

Lecture 03: 语音信号处理基础

预处理与特征提取

王帅

南京大学智能科学与技术学院

2025 年 9 月 8 日



南京大學
NANJING UNIVERSITY




智能科学与技术学院
School of Intelligence Science and Technology

- 1 引言与基础
- 2 语音信号预处理 (Pre-processing)
- 3 核心：特征提取 (Feature Extraction)
- 4 总结 (Summary)

物理世界的语音信号

物理世界的语音信号


- 连续的压力波
- 模拟信号 (Analog)
- 信息丰富但高度冗余



计算机世界的数字表示

物理世界的语音信号

- 连续的压力波
- 模拟信号 (Analog)
- 信息丰富但高度冗余




计算机世界的数字表示

- 离散的数值序列
- 数字信号 (Digital)
- 精炼、可计算的 **特征**


物理世界的语音信号

- 连续的压力波
- 模拟信号 (Analog)
- 信息丰富但高度冗余



计算机世界的数字表示

- 离散的数值序列
- 数字信号 (Digital)
- 精炼、可计算的 **特征**




信号的类型

周期性



确定信号：信号根据已有的公式而产生

周期信号：根据周期 τ 进行重复



非周期信号：任何没有固定周期的信号



随机信号：在 t 时刻的信号是一个随机变量的函数：不可预见



人类产生的声波信号


发声原理



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology



声源系统

呼吸系统

肺部作为气泵，通过膈肌和肋间肌的运动提供动力气流

喉部结构

声带（Vocal Folds）是发声的关键器官，两片富有弹性的肌肉膜

声带振动

气流通过声带时，声带周期性振动

滤波器系统

声道结构

可变的谐振腔，从喉部上方延伸至嘴唇和鼻孔，包括咽腔、口腔和鼻腔

共振峰（Formants）

声道内部空气柱发生共振，在特定频率上产生能量峰值

声道形状变化

不同形状导致不同共振峰频率，是区分不同音素的关键机制

人类产生的声波信号

发声原理



🔊 浊音 (Voiced Sound)

声带处于适当张力并相互靠近，气流通过时引起声带周期性振动周期性振动产生基频 (F_0)

示例：元音 (a, e, i, o, u)、辅音 (m, n, b, d, g, z, v)

🔊 轻音 (Unvoiced Sound)

声带张开，气流通过时不会引起声带振动，直接通过喉部形成湍流无明显的基频，声学特性更接近噪声


示例：辅音 (p, t, k, f, s, h)

🔊 基频 (Fundamental Frequency, F_0)


基频决定了语音的音高，声带振动越快，音高越高

↑ 成人男性基频范围：约80-120 Hz

↑ 成人女性基频范围：约160-240 Hz



人类的发音是一个复杂而精妙的过程，主要涉及动力区、激励区和调制区三个部分的器官协同作用。



调制区由舌头、上齿、双唇、咽腔等组成。

- 舌头的前后位置、高低位置以及卷曲程度的不同，可以产生不同的元音和辅音。
- 上齿和双唇可以通过开合、紧闭、突出等动作，与气流相互作用，产生不同的爆破音、摩擦音和鼻音等辅音。

激励区包括喉头、气管和声带。

- 喉头又称喉结，由软骨、肌肉和韧带组成，内部有声带
- 气流从肺部经气管上升至喉头，声带根据发音需要振动或不振动

动力区主要由胸腔、肺和横膈膜组成。

- 肺是呼吸主要器官，发音时肺部呼出气流提供动力
- 横膈膜位于胸腔和腹腔之间，在发音过程中，通过收缩和放松来调节气流的强弱和稳定性。

人类产生的声波信号


语音时域信号的特点



- ① 清音段: 能量低, 过零率高, 波形特点有点像随机的噪声。这部分信号常与语音的辅音段对应。
- ② 浊音段: 能量高, 过零率低, 波形具有周期性特点。所谓的短时平稳性质就是处于这个语音浊音(元音)段中。
- ③ 过渡段: 一般是指从辅音段向元音段信号变化之间的部分。信号变化快, 是语音信号处理中最复杂、困难的部分。

人类产生的声波信号

数字语音波形记录



当我们对着一个麦克风说话的时候,声压的变化被转化成电压层面的成比例的变化。一台装有合适硬件的计算机通过一个被称为模数转换 (ADC) 的过程,可以将模拟电压信号变化转化成数字声音的波形信号。

信号的类型

离散和连续




南京大学
NANJING UNIVERSITY




智能科学与技术学院
School of Intelligence Science and Technology

连续-时间/幅值信号:



离散-时间/幅值信号:



第一步：数字化之采样 (Sampling)

时间维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

奈奎斯特-香农采样定理 (Nyquist-Shannon Sampling Theorem)

为了无失真地从样本中恢复原始模拟信号，采样频率 f_s 必须至少是原始信号最高频率 $f_{\max}$ 的两倍。

第一步：数字化之采样 (Sampling)

时间维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

奈奎斯特-香农采样定理 (Nyquist-Shannon Sampling Theorem)

