



Acoustic-aware Training for Multi-genre Speaker Recognition

Zhenyu Zhou

Instructors: Lantian Li

2022.11.04



目录

01 Introduction

02 Motivation

03 Acoustic embedding

04 Visualization analysis

05 Condition-aware learning

06 Experiments



信号特点：语音信号具有“形简意丰”的特点，即在一段语音信号中可能融合了包括内容信息，说话人信息，环境信息在内的各种信息。

研究难点：对于说话人识别任务来说，场景信息是极大的干扰因素。但是在实际应用中，尤其是多场景说话人识别下，由于描述说话人的表征向量中冗杂了场景信息，造成了性能指标极度下降。

研究现状：当前主流的多场景说话人识别方法是基于数据驱动的多场景训练，即在训练时就丢入一个说话人的多场景语音数据。但是这种纯粹靠输入数据的分布特征来提取特征，难免会掺杂部分的场景信息，从而难以“纯化”说话人表征。

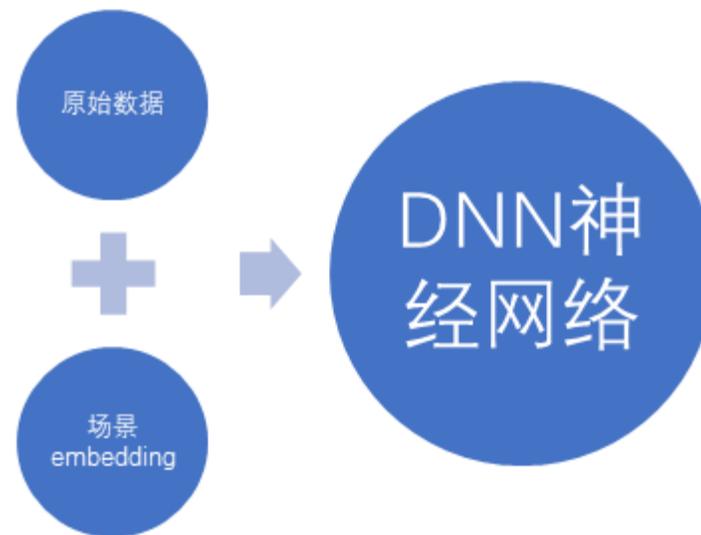
改进方法：本项目研究基于音频事件表征的多场景训练方法。加入预训练的音频事件表征，并以此为先验知识辅助模型训练，将盲目型训练变成知识型训练，从而更好地表征多场景说话人模型，提高在多场景下的识别性能。



在一段语音数据中，声纹信息和场景信息是强耦合的，而这种耦合关系会极大的影响识别的准确率。

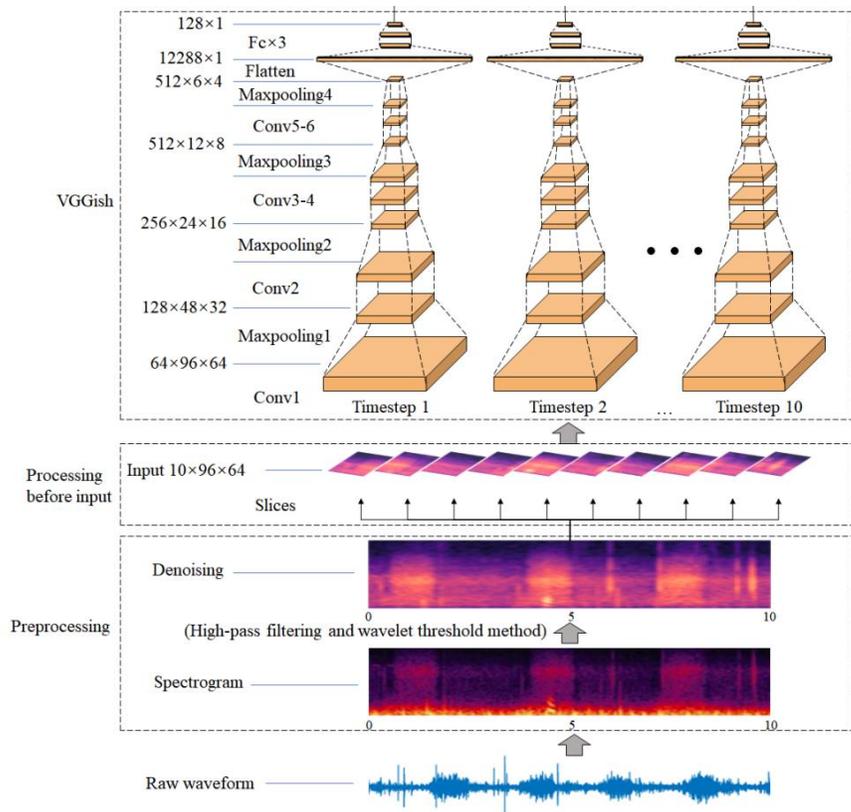
直觉上，场景信息和说话人信息可以看作是一对彼此独立的变量。因此，可以考虑采用条件学习（**Conditional learning**）的方式，把场景信息作为训练的辅助条件，来增强对深度说话人模型的学习。

