *  *
 13   *  *  *
 14   *  *  *
 15   *  *  *
 16   *  *  *
```

这次 traceroute 没有停住，而是一直到 64 跳的限制后才停止（因为输出过长，我没有把全部的信息复制过来）。当然，一般实践中你看到连续六七个以上的*，基本就可以判定是目的端对 UDP 无响应，可以按下 Ctrl + C 终止了。

我把整个流程的实现原理，概括成了下面的示意图，希望能帮助你理解：

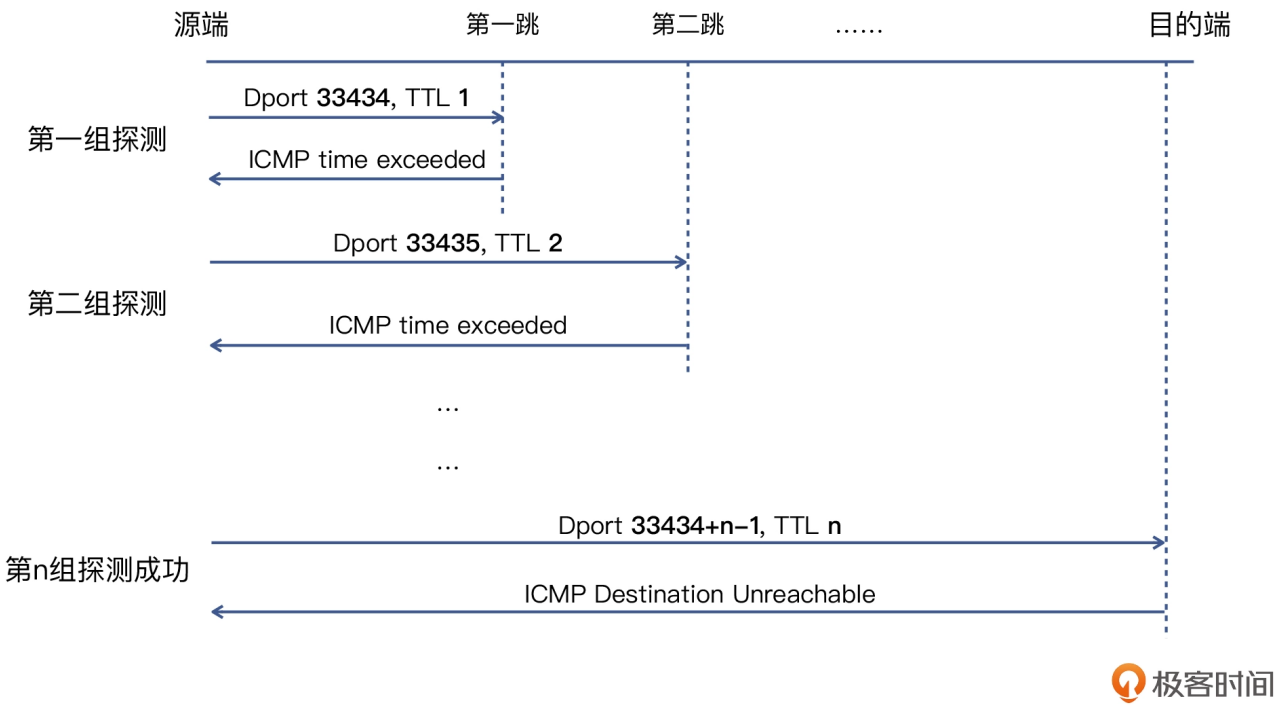

然后，我们再用 ICMP 模式做一次 traceroute，输出如下：

复制代码