为了无失真地从样本中恢复原始模拟信号，采样频率 f_s 必须至少是原始信号最高频率 $f_{\max}$ 的两倍。

$$f_s \geq 2 \cdot f_{\max}$$

第一步：数字化之采样 (Sampling)

时间维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

奈奎斯特-香农采样定理 (Nyquist-Shannon Sampling Theorem)

为了无失真地从样本中恢复原始模拟信号，采样频率 f_s 必须至少是原始信号最高频率 $f_{\max}$ 的两倍。

$$f_s \geq 2 \cdot f_{\max}$$

应用实例

- 人声有效频率范围：主要能量集中在 4 kHz 以下，但泛音可达更高。

第一步：数字化之采样 (Sampling)

时间维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

奈奎斯特-香农采样定理 (Nyquist-Shannon Sampling Theorem)

为了无失真地从样本中恢复原始模拟信号，采样频率 f_s 必须至少是原始信号最高频率 $f_{\max}$ 的两倍。

$$f_s \geq 2 \cdot f_{\max}$$

应用实例

- 人声有效频率范围：主要能量集中在 4 kHz 以下，但泛音可达更高。
- 电话语音 (窄带)： $f_{\max} \approx 4 \text{ kHz}$ ，因此行业标准采样率为 8 kHz。

第一步：数字化之采样 (Sampling)

时间维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

奈奎斯特-香农采样定理 (Nyquist-Shannon Sampling Theorem)

为了无失真地从样本中恢复原始模拟信号，采样频率 f_s 必须至少是原始信号最高频率 $f_{\max}$ 的两倍。

$$f_s \geq 2 \cdot f_{\max}$$

应用实例

- 人声有效频率范围：主要能量集中在 4 kHz 以下，但泛音可达更高。
- 电话语音 (窄带)： $f_{\max} \approx 4 \text{ kHz}$ ，因此行业标准采样率为 8 kHz。
- 通用语音识别 (宽带)：为保留更丰富的泛音细节，通常 $f_{\max} \approx 8 \text{ kHz}$ ，标准采样率为 16 kHz。

第一步：数字化之采样 (Sampling)

时间维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

奈奎斯特-香农采样定理 (Nyquist-Shannon Sampling Theorem)

为了无失真地从样本中恢复原始模拟信号，采样频率 f_s 必须至少是原始信号最高频率 $f_{\max}$ 的两倍。

$$f_s \geq 2 \cdot f_{\max}$$

应用实例

- 人声有效频率范围：主要能量集中在 4 kHz 以下，但泛音可达更高。
- 电话语音 (窄带)： $f_{\max} \approx 4 \text{ kHz}$ ，因此行业标准采样率为 **8 kHz**。
- 通用语音识别 (宽带)：为保留更丰富的泛音细节，通常 $f_{\max} \approx 8 \text{ kHz}$ ，标准采样率为 **16 kHz**。
- 关键问题：如果采样率不足 ($f_s < 2f_{\max}$) 会发生什么？→ **频谱混叠 (Aliasing)**。

第一步：数字化之量化 (Quantization)

幅度维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 采样后，每个样本点的幅度值是连续的。

第一步：数字化之量化 (Quantization)

幅度维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 采样后，每个样本点的幅度值是连续的。
- 量化 (Quantization) 是用有限个离散电平来近似表示连续的幅度值。

第一步：数字化之量化 (Quantization)

幅度维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 采样后，每个样本点的幅度值是连续的。
- 量化 (Quantization) 是用有限个离散电平来近似表示连续的幅度值。
- 使用 B 个比特 (bit) 表示一个样本，则共有 2^B 个量化级别。

第一步：数字化之量化 (Quantization)

幅度维度的离散化



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 采样后，每个样本点的幅度值是连续的。
- 量化 (Quantization) 是用有限个离散电平来近似表示连续的幅度值。
- 使用 B 个比特 (bit) 表示一个样本，则共有 2^B 个量化级别。

第一步：数字化之量化 (Quantization)

幅度维度的离散化




南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 采样后，每个样本点的幅度值是连续的。
- 量化 (Quantization) 是用有限个离散电平来近似表示连续的幅度值。
- 使用 B 个比特 (bit) 表示一个样本，则共有 2^B 个量化级别。



行业标准：16-bit PCM

16-bit 脉冲编码调制 (PCM) 是语音处理中最常用的标准。

- $B = 16$, 提供 $2^{16} = 65,536$ 个量化级别。

量化误差 (Quantization Error)

$$e[n] = x_q[n] - x[n]$$

原始采样值 $x[n]$ 与量化后的值 $x_q[n]$ 的差。

核心假设：语音信号的短时平稳性 (Quasi-stationary)

语音信号在宏观上是时变的（非平稳），但在一个足够短的时间窗口内（如 10 ms to 30 ms），其发声器官状态和信号统计特性可以认为是基本不变的（平稳）。

核心假设：语音信号的短时平稳性 (Quasi-stationary)