具体地，对于一条语音信号，首先得到描述其场景信息的场景表征（**Genre embedding**），然后将该场景表征拼接到原始语音特征上，然后作为神经网络模型的输入。



3 场景表征的获取

Acoustic embedding



```
# Architectural constants.  
NUM_FRAMES = 96 # Frames in input mel-spectrogram patch.  
NUM_BANDS = 64 # Frequency bands in input mel-spectrogram patch.  
EMBEDDING_SIZE = 128 # Size of embedding layer.
```

```
# Hyperparameters used in feature and example generation.  
SAMPLE_RATE = 16000  
STFT_WINDOW_LENGTH_SECONDS = 0.025 # 帧长  
STFT_HOP_LENGTH_SECONDS = 0.010 # 帧移  
NUM_MEL_BINS = NUM_BANDS  
MEL_MIN_HZ = 125  
MEL_MAX_HZ = 7500  
LOG_OFFSET = 0.01 # Offset used for stabilized log of input mel-spectrogram.  
EXAMPLE_WINDOW_SECONDS = 0.96 # Each example contains 96 10ms frames  
EXAMPLE_HOP_SECONDS = 0.96 # with zero overlap.
```

场景表征 (Acoustic embedding) 的获取采用的是在 Google AudioSet 数据集上预训练得到的 VGGish 模型。以 VGGish 模型为预训练模型，将音频原始输入特征转化成具有语义信息的低维音频事件表征向量。

左图是 VGGish 的网络架构。其中 VGGish 模型的输入是固定的，即 96 Frames * 64 Mel-spectrum。举例来说，对于一条 10s 的音频，首先按照 0.96s (96 frames * 0.01s hop length) 为最小单位，分成 10 个 segments，然后每个 segment 得到一个 128 维的 acoustic embedding，最后的输出便是 [10, 128] 的 tensor。最后将每一帧的 embedding 求均值得到句子级的 acoustic embedding。



Research background:



Fig. 8. Cross-genre tests with the x-vector system. The lightness of the color corresponds to the numerical value of the EER (%).

在多场景的说话人确认任务中，会存在注册-测试场景失配问题，即当注册场景和测试场景不同时，识别错误率会很高。不同场景对于说话人声纹信息的干扰程度不尽相同。

为了消除这种识别误差，滤除场景特征对于声纹特征的影响，我们提出了加入场景表征的 **acoustic-aware training** 方法。通过对不同场景表征的降维可视化实验，可以定性地分析出不同场景之间的分布特性（近还是远离）。对于分布相近的场景，注册-测试失配问题并不大；而对于分布较远的场景，则可以加入场景表征，完成辅助训练和预测，提升识别性能。

从图中可以看出，**singing** 场景与 **interview**、**entertainment**、**live_broadcast** 三个场景会容易出现注册-测试失配问题。



