



## BV1hU4y1g7sp (美食评测)

前40一直在说话 只有最后一个视频完全没人声 共72

## BV1KK411V7MK (剧)

同一个人 不同口音 (视频3 12 19 34) 36后面没说话人声音 共57

## BV1tJ411P7Cr (多人唱歌)

(没有人脸不适合我们的数据集, 主要用来检测是否能在有背景音乐且在唱歌的情况下区分说话人) 第11个开始错了 共55

## BV17b4y1m79y (挑战-vlog)

前56全是纯目标说话人, 107个视频不到一秒钟 共294

# 三、初步设想

## 1. 场景设定 (是否需要划分场景存疑)

### 两个模态都好

讲课

### 声音模态较好

评测

VLOG

### 人脸模态较好

近景唱歌

### 两个模态都不一定很好

多人vlog

剧

远景唱歌

## 2. audio-driven 采集流程

分为**预筛**和**精筛**

### 预筛

- 每个人寻找自己熟悉的UP主 (**每个人不重复**), 负责采集该UP主的视频, 最好不同场景不同风格, 人脸和声音都需要出现, 视频中该up主所占部分至少为50%, 给出选择视频的**BV号**
- 给出音频的**置信度**
  - 高置信度** 讲课等up主人脸和声音质量都很高的情况
  - 中置信度** 如果是复杂场景vlog或多人拍摄该up占主导的情况
  - 低置信度** 唱歌等声音环境较复杂的情况
- 给出每个视频中**该说话人连续说话10秒**的一段音频用于注册

## 精筛

程序将根据不同置信度选择保留的段数并得到最后的结果，每个人负责检查自己选择的UP视频结果的情况