语音信号在宏观上是时变的（非平稳），但在一个足够短的时间窗口内（如 10 ms to 30 ms），其发声器官状态和信号统计特性可以认为是基本不变的（平稳）。

为什么？

我们的发声器官（声带、舌头、嘴唇）的物理状态在短时间内不会发生剧烈变化。

怎么办？

将信号切分成很多短小的“帧” (Frame)，对每一帧进行独立分析。这就是分帧的思想。

核心假设：语音信号的短时平稳性 (Quasi-stationary)

语音信号在宏观上是时变的（非平稳），但在一个足够短的时间窗口内（如 10 ms to 30 ms），其发声器官状态和信号统计特性可以认为是基本不变的（平稳）。

为什么？

我们的发声器官（声带、舌头、嘴唇）的物理状态在短时间内不会发生剧烈变化。

怎么办？

将信号切分成很多短小的“帧” (Frame)，对每一帧进行独立分析。这就是分帧的思想。

经典预处理流程

去直流/预加重 → 分帧 → 加窗

预处理 (1)

预加重 (Pre-emphasis)



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

目的

- 提升高频分量的能量，补偿语音信号高频滚降的特性。

预处理 (1)

预加重 (Pre-emphasis)



目的

- 提升高频分量的能量，补偿语音信号高频滚降的特性。
- 突出高频共振峰，这对区分不同的辅音（如 /s/, /f/）至关重要。

预处理 (1)

预加重 (Pre-emphasis)



目的

- 提升高频分量的能量，补偿语音信号高频滚降的特性。
- 突出高频共振峰，这对区分不同的辅音（如 /s/, /f/）至关重要。
- 某种程度上，可以平滑频谱，并改善后续傅里叶变换的数值稳定性。

预处理 (1)

预加重 (Pre-emphasis)



目的

- 提升高频分量的能量，补偿语音信号高频滚降的特性。
- 突出高频共振峰，这对区分不同的辅音（如 /s/, /f/）至关重要。
- 某种程度上，可以平滑频谱，并改善后续傅里叶变换的数值稳定性。

预处理 (1)

预加重 (Pre-emphasis)



目的

- 提升高频分量的能量，补偿语音信号高频滚降的特性。
- 突出高频共振峰，这对区分不同的辅音（如 /s/, /f/）至关重要。
- 某种程度上，可以平滑频谱，并改善后续傅里叶变换的数值稳定性。

实现方法：一阶高通滤波器

将信号通过一个简单的一阶有限冲激响应 (FIR) 滤波器：

$$y[n] = x[n] - \alpha \cdot x[n - 1]$$

目的

- 提升高频分量的能量，补偿语音信号高频滚降的特性。
- 突出高频共振峰，这对区分不同的辅音（如 /s/, /f/）至关重要。
- 某种程度上，可以平滑频谱，并改善后续傅里叶变换的数值稳定性。

实现方法：一阶高通滤波器

将信号通过一个简单的一阶有限冲激响应 (FIR) 滤波器：

$$y[n] = x[n] - \alpha \cdot x[n - 1]$$

- $y[n]$ 是预加重后的信号。
- $x[n]$ 是原始信号。
- α 是预加重系数，通常取值在 0.95 到 0.97 之间。

分帧 (Framing)

- 帧长 (**Frame Size**): 通常为 20 ms to 30 ms。
(16 kHz 采样率下, 25 ms = 400 个采样点)
- 帧移 (**Frame Shift**): 通常为 10 ms。
(16 kHz 采样率下, 10 ms = 160 个采样点)
- 帧与帧之间有 重叠, 确保信息的平滑过渡。

加窗 (Windowing)

- 问题: 直接截断一帧信号 (等于乘以矩形窗) 会在频域引入严重的 频谱泄漏 (Spectral Leakage)。
- 方案: 乘以一个两端平滑过渡到零的窗函数, 如汉明窗。

分帧 (Framing)

- 帧长 (**Frame Size**): 通常为 20 ms to 30 ms。
(16 kHz 采样率下, 25 ms = 400 个采样点)
- 帧移 (**Frame Shift**): 通常为 10 ms。
(16 kHz 采样率下, 10 ms = 160 个采样点)
- 帧与帧之间有 重叠, 确保信息的平滑过渡。

加窗 (Windowing)

- 问题: 直接截断一帧信号 (等于乘以矩形窗) 会在频域引入严重的 频谱泄漏 (Spectral Leakage)。
- 方案: 乘以一个两端平滑过渡到零的窗函数, 如汉明窗。

类比


直接分帧就像用剪刀“咔嚓”一下剪断绳子, 断口会炸开; 加窗则像是在剪断前, 先用胶水把两端捻细, 断口就会很平滑。

预处理 (2) & (3)

分帧



完整语音波形是一个很长的非平稳长时采样序列. 在语音信号处理中, 将长时序列分成准平稳的不同的块/帧是很有用的



汉明窗 (Hamming Window) - 语音领域最常用

对于一个长度为 N 的帧，窗函数 $w[n]$ 定义为：

$$w[n] = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \leq n \leq N-1$$

加窗后的信号 $x_w[n] = x[n] \cdot w[n]$ 。

汉明窗 (Hamming Window) - 语音领域最常用

对于一个长度为 N 的帧，窗函数 $w[n]$ 定义为：

$$w[n] = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \leq n \leq N-1$$

加窗后的信号 $x_w[n] = x[n] \cdot w[n]$ 。

矩形窗 (Rectangular)