Technical comparison

• PCA

PCA降维方式用于提取数据的主要特征分量，主要思想是**将n维特征映射到互相正交的k维特征上，这些k维特征是在原有n维特征的基础上重新构造出来的**。PCA降维可以滤除掉部分噪声和冗余信息的干扰，但是PCA的可视化效果并不理想，聚类效果不明显。

• T-SNE

T-SNE降维能够将高维数据降低到2维或3维，在进行数据可视化时，能得到很好的结果。主要思想是**计算高维状态下，不同样本点之间的距离关系；同时在映射到低维时，保证相同样本点之间的距离要和高维下的距离关系尽可能相同**。这种相似性的描述，可以使用KL散度来定义loss function。

• UMAP

UMAP相比较于T-SNE可以在强调局部特征的前提下，兼顾到部分的整体信息。主要思想是，**使用KNN找到样本点的临近节点，并构建一个图**。

Experiments

通过 t-SNE, UMAP 等流形学习方法, 对 Acoustic embedding 进行降维可视化, 分析 speaker factor 和 genre factor 之间的分布特性。

Single-Speaker Multi-Genre (SS-MG): 验证表格中非对角线上的性能表现

青色的点代表 singing, 红色的点代表 interview, 蓝色的点代表 entertainment, 粉色的点代表 live_broadcast。

Multi-Genre

• id00100



图1.1 PCA降维

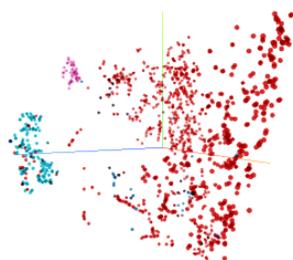


图1.2 T-SNE降维

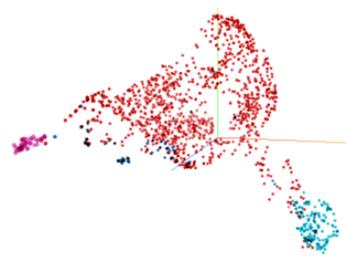


图1.3 UMAP降维

• id00392

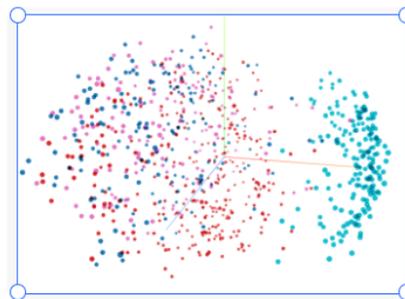


图2.1 PCA降维

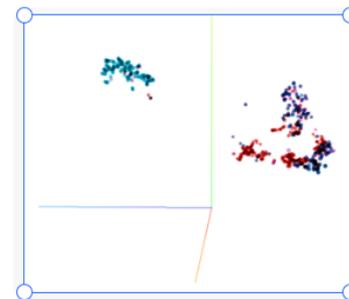


图2.2 T-SNE降维

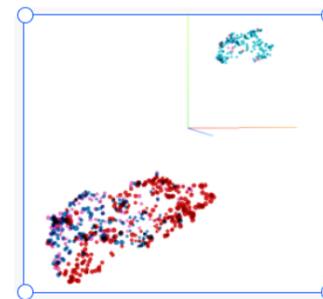


图2.3 UMAP降维



Multi-Genre

• id00500

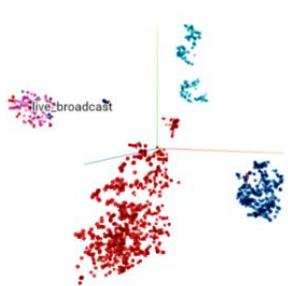


图3.1 PCA降维

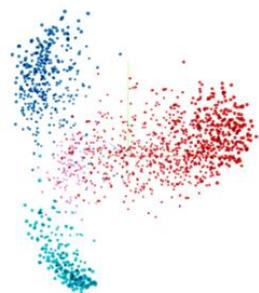


图3.2 T-SNE降维

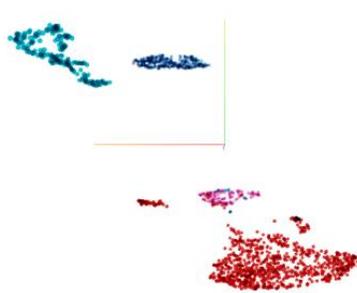