```
$ traceroute -I www.baidu.com
traceroute to www.a.shifen.com (180.101.49.12), 64 hops max
  1   10.0.2.2  0.105ms  0.229ms  0.173ms
  2   192.168.1.1  8.972ms  1.725ms  1.326ms
  3   100.65.0.1  9.850ms  7.893ms  7.311ms
  4   *  *  61.152.53.149  5.579ms
  5   *  61.152.25.230  20.238ms  5.204ms
  6   *  *  *
  7   *  58.213.94.114  21.249ms  *
  8   58.213.94.126  13.869ms  *  *
  9   58.213.96.54  11.736ms  10.094ms  10.644ms
 10   *  *  *
 11   *  *  *
 12   *  *  *
 13   180.101.49.12  24.780ms  9.443ms  10.201ms
```

这次就能顺利完成了，这是因为目的 IP 对 ICMP 是有回复的，所以 traceroute 就在最后一跳，也就是第 13 跳顺利停止了。

这里还有个小技巧。你有没有发现 **UDP 和 ICMP 这两种模式下，路径信息是可以互补的**？比如 UDP 模式下没有显示第 5 和第 7 跳的 IP，但是 ICMP 模式下就有。这就是为什么我建议你把两种模式分别跑一下，这样可以获取到尽可能完整的路径。

```
@victorebpf:~$ traceroute www.baidu.com
traceroute to www.a.shifen.com (180.101.49.11), 64 hops max
 1   10.0.2.2  0.091ms  0.087ms  0.002ms
 2   192.168.1.1  11.628ms  13.413ms  5.311ms
 3   100.65.0.1  10.110ms  6.043ms  4.223ms
 4   61.152.53.149  4.680ms  9.512ms  4.736ms
 5   61.152.25.82  11.088ms  14.483ms  6.530ms
 6   202.97.29.110  9.635ms  17.331ms  18.081ms
 7   58.213.95.102  11.266ms  10.715ms  23.246ms
 8   *  58.213.95.134  16.182ms  *
 9   58.213.96.54  28.350ms  19.337ms  19.899ms
10   *  *  *
11   *  *  *
12   *  *  *
13   *  *  *
14   *  *  *
15   *  *  *
```

```
@victorebpf:~$ traceroute -I www.baidu.com
traceroute to www.a.shifen.com (180.101.49.11), 64 hops max
 1   10.0.2.2  0.267ms  0.269ms  0.001ms
 2   192.168.1.1  4.723ms  1.787ms  5.779ms
 3   100.65.0.1  11.624ms  15.475ms  9.920ms
 4   61.152.53.149  5.646ms  *  5.778ms
 5   *  *  *
 6   *  202.97.29.118  12.000ms  9.295ms
 7   *  *  *
 8   *  *  58.213.95.126  16.204ms
 9   58.213.96.62  28.347ms  27.150ms  22.876ms
10   *  *  *
11   *  *  *
12   *  *  *
13   *  * ^@ *
14   180.101.49.11  10.103ms  21.717ms  12.880ms
@victorebpf:~$
```

第二个问题是关于 telnet 挂起。这里说的“挂起”，是指没有进一步的反应了，比如像下图这样：

```
sh-3.2$ telnet www.baidu.com 500
Trying 180.101.49.12...
```

究其原因，就是 telnet 发送了 SYN 后没有收到 SYN+ACK。我们在第 21 讲提到了系统调用，那么对于 telnet 这样的用户空间程序来说，它要发起 TCP 连接，就必须调用 **connect()** 这个系统调用，后者会负责发出 SYN。但是 SYN 发出去后，对端没有回复 SYN+ACK，这就导致 connect() 阻塞，telnet 程序也只好等在那里，表象上就是挂起了。

你可以参考这个示意图来理解整个过程：

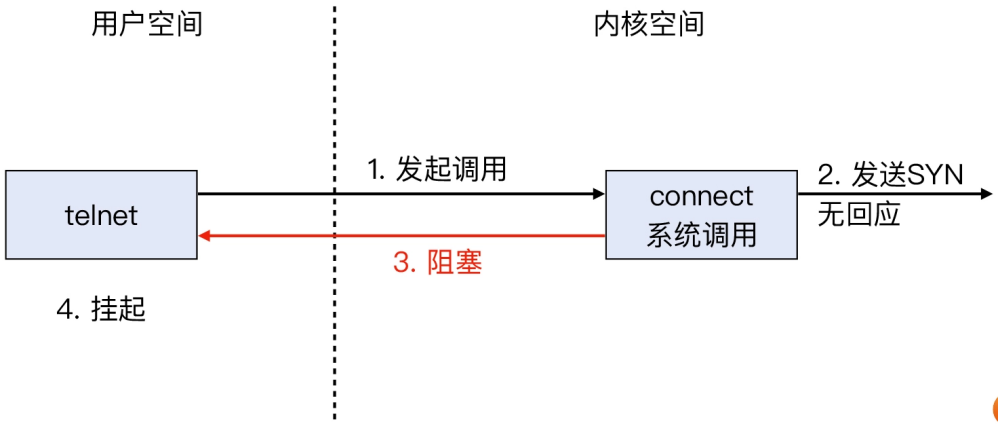

当然，在第 21 讲我们也学习过 strace 这个工具了，所以我们可以用 strace 来验证这个过程。直接运行下面的命令：