- $w[n] = 1$
- 优点：主瓣窄 (频率分辨率高)
- 缺点：旁瓣高 (频谱泄漏严重)

汉明窗/汉宁窗

- 两端趋于 0
- 优点：旁瓣低 (有效抑制频谱泄漏)
- 缺点：主瓣略宽 (频率分辨率稍低)

汉明窗 (Hamming Window) - 语音领域最常用

对于一个长度为 N 的帧，窗函数 $w[n]$ 定义为：

$$w[n] = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \leq n \leq N-1$$

加窗后的信号 $x_w[n] = x[n] \cdot w[n]$ 。

矩形窗 (Rectangular)

- $w[n] = 1$
- 优点：主瓣窄 (频率分辨率高)
- 缺点：旁瓣高 (频谱泄漏严重)

汉明窗/汉宁窗

- 两端趋于 0
- 优点：旁瓣低 (有效抑制频谱泄漏)
- 缺点：主瓣略宽 (频率分辨率稍低)

多数情况抑制频谱泄漏比追求极致的频率分辨率重要，因此汉明窗是标准选择。

为什么要进行时频分析？

从时域波形到频域特征



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

时域分析的局限性

时域波形缺乏直观的结构性。同一个音素（如 /a/），不同人说出来，甚至同一个人在不同时间说，其波形都可能千差万别。

思考：我们如何才能“看透”波形，找到其背后稳定不变的本质？

为什么要进行时频分析？

从时域波形到频域特征



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

时域分析的局限性

时域波形缺乏直观的结构性。同一个音素（如 /a/），不同人说出来，甚至同一个人在不同时间说，其波形都可能千差万别。

思考：我们如何才能“看透”波形，找到其背后稳定不变的本质？

分析频率成分

语音的本质特征隐藏在频率中。例如，元音的身份由几个关键的共振峰 (**Formants**) 的频率位置决定。这些频率特征比时域波形稳定得多。

目标：我们需要一个工具，能揭示信号在不同时间点的频率构成。

核心工具：短时傅里叶变换 (STFT)

捕捉时变的频谱特性



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

基本原理：语音的短时平稳性 (Short-Time Stationarity)

语音信号整体上是非平稳的，其统计特性随时间快速变化。但在一个足够短的时间窗口内（如 20-30ms），声道形状可视为近似不变，信号表现出准平稳特性。

核心工具：短时傅里叶变换 (STFT)

捕捉时变的频谱特性



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

基本原理：语音的短时平稳性 (Short-Time Stationarity)

语音信号整体上是非平稳的，其统计特性随时间快速变化。但在一个足够短的时间窗口内（如 20-30ms），声道形状可视为近似不变，信号表现出准平稳特性。

STFT：滑动窗口分析法

STFT 的过程就像用一个“探照灯”（窗函数）在时间轴上滑动：

- ① 分帧 (Framing): 将信号切分成一系列有重叠的短时帧。

声谱图是语音信号的“指纹”，可视化了能量在时间和频率上的分布。

核心工具：短时傅里叶变换 (STFT)

捕捉时变的频谱特性



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

基本原理：语音的短时平稳性 (Short-Time Stationarity)

语音信号整体上是非平稳的，其统计特性随时间快速变化。但在一个足够短的时间窗口内（如 20-30ms），声道形状可视为近似不变，信号表现出准平稳特性。

STFT：滑动窗口分析法

STFT 的过程就像用一个“探照灯”（窗函数）在时间轴上滑动：

- ① 分帧 (Framing): 将信号切分成一系列有重叠的短时帧。
- ② 加窗 (Windowing): 对每一帧乘以一个窗函数，以平滑帧的边缘。

声谱图是语音信号的“指纹”，可视化了能量在时间和频率上的分布。

核心工具：短时傅里叶变换 (STFT)

捕捉时变的频谱特性



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

基本原理：语音的短时平稳性 (Short-Time Stationarity)

语音信号整体上是非平稳的，其统计特性随时间快速变化。但在一个足够短的时间窗口内（如 20-30ms），声道形状可视为近似不变，信号表现出准平稳特性。

STFT：滑动窗口分析法

STFT 的过程就像用一个“探照灯”（窗函数）在时间轴上滑动：

- ① 分帧 (Framing): 将信号切分成一系列有重叠的短时帧。
- ② 加窗 (Windowing): 对每一帧乘以一个窗函数，以平滑帧的边缘。
- ③ 变换 (Transform): 对加窗后的每一帧进行傅里叶变换 (FFT)，得到该时间点的频谱。

声谱图是语音信号的“指纹”，可视化了能量在时间和频率上的分布。

核心工具：短时傅里叶变换 (STFT)

捕捉时变的频谱特性



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

基本原理：语音的短时平稳性 (Short-Time Stationarity)