图3.3 UMAP降维

• id00523

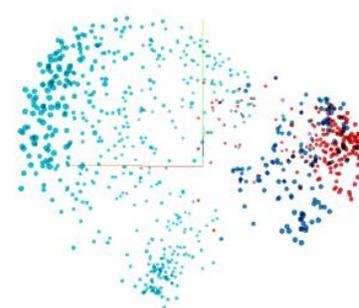


图4.1 PCA降维



图4.2 T-SNE降维

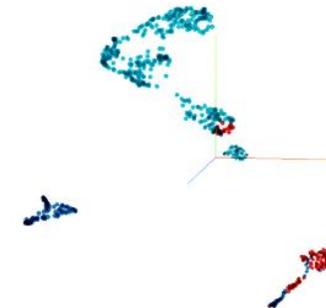


图4.3 UMAP降维

• id00702



图5.1 PCA降维



图5.2 T-SNE降维

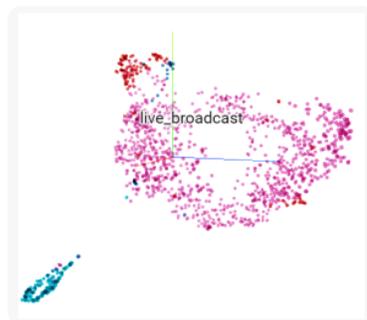


图5.3 UMAP降维

• id00976



图6.1 PCA降维



图6.2 T-SNE降维

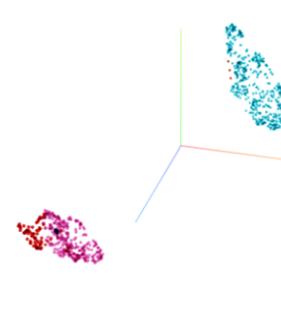


图6.3 UMAP降维



Conclusion

我们选取了六个不同的说话人，对于他们所共有的四类场景 `singing`、`interview`、`entertainment` 以及 `live_broadcast` 进行 PCA、T-SNE、UMAP 三种方式进行降维可视化，可以得到一个普遍的结论，即 `singing` 场景的 `acoustic distribution`（声学分布）和其他三类场景的 `acoustic distribution`（声学分布）的距离较远，内聚性较差；其中 `singing` 和 `entertainment` 场景的 `acoustic distribution` 相差最大。其他三类场景的分布距离较近，具有一定的相似性；其中 `interview` 场景和 `entertainment` 场景的分布距离很近，内聚效果很好，有着很高的相似性。

对于 `interview`、`entertainment`、`live_broadcast` 三类场景下的说话人确认来说，由于三类场景的 `acoustic distribution` 具有一定的相似性，场景信息的干扰较弱，当发生注册-测试场景失配时，识别性能仍相对可靠。对于 `singing` 和其他三类场景的说话人确认来说，场景特征对于说话人声纹特征的干扰作用较为明显，当发生场景失配时，极易造成较高的错误率。值得一提的是，`acoustic embedding` 分布的特性和 `multi-genre` 测试的结果完全吻合。这侧面意味着，`acoustic embedding` 中蕴含着能够描述场景特性的信息，可以作为 `conditional learning` 的辅助信息因子，帮助 `multi-genre training`，提升模型在 `multi-genre` 上的性能表现。