```
1 strace telnet www.baidu.com 500
```

复制代码

就能看到，strace 停留在 connect() 系统调用这里了：

```
1 ......
2 socket(AF_INET, SOCK_STREAM, IPPROTO_IP) = 3
3 setsockopt(3, SOL_IP, IP_TOS, [16], 4)  = 0
4 connect(3, {sa_family=AF_INET, sin_port=htons(500), sin_addr=inet_addr("45.113
```

复制代码

02 讲的答疑

思考题

1. 请你用偏移量方法，写一个 tcpdump 抓取 TCP SYN 包的过滤表达式。
2. 如果确定问题是在 IP 层，tcpdump 命令如何写，可以做到既找到 IP 层的问题，又节约抓包文件大小呢？

答案

很多同学都写出了正确的偏移量的过滤表达式，也就是：

```
1 tcpdump 'tcp[13]&2 != 0'
```

复制代码

当然，这个题目没有指明是一定只要 SYN 包，我们用上面这条命令可以抓到 SYN 和 SYN+ACK 这两种报文。而如果要指定只抓取 SYN 包而不抓取 SYN+ACK，可以用下面的表达式：

```
1 tcpdump 'tcp[13]|2 = 2'
```

复制代码

> 注意：这里的运算符是“|”，也就是字符或运算符。

第二个问题的关键点是 tcpdump 的 **-s 参数**，我们通过它可以指定要抓取的每个报文的大小。不过那就有个问题了，这里的“报文”是指 IP 分组还是二层帧呢？

虽然 tcpdump 名称里是 tcp，实际上它能抓取 udp、ip、icmp 等等各种报文，因为它抓取的就是第二层的帧。所以说，**这里的“报文大小”，指的是二层帧的大小**。我在第 2 讲里也贴了一张图，展示了在某一次抓包里，一个报文的各层占用的字节数：

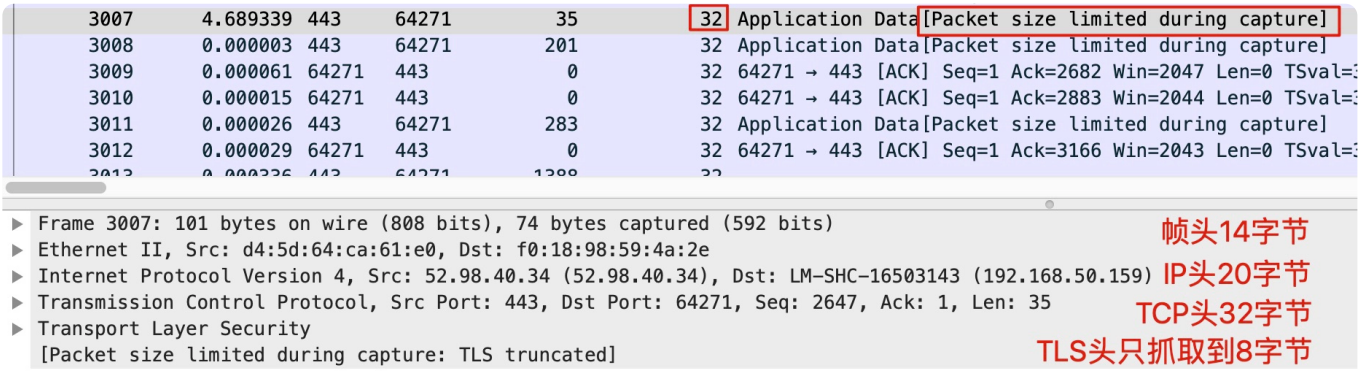

一般来说，IP 头部就是 20 字节，加上帧头 14 字节，所以**理论上我们只要抓取前 34 字节的报文，就可以获取到二层和三层的信息了**。

不过且慢，有个同学报告了一个问题：