语音信号整体上是非平稳的，其统计特性随时间快速变化。但在一个足够短的时间窗口内（如 20-30ms），声道形状可视为近似不变，信号表现出准平稳特性。

STFT：滑动窗口分析法

STFT 的过程就像用一个“探照灯”（窗函数）在时间轴上滑动：

- ① 分帧 (Framing): 将信号切分成一系列有重叠的短时帧。
- ② 加窗 (Windowing): 对每一帧乘以一个窗函数，以平滑帧的边缘。
- ③ 变换 (Transform): 对加窗后的每一帧进行傅里叶变换 (FFT)，得到该时间点的频谱。
- ④ 组合 (Combine): 将所有帧的频谱按时间顺序排列，形成声谱图 (Spectrogram)。

声谱图是语音信号的“指纹”，可视化了能量在时间和频率上的分布。

STFT 公式

在时间点 m 和频率点 k 的 STFT 值 $X(m, k)$ 定义为：

$$X(m, k) = \sum_{n=0}^{N-1} x[n + mH] \cdot w[n] \cdot e^{-j \frac{2\pi kn}{N_{\text{FFT}}}}$$

- $x[\cdot]$: 原始信号
- $w[n]$: 长度为 N 的窗函数
- H : 帧移 (Hop Length)
- N_{FFT} : FFT 计算点数 (通常 $N_{\text{FFT}} \geq N$)

Why STFT ?

语音的短时平稳性与听觉相关性



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 语音是非平稳信号，但在短时间（约 20 ms–30 ms）内可近似平稳：声道形状在该尺度内变化缓慢。

Why STFT ?

语音的短时平稳性与听觉相关性



- 语音是非平稳信号，但在短时间（约 20 ms–30 ms）内可近似平稳：声道形状在该尺度内变化缓慢。
- 元音等共振峰（Formants）对应声道共振，短时幅度谱能稳定刻画其位置；辅音/爆破体现在高频能量与瞬态结构。

Why STFT ?



语音的短时平稳性与听觉相关性

- 语音是非平稳信号，但在短时间（约 20 ms–30 ms）内可近似平稳：声道形状在该尺度内变化缓慢。
- 元音等共振峰（Formants）对应声道共振，短时幅度谱能稳定刻画其位置；辅音/爆破体现在高频能量与瞬态结构。
- 发声源-声道模型：声源（脉冲列/噪声）经声道滤波，短时谱近似为声道响应的幅度包络 → 借助 STFT 可提取 MFCC、Mel 频谱等特征。

Why STFT ?

语音的短时平稳性与听觉相关性



- 语音是非平稳信号，但在短时间（约 20 ms–30 ms）内可近似平稳：声道形状在该尺度内变化缓慢。
- 元音等共振峰（Formants）对应声道共振，短时幅度谱能稳定刻画其位置；辅音/爆破体现在高频能量与瞬态结构。
- 发声源-声道模型：声源（脉冲列/噪声）经声道滤波，短时谱近似为声道响应的幅度包络 → 借助 STFT 可提取 MFCC、Mel 频谱等特征。
- 连续时间/全局频域会把不同语音单元的时变特性“混在一起”，难以对齐音素级事件；STFT 提供时频局部化表示，便于 ASR、TTS、增强与分离。

Why STFT ?

语音的短时平稳性与听觉相关性



- 语音是非平稳信号，但在短时间（约 20 ms–30 ms）内可近似平稳：声道形状在该尺度内变化缓慢。
- 元音等共振峰（Formants）对应声道共振，短时幅度谱能稳定刻画其位置；辅音/爆破体现在高频能量与瞬态结构。
- 发声源-声道模型：声源（脉冲列/噪声）经声道滤波，短时谱近似为声道响应的幅度包络 → 借助 STFT 可提取 MFCC、Mel 频谱等特征。
- 连续时间/全局频域会把不同语音单元的时变特性“混在一起”，难以对齐音素级事件；STFT 提供时频局部化表示，便于 ASR、TTS、增强与分离。
- 计算与工程可行性：S-DFT/FFT 高效、成熟，逆变换（iSTFT）易于重建（配合重叠加法与窗修正）。

1. 连续时间傅里叶变换 (CTFT)

- 对象: 连续、非周期信号 $x(t)$ 。
- 特点: 得到连续、非周期的频谱 $X(f)$ 。是纯粹的理论分析工具。

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt$$

1. 连续时间傅里叶变换 (CTFT)

- 对象: 连续、非周期信号 $x(t)$ 。
- 特点: 得到连续、非周期的频谱 $X(f)$ 。是纯粹的理论分析工具。

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt$$

2. 离散时间傅里叶变换 (DTFT)

- 对象: 离散、无限长信号 $x[n]$ (由 $x(t)$ 采样得到)。
- 特点: 得到连续、但以 2π 为周期的频谱 $X(e^{j\omega})$ 。理论上完美，但无法直接在计算机上精确计算。

3. 离散傅里叶变换 (DFT) 与快速傅里叶变换 (FFT)