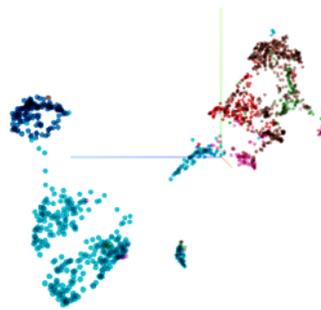
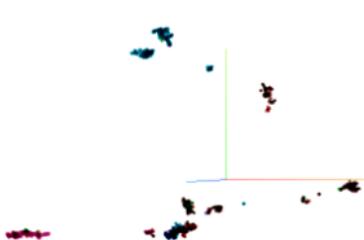
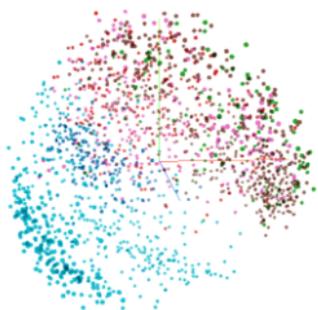


Multi-Speaker Single-Genre (MS-SG): 验证表格中对角线上的性能表现

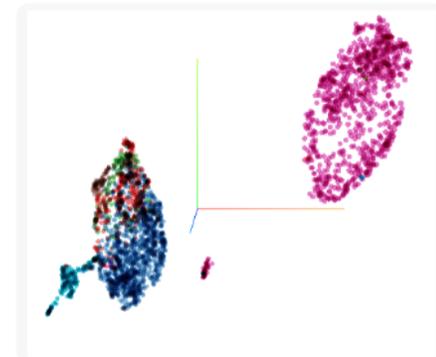
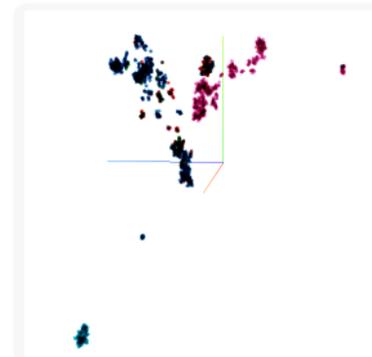
不同颜色代表不同的说话人，深蓝色代表 id00100，绿色代表 id00702，粉色代表 id00500，棕色代表 id00976，红色代表 id00392，淡蓝色代表 id00523

Multi-speaker

- Singing



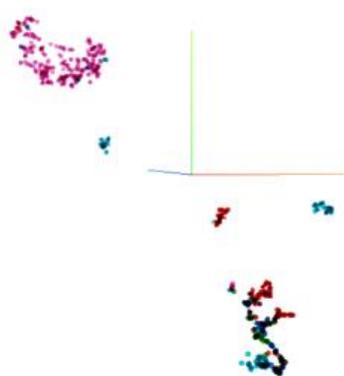
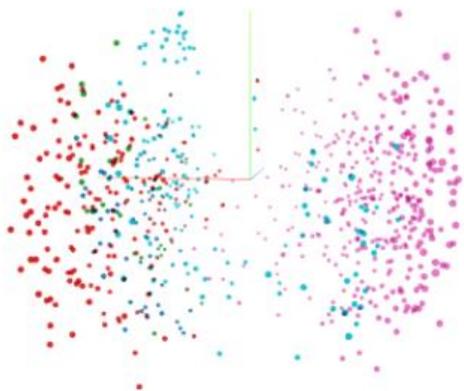
- Interview



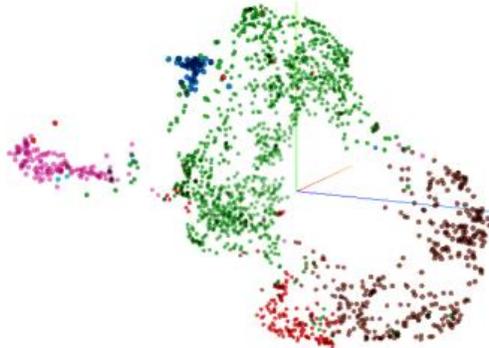
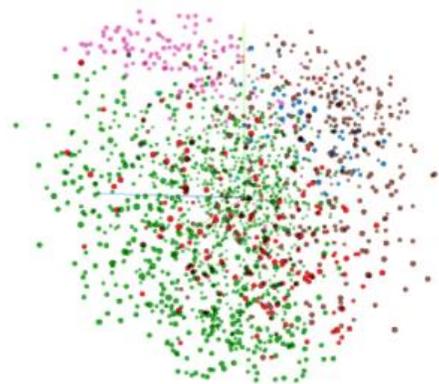