> 老师，对于“问题 2”我有个疑问。我最开始用的命令是“`tcpdump -i any -s 34`”，发现 -s 写成 34，就抓不到网络层的目的地址字段，用 Wireshark 分析后发现，帧头（不知道还叫不叫这个，Wireshark 显示为 `Linux cooked capture v1`）占了 16 个字节，写成 36 就能把信息抓全了，但是写成“`tcpdump -i eth0 -s 34`”就可以抓全。

这个问题我之前也没留意到，于是去查证了一下。原来在 tcpdump 里，对于 any 这个接口，它在输出帧头的时候用了一种叫 **Linux cooked capture v1** 的格式，这个格式的长度是 16 个字节，而以太网帧是 14 字节。这就造成了 2 个字节的差异，也就是按原先的 34 字节去抓取就不够了，所以要扩大到 36 字节才可以抓到完整的 IP 头部。

我们看一个例子：

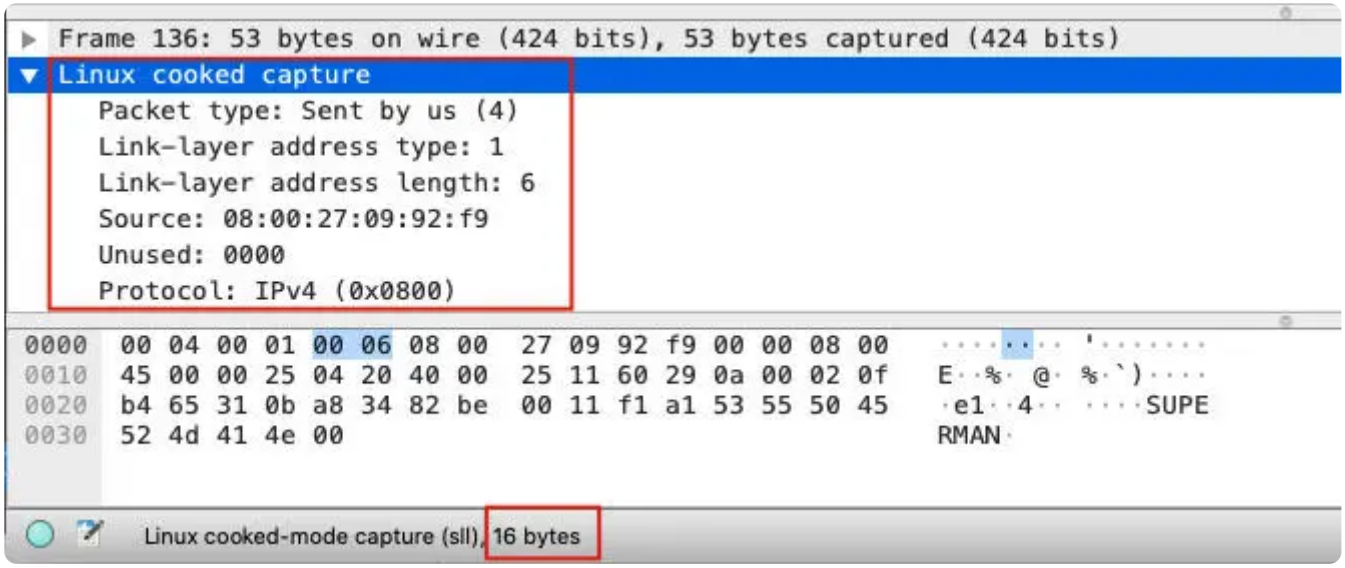

> 补充：上面的 traceroute udp 模式的示例文件就是用 -i any 模式抓取的，所以它的二层帧头就是 `Linux cooked capture v1` 格式。

另外，“IP 头部 20 字节”这个描述，其实还有一个隐含的前提：**IP 头部没有做扩展**（Options）。跟 TCP 类似，IP 头部也可以扩展，但是一般用的比较少，在公网上 IP Options 的报文有可能被丢弃，所以很少被采用。我们在内网也曾经做过实验，启用了 IP Options，结果发现虽然内网设备可以支持 IP Options，但是延迟增加了很多，所以最后还是取消了它。

03 讲的答疑

思考题

1. 在 Linux 中，还有一个内核参数也是关于握手的，net.ipv4.tcp_synack_retries。你知道这个参数是用来做什么的吗？
2. 如果握手双方，一方支持 Window Scale，一方不支持，那么在这个连接里，Window Scale 最终会被启用吗？你可以参考 RFC1323，给出你的解答。

答案

第一个问题是关于 Linux 内核参数的。对于各种网络相关的内核参数来说，最快捷的方法可能就是直接在 Linux 主机里面查看 TCP 的手册了，也就是执行：

复制代码