- 对象: 离散、有限长信号 $x[n]$ (对 $x[n]$ 进行截断/分帧)。
- 特点: 得到离散、有限长的频谱 $X[k]$ 。

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j \frac{2\pi kn}{N}}$$

- **FFT**: 是一种高效计算 DFT 的算法，将复杂度从 $O(N^2)$ 降至 $O(N \log N)$ ，使得 STFT 等分析方法在工程上成为可能。

核心思想

MFCC (Mel-Frequency Cepstral Coefficients) 是一种模仿 **人耳听觉机理** 的特征。关键在于：人耳对频率的感知是 **非线性的**，对低频声音的变化比高频更敏感。

核心思想

MFCC (Mel-Frequency Cepstral Coefficients) 是一种模仿 **人耳听觉机理** 的特征。关键在于：人耳对频率的感知是非线性的，对低频声音的变化比高频更敏感。

MFCC 提取全流程

- ① 预处理: 预加重、分帧、加窗
- ② **FFT**: 计算每一帧的功率谱

核心思想

MFCC (Mel-Frequency Cepstral Coefficients) 是一种模仿 **人耳听觉机理** 的特征。关键在于：人耳对频率的感知是非线性的，对低频声音的变化比高频更敏感。

MFCC 提取全流程

- 1 预处理: 预加重、分帧、加窗
- 2 **FFT**: 计算每一帧的功率谱
- 3 梅尔滤波器组: 将功率谱通过一组特殊的三角滤波器

核心思想

MFCC (Mel-Frequency Cepstral Coefficients) 是一种模仿 **人耳听觉机理** 的特征。关键在于：人耳对频率的感知是非线性的，对低频声音的变化比高频更敏感。

MFCC 提取全流程

- 1 预处理: 预加重、分帧、加窗
- 2 **FFT**: 计算每一帧的功率谱
- 3 梅尔滤波器组: 将功率谱通过一组特殊的三角滤波器
- 4 对数能量: 计算每个滤波器输出的对数能量

核心思想

MFCC (Mel-Frequency Cepstral Coefficients) 是一种模仿 **人耳听觉机理** 的特征。关键在于：人耳对频率的感知是非线性的，对低频声音的变化比高频更敏感。

MFCC 提取全流程

- 1 预处理: 预加重、分帧、加窗
- 2 **FFT**: 计算每一帧的功率谱
- 3 梅尔滤波器组: 将功率谱通过一组特殊的三角滤波器
- 4 对数能量: 计算每个滤波器输出的对数能量
- 5 **DCT**: 进行离散余弦变换, 解相关并降维

梅尔尺度 (Mel Scale)

一个基于人耳感知建立的非线性频率尺度。它与物理频率 f (Hz) 的转换关系近似为：

$$\text{mel} = 2595 \log_{10} \left(1 + \frac{f}{700} \right)$$

梅尔尺度 (Mel Scale)

一个基于人耳感知建立的非线性频率尺度。它与物理频率 f (Hz) 的转换关系近似为：

$$\text{mel} = 2595 \log_{10} \left(1 + \frac{f}{700} \right)$$

- 特点：低频区域，梅尔尺度与赫兹尺度近似线性；高频区域近似对数关系。

梅尔尺度 (Mel Scale)

一个基于人耳感知建立的非线性频率尺度。它与物理频率 f (Hz) 的转换关系近似为：

$$\text{mel} = 2595 \log_{10} \left(1 + \frac{f}{700} \right)$$

- 特点：低频区域，梅尔尺度与赫兹尺度近似线性；高频区域近似对数关系。
- 滤波器组：一组三角滤波器（通常 20-40 个），在梅尔尺度上等距分布。

梅尔尺度 (Mel Scale)

一个基于人耳感知建立的非线性频率尺度。它与物理频率 f (Hz) 的转换关系近似为：

$$\text{mel} = 2595 \log_{10} \left(1 + \frac{f}{700} \right)$$

- **特点：**低频区域，梅尔尺度与赫兹尺度近似线性；高频区域近似**对数**关系。
- **滤波器组：**一组三角滤波器（通常 20-40 个），在梅尔尺度上等距分布。
- **结果：**这意味着在低频区滤波器密集、窄小，在高频区滤波器稀疏、宽大，完美模拟人耳特性。

步骤 4: 计算对数能量

将功率谱与每个梅尔滤波器相乘再求和，得到每个滤波器的输出能量 E_i ，然后取对数。

$$S[i] = \ln \left(\sum_k P[k] M_i[k] \right)$$

- $M_i[k]$ 是第 i 个梅尔滤波器。

步骤 4: 计算对数能量

将功率谱与每个梅尔滤波器相乘再求和，得到每个滤波器的输出能量 E_i ，然后取对数。

$$S[i] = \ln \left(\sum_k P[k] M_i[k] \right)$$

- $M_i[k]$ 是第 i 个梅尔滤波器。
- 为何取对数？ 1. 模仿人耳对声音强度的对数感知； 2. 压缩数值动态范围。

步骤 4: 计算对数能量

将功率谱与每个梅尔滤波器相乘再求和，得到每个滤波器的输出能量 E_i ，然后取对数。

$$S[i] = \ln \left(\sum_k P[k] M_i[k] \right)$$

- $M_i[k]$ 是第 i 个梅尔滤波器。
- 为何取对数？ 1. 模仿人耳对声音强度的对数感知； 2. 压缩数值动态范围。

步骤 4: 计算对数能量

将功率谱与每个梅尔滤波器相乘再求和，得到每个滤波器的输出能量 E_i ，然后取对数。

$$S[i] = \ln \left(\sum_k P[k] M_i[k] \right)$$

- $M_i[k]$ 是第 i 个梅尔滤波器。
- 为何取对数？1. 模仿人耳对声音强度的对数感知；2. 压缩数值动态范围。

步骤 5: 离散余弦变换 (DCT)