Multi-speaker :

- Entertainment



- live_broadcast



Conclusion

如上所示，live_broadcast 场景下的 acoustic distribution 具有不错区分性，entertainment 场景下的 acoustic distribution 的说话人区分性略逊于 live_broadcast，而 interview 场景下的 acoustic distribution 的说话人区分性最差的。

对照于 single-genre 的测试结果（对角线 EER 结果），live_broadcast 优于 entertainment 优于 interview。

这意味着 acoustic embedding 的说话人区分性与 speaker embedding 的说话人区分性在某种程度上具有一定的相关性。换言之，二者就说话人识别任务而言是互补的。



Data

采用 CN-Celeb1 多复杂场景中文明星数据集。该数据集包含1000位说话人，覆盖11种真实场景。选择 CNC1.dev 作为训练集（800人），用于模型训练；CNC1.eval 作为测试集（200人），用于性能评测。

Vanilla-blind training:

基于 x-vector 框架，使用 ResNet34L、ECAPA-TDNN 为两种 backbones，采用 AM-Softmax 损失函数，采用 Attentive statistic pooling 池化策略；后端使用 Cosine 余弦距离进行系统打分；使用等错误率 EER 作为评价指标。

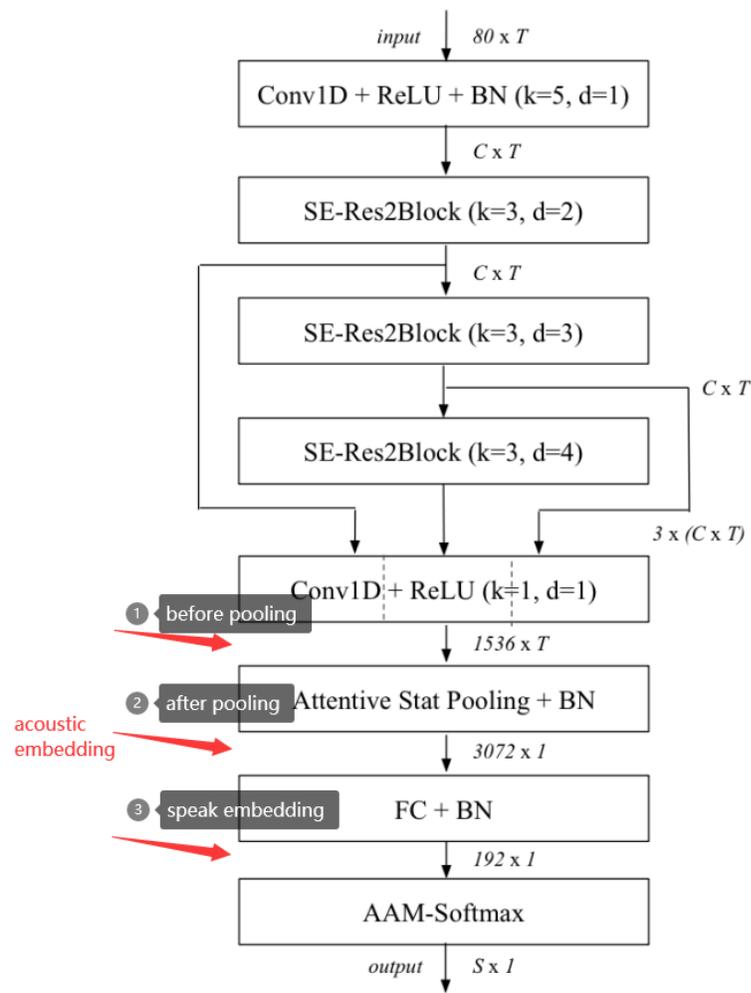
Vanilla-blind training result:

| Backbone | Loss function | Pooling | Emb_dim | Backend | EER(%) | Ckpt |
|------------|---------------|---------|---------|---------|---------------|-------------------------------|
| ResNet34L | AM-Softmax | ASP | 256 | Cosine | 15.736 | epoch=94_train_loss=0.11.ckpt |
| ECAPA-TDNN | AM-Softmax | ASP | 256 | Cosine | <u>16.412</u> | epoch=71_train_loss=0.15.ckpt |