```
1 man tcp
```

然后搜索 tcp_synack_retries 就可以了，也就是这个部分：

> tcp_synack_retries (integer; default: 5; since Linux 2.2)
> The maximum number of times a SYN/ACK segment for a passive TCP connection will be retransmitted. This number should not be higher than 255.

也就说，**这是 TCP 回复 SYN+ACK 后等不到 ACK 时，需要重试的次数**。

第二个问题是关于 Window Scale（下面简称 WS）在握手中的具体实现。就像我题目里说的，你可以直接去找到RFC1323，然后找到这部分的内容：

> This option may be sent in an initialsegment (i.e., a segment with the SYN bit on and the ACK bit off). It may also be sent in a <SYN,ACK> segment, but only if a Window Scale option was received in the initialsegment. A Window Scale option in a segment without a SYN bit should be ignored.

直译过来就是：这个 WS 选项可以在 SYN 包中，也可以在 SYN+ACK 包中。但只有收到的 SYN 中有这个 WS 选项，回复的 SYN+ACK 才可以加上这个选项。如果收到的报文不带 SYN 标志位但却带上了 WS 选项，这样的 WS 应该被忽略。

也就是说，如果发过来的 SYN 里不带 WS 选项，那回复的 SYN+ACK 也不应该带 WS，自然这次的连接里也就不会用上 WS 了。简单来说，只要有一方不支持 WS，这次的连接里就不会用 WS。

04 讲的答疑

思考题

1. 如果要在 Wireshark 中搜索到挥手阶段出现的 RST+ACK 报文，那么这个过滤器该如何写呢？
2. 你有没有通过抓包分析，解决过应用层的奇怪问题呢？你是怎么做的呢？