对数能量 $S[i]$ 之间存在相关性。DCT 是一种优秀的正交变换，可以有效解相关，并将能量集中在少数低阶系数上。

$$c[n] = \sum_{i=1}^K S[i] \cos \left(\frac{\pi n (i - 0.5)}{K} \right)$$

步骤 4: 计算对数能量

将功率谱与每个梅尔滤波器相乘再求和，得到每个滤波器的输出能量 E_i ，然后取对数。

$$S[i] = \ln \left(\sum_k P[k] M_i[k] \right)$$

- $M_i[k]$ 是第 i 个梅尔滤波器。
- 为何取对数？1. 模仿人耳对声音强度的对数感知；2. 压缩数值动态范围。

步骤 5: 离散余弦变换 (DCT)

对数能量 $S[i]$ 之间存在相关性。DCT 是一种优秀的正交变换，可以有效解相关，并将能量集中在少数低阶系数上。

$$c[n] = \sum_{i=1}^K S[i] \cos \left(\frac{\pi n (i - 0.5)}{K} \right)$$

为什么需要动态特征？

MFCC 是“静态”的，只描述了当前帧的频谱包络。但语音的精髓在于“变化”。例如，/b/ 和 /w/ 的稳态部分可能相似，但它们的 **过渡（动态）** 完全不同。

为什么需要动态特征？

MFCC 是“静态”的，只描述了当前帧的频谱包络。但语音的精髓在于“变化”。例如，/b/ 和 /w/ 的稳态部分可能相似，但它们的 **过渡（动态）** 完全不同。

计算方法：差分 (Differentiation)

第 t 帧的 Delta 特征 d_t 可以通过一个回归窗口来近似计算其一阶导数：

$$d_t = \frac{\sum_{n=1}^N n(c_{t+n} - c_{t-n})}{2 \sum_{n=1}^N n^2}$$

- c_t 是第 t 帧的静态 MFCC 向量。N 是回归窗口大小 (通常为 2)。

为什么需要动态特征？

MFCC 是“静态”的，只描述了当前帧的频谱包络。但语音的精髓在于“变化”。例如，/b/ 和 /w/ 的稳态部分可能相似，但它们的 **过渡（动态）** 完全不同。

计算方法：差分 (Differentiation)

第 t 帧的 Delta 特征 d_t 可以通过一个回归窗口来近似计算其一阶导数：

$$d_t = \frac{\sum_{n=1}^N n(c_{t+n} - c_{t-n})}{2 \sum_{n=1}^N n^2}$$

- c_t 是第 t 帧的静态 MFCC 向量。N 是回归窗口大小 (通常为 2)。
- 这本质上是在计算 MFCC 轨迹的 **速度 (velocity)**。

为什么需要动态特征?

MFCC 是“静态”的,只描述了当前帧的频谱包络。但语音的精髓在于“变化”。例如, /b/ 和 /w/ 的稳态部分可能相似,但它们的 **过渡 (动态)** 完全不同。

计算方法: 差分 (Differentiation)

第 t 帧的 Delta 特征 d_t 可以通过一个回归窗口来近似计算其一阶导数:

$$d_t = \frac{\sum_{n=1}^N n(c_{t+n} - c_{t-n})}{2 \sum_{n=1}^N n^2}$$

- c_t 是第 t 帧的静态 MFCC 向量。 N 是回归窗口大小 (通常为 2)。
- 这本质上是在计算 MFCC 轨迹的 **速度 (velocity)**。

为什么需要动态特征？

MFCC 是“静态”的，只描述了当前帧的频谱包络。但语音的精髓在于“变化”。例如，/b/ 和 /w/ 的稳态部分可能相似，但它们的 **过渡（动态）** 完全不同。

计算方法：差分 (Differentiation)

第 t 帧的 Delta 特征 d_t 可以通过一个回归窗口来近似计算其一阶导数：

$$d_t = \frac{\sum_{n=1}^N n(c_{t+n} - c_{t-n})}{2 \sum_{n=1}^N n^2}$$

- c_t 是第 t 帧的静态 MFCC 向量。N 是回归窗口大小 (通常为 2)。
- 这本质上是在计算 MFCC 轨迹的 **速度 (velocity)**。

总结：完整的信号处理流水线



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

① 模拟信号 $\xrightarrow{\text{麦克风}}$

总结：完整的信号处理流水线



- 1 模拟信号 $\xrightarrow{\text{麦克风}}$
- 2 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形