Acoustic-aware training : Improvement ideas:

| Layer | Module | Output | |
|---------------------|---|---|---------------------------|
| Input | – | $80 \times 200 \times 1$ | |
| Conv2D | $3 \times 3 \times 32$, Stride 1 | $80 \times 200 \times 32$ | |
| ResNetBlock1 | $\begin{bmatrix} 3 \times 3 \times 32 \\ 3 \times 3 \times 32 \\ \text{SE Layer} \end{bmatrix} \times 3$, Stride 1 | $80 \times 200 \times 32$ | |
| ResNetBlock2 | $\begin{bmatrix} 3 \times 3 \times 64 \\ 3 \times 3 \times 64 \\ \text{SE Layer} \end{bmatrix} \times 4$, Stride 2 | $40 \times 100 \times 64$ | |
| ResNetBlock3 | $\begin{bmatrix} 3 \times 3 \times 128 \\ 3 \times 3 \times 128 \\ \text{SE Layer} \end{bmatrix} \times 6$, Stride 2 | $20 \times 50 \times 128$ | |
| 1 before pooling | ResNetBlock4 | $\begin{bmatrix} 3 \times 3 \times 256 \\ 3 \times 3 \times 256 \\ \text{SE Layer} \end{bmatrix} \times 3$, Stride 2 | $10 \times 25 \times 256$ |
| 2 after pooling | Pooling | TSP [37] | 20×256 |
| | Flatten | – | 5120 |
| 3 speaker embedding | Dense | – | 256 |
| | Dense | AM-Softmax [38] | 5994 |





| Backbone | Position | Loss function | Pooling | Emb_dim | Backend | EER(%) | Ckpt |
|------------|----------------|---------------|---------|---------|---------|--------|-------------------------------|
| ResNet34L | Before Pooling | AM-Softmax | ASP | 256 | Cosine | 15.477 | epoch=78_train_loss=0.07.ckpt |
| | After Pooling | | | | | 15.517 | epoch=83_train_loss=0.13.ckpt |
| | At Spk Emb | | | | | 14.892 | epoch=98_train_loss=0.21.ckpt |
| Backbone | Position | Loss function | Pooling | Emb_dim | Backend | EER(%) | Ckpt |
| ECAPA-TDNN | Before Pooling | AM-Softmax | ASP | 256 | Cosine | 15.984 | epoch=89_train_loss=0.09.ckpt |
| | After Pooling | | | | | 16.215 | epoch=76_train_loss=0.10.ckpt |
| | At Spk Emb | | | | | 16.176 | epoch=98_train_loss=0.13.ckpt |

Baseline:
15.736

Baseline:
16.412

对比实验结果，可见加入 acoustic embedding 的先验信息，可以一定程度上提升在多场景下的说话人识别表现。

当使用 ECAPA-TDNN 作为主干网络时，当嵌入到 pooling layer 之前，训练 loss 能降低更多，同时 EER 指标能提升 0.428%；当嵌入到 pooling layer 之后和 speaker embedding 之上的性能提升并不明显。