答案

第一个问题里挥手阶段出现 RST 的现象， 这个已经不是用 FIN 完成的标准挥手过程了，而是出现了异常。不过从报文特征来说还是比较直接的，就是既要带 RST 标志位，也要带 ACK 标志位，所以答案就是：**tcp.flags.ack==1 and tcp.flags.reset == 1**。

第二个问题是开放式的，比如 **@江山如画**同学分享了一个挺有意思的案例，是双方时钟不同步导致了 TLS 握手失败。时钟问题也是一个挺有“存在感”的问题，时不时会在各种故障中扮演一点角色，我们可以在排查没什么方向的时候，也可以查一下时钟。

另外说到 TLS 握手的问题，我在第 19 讲里介绍了两个典型案例，也是刚过去不久的一讲，我想你应该还有印象。

05 讲的答疑

思考题

这节课里，我介绍了使用裸序列号作为定位两侧同个报文的手段。那么要定位两侧的同个报文，除了这个方法，还有哪些方法呢？你可以从网络七层模型出发，给出自己的思考。

答案

定位两侧同个报文，是一个比较关键的技术点，因为抓包分析的一个重要任务，就是对比两侧抓包文件中的报文，从而判定丢包、乱序、重传等行为的严重程度和原因，由此才能针对性地做进一步排查乃至找到解决方案。如果不能找到“同个报文”，那刚才说的一系列工作就无从谈起了。

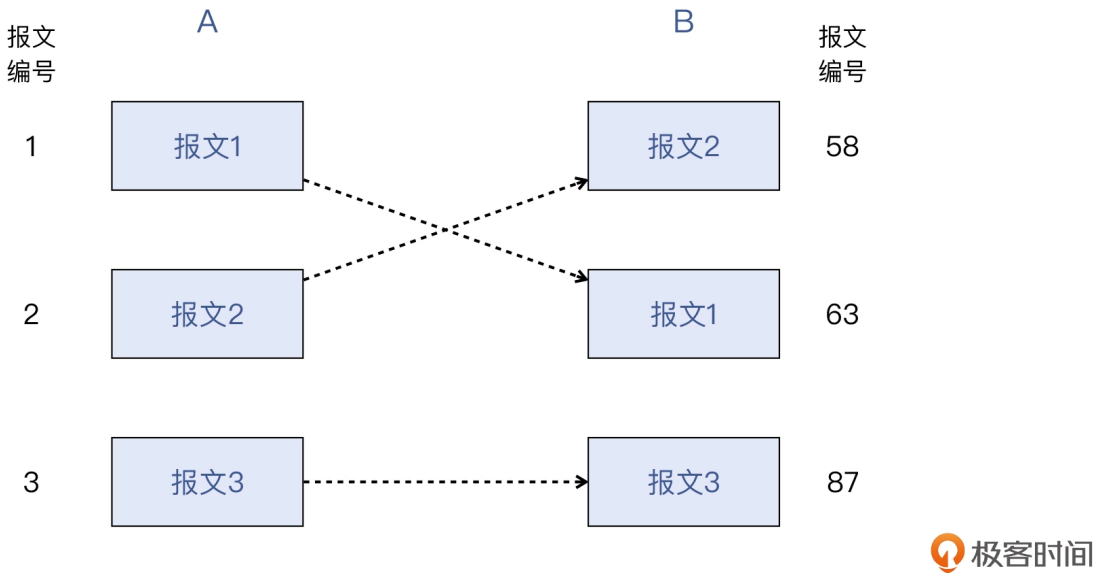

> 补充：A 和 B 对报文的编号一般是不同的，因为各自抓取报文的起始时间、抓取条件等都可能不同，就会导致抓取到的报文互有交集。

比如上面就是一个典型的 TCP 问题的场景，也就是报文顺序发生了变化，这个现象就是“乱序”：发出 1、2、3，收到的却是 2、1、3。那么显然，我们需要在两侧的抓包文件里，找到对应的同个报文。事实上，现在说的 1、2、3，是 A 的抓包文件里的报文编号，而 B 那边有自己的视角和报文编号，跟 A 是完全不同的。

我在第 5 讲里介绍的方法，是用了裸序列号（原始序列号），因为 TCP 报文的这个序列号在传输中是不会变化的，所以这就是一个很好的确定报文的方法。其实，这属于**第一大类方法：按照 TCP 报文的元信息，也就是 TCP 头部的特征去找到对应的报文**。

既然确定了这个大类的方法原则，你很容易举一反三，想到其他的方法。比如：

用 TCP 确认号，比如下面这个过滤器：