当使用 ResNet34L 作为主干网络时，加在 pooling layer 之前和之后的效果提升并不明显，但是当嵌入到 Speaker embedding 之上时，性能的改善极为明显。



| Backbone | Position | Loss function | Pooling | Emb_dim | Backend | EER(%) | Ckpt | Test embedding |
|------------|------------|---------------|---------|---------|---------|--------|-------------------------------|--------------------------------------|
| ResNet34L | At Spk Emb | AM-Softmax | ASP | 256 | Cosine | 14.892 | epoch=98_train_loss=0.21.ckpt | Speaker embedding |
| ResNet34L | At Spk Emb | AM-Softmax | ASP | 256 | Cosine | 14.959 | epoch=98_train_loss=0.21.ckpt | Speaker embedding+acoustic embedding |
| Backbone | Position | Loss function | Pooling | Emb_dim | Backend | EER(%) | Ckpt | Test embedding |
| ECAPA-TDNN | At Spk Emb | AM-Softmax | ASP | 256 | Cosine | 16.176 | epoch=98_train_loss=0.13.ckpt | Speaker embedding |
| ECAPA-TDNN | At Spk Emb | AM-Softmax | ASP | 256 | Cosine | 16.328 | epoch=98_train_loss=0.13.ckpt | Speaker embedding+acoustic embedding |

在测试过程中，当输入的 Test embedding 为 Speaker embedding，识别表现结果要优于输入的 Test embedding 为 Speaker embedding + acoustic embedding。

分析：对于目标说话人测试列表，注册场景和测试场景相同的情况下，加入 acoustic embedding 会正向的提升识别性能；在注册场景和测试场景不同的情况下，加入 acoustic embedding 会反向降低识别性能。对于非目标说话人测试列表，效果是截然相反的。

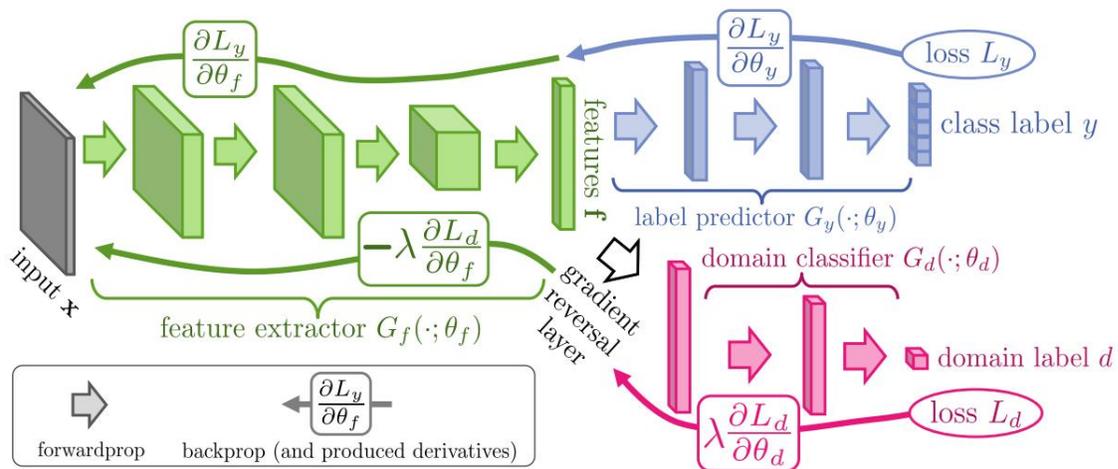
从实验结果看出，输入的 Test embedding 为 Speaker embedding 时，识别效果更好。这是可以理解的，因为在多场景说话人识别任务中，注册和测试场景不同的情况比两者场景相同的情况要更为普遍。



- 语音数据中的声纹信息和场景信息是强耦合的，这种耦合关系会极大的影响识别的准确率。
- 部分场景的声学分布具有很高的相似性，对于这部分场景信息来说，不容易发生注册-测试失配问题。某些场景和其它场景的声学分布差别较大，对于这部分场景，场景特征对于声纹特征的干扰更加明显。
- 不同场景下的说话人分布差异很明显。部分场景下，不同说话人之间的方差较小，在这些场景下的说话人识别任务性能较差。
- 加入 acoustic embedding 的 condition-aware learning 可以在一定程度上滤除说话人特征中的场景信息，提高多场景说话人识别的性能。



- Multi-task training and Genre-adversarial training



- Working on large data sets

将现在的工作迁移到大数据集上进行验证



Thank you for your listening !

Zhenyu Zhou

Instructors: Lantian Li

2022.11.04