```
1 tcp.ack_raw == 754313633
```

复制代码

如果有 TCP timestamp 扩展，就用 TCP timestamp，比如下面两种过滤器：

```
1 tcp.options.timestamp.tsval == 2947948748
2 tcp.options.timestamp.tsecr == 3209788920
```

复制代码

如果有 TCP SACK 扩展，就用 SACK 号，比如用过滤器：

```
1 tcp.options.sack_le == 1234
```

复制代码

而**第二个大类的方法，是利用 TCP 的载荷本身的特征去找到对应的报文**。比如 HTTP 是文本协议，那么我们用下面这个过滤器，就可以找到含有这个字符串的报文：

复制代码

```
tcp contains "id=abcdafeafeagfeagfaraera1242dfea"
```

其实换成以下这几种方式，也是一样的效果：

复制代码

```
frame contains "id=abcdafeafeagfeagfaraera1242dfea"
ip contains "id=abcdafeafeagfeagfaraera1242dfea"
http contains "id=abcdafeafeagfeagfaraera1242dfea"
```

这个示意图，也表示了这样的两大类寻找对应报文的方法：

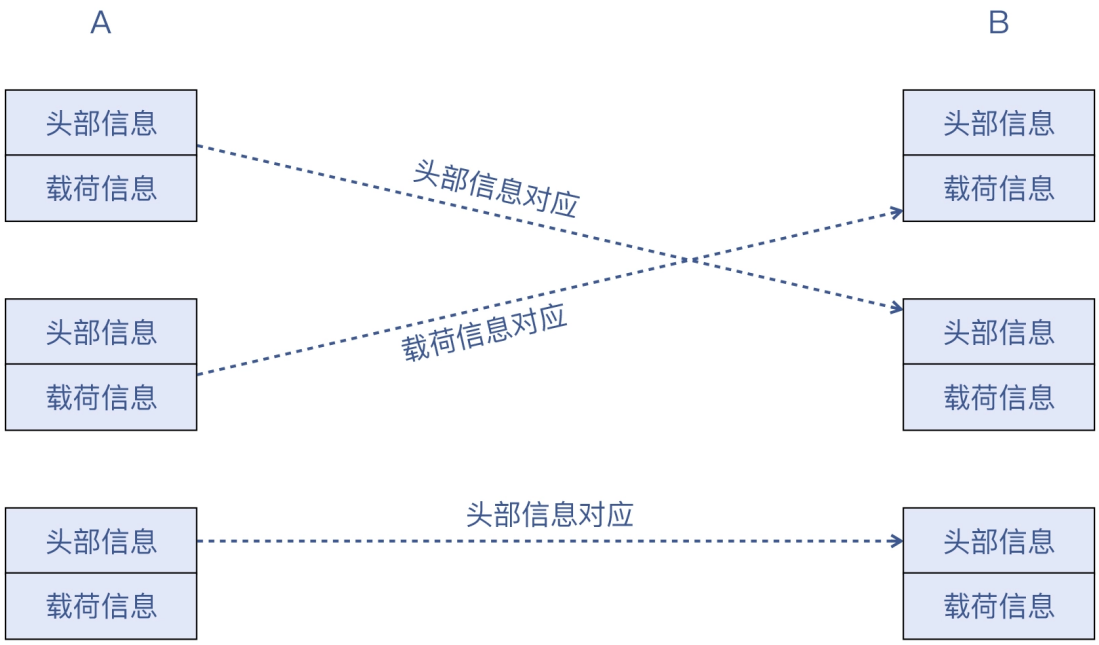

极客时间

不过，你看了这张图，会不会以为我们每个报文都要这么找对应关系呢？那当然不用了，每个 TCP 流只要找一个关键报文，然后根据这个报文去做 Follow -> TCP Stream 就好了。

小结

以上就是针对课程前 5 讲思考题的参考答案和拓展解读，希望能给你一些启发。另外，也非常感谢你对课后思考题的仔细思考和认真解答。在看留言的过程中，我从大家的答复中也看到了更加全面或是更加深入的思考，我自己受益匪浅。

接下来，我还会针对剩余的课后思考题，以及你的提问来作出解答。有任何问题，还是跟以前一样，欢迎你在留言区跟我交流，我们一同成长。

上一篇 22 | 为什么压力测试TPS总是上不去？

精选留言

写留言

由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。