总结：完整的信号处理流水线



- 1 模拟信号 $\xrightarrow{\text{麦克风}}$
- 2 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- 3 预处理:

$\rightarrow$ 加窗后的信号帧序列

总结：完整的信号处理流水线



- ① 模拟信号 $\xrightarrow{\text{麦克风}}$
- ② 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- ③ 预处理:
 - 预加重 ($\alpha \approx 0.97$)

$\rightarrow$ 加窗后的信号帧序列

总结：完整的信号处理流水线



- ① 模拟信号 $\xrightarrow{\text{麦克风}}$
- ② 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- ③ 预处理:
 - 预加重 ($\alpha \approx 0.97$)
 - 分帧 (25 ms 帧长, 10 ms 帧移)

$\rightarrow$ 加窗后的信号帧序列

总结：完整的信号处理流水线



- ① 模拟信号 $\xrightarrow{\text{麦克风}}$
- ② 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- ③ 预处理:
 - 预加重 ($\alpha \approx 0.97$)
 - 分帧 (25 ms 帧长, 10 ms 帧移)
 - 加窗 (汉明窗) $\rightarrow$ 加窗后的信号帧序列

总结：完整的信号处理流水线



- ① 模拟信号 $\xrightarrow{\text{麦克风}}$
- ② 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- ③ 预处理:
 - 预加重 ($\alpha \approx 0.97$)
 - 分帧 (25 ms 帧长, 10 ms 帧移)
 - 加窗 (汉明窗) $\rightarrow$ 加窗后的信号帧序列
- ④ 特征提取 (以 **MFCC** 为例):

总结：完整的信号处理流水线



- ① 模拟信号 $\xrightarrow{\text{麦克风}}$
- ② 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- ③ 预处理:
 - 预加重 ($\alpha \approx 0.97$)
 - 分帧 (25 ms 帧长, 10 ms 帧移)
 - 加窗 (汉明窗) $\rightarrow$ 加窗后的信号帧序列
- ④ 特征提取 (以 **MFCC** 为例):
 - FFT $\rightarrow$ 功率谱

总结：完整的信号处理流水线



- ① 模拟信号 $\xrightarrow{\text{麦克风}}$
- ② 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- ③ 预处理:
 - 预加重 ($\alpha \approx 0.97$)
 - 分帧 (25 ms 帧长, 10 ms 帧移)
 - 加窗 (汉明窗) $\rightarrow$ 加窗后的信号帧序列
- ④ 特征提取 (以 **MFCC** 为例):
 - FFT $\rightarrow$ 功率谱
 - 梅尔滤波器组 $\rightarrow$ 对数能量

总结：完整的信号处理流水线



- 1 模拟信号 $\xrightarrow{\text{麦克风}}$
- 2 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- 3 预处理:

- 预加重 ($\alpha \approx 0.97$)
- 分帧 (25 ms 帧长, 10 ms 帧移)
- 加窗 (汉明窗)

$\rightarrow$ 加窗后的信号帧序列

- 4 特征提取 (以 **MFCC** 为例):
 - FFT $\rightarrow$ 功率谱
 - 梅尔滤波器组 $\rightarrow$ 对数能量
 - DCT $\rightarrow$ 静态 **MFCC** 特征

总结：完整的信号处理流水线



- 1 模拟信号 $\xrightarrow{\text{麦克风}}$
- 2 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- 3 预处理:

- 预加重 ($\alpha \approx 0.97$)
- 分帧 (25 ms 帧长, 10 ms 帧移)
- 加窗 (汉明窗)

$\rightarrow$ 加窗后的信号帧序列

- 4 特征提取 (以 **MFCC** 为例):
 - FFT $\rightarrow$ 功率谱
 - 梅尔滤波器组 $\rightarrow$ 对数能量
 - DCT $\rightarrow$ 静态 **MFCC** 特征
- 5 动态特征计算:

总结：完整的信号处理流水线



- 1 模拟信号 $\xrightarrow{\text{麦克风}}$
- 2 数字化: 采样 (16 kHz) & 量化 (16-bit) $\rightarrow$ 数字波形
- 3 预处理:

- 预加重 ($\alpha \approx 0.97$)
- 分帧 (25 ms 帧长, 10 ms 帧移)
- 加窗 (汉明窗)

$\rightarrow$ 加窗后的信号帧序列

- 4 特征提取 (以 **MFCC** 为例):

- FFT $\rightarrow$ 功率谱
- 梅尔滤波器组 $\rightarrow$ 对数能量
- DCT $\rightarrow$ 静态 **MFCC** 特征

- 5 动态特征计算:

- 差分 $\rightarrow$ **Delta, Delta-Delta** 特征

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为了一个低维、信息密集、相对鲁棒的特征向量序列。

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为一个低维、信息密集、相对鲁棒的特征向量序列。

信号处理 $\implies$ 特征 $\implies$ 机器学习模型

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为了一个低维、信息密集、相对鲁棒的特征向量序列。

信号处理 $\implies$ 特征 $\implies$ 机器学习模型

下一步是什么？

这些特征向量将作为输入，送入各种强大的机器学习模型中进行声学建模，例如：

- 传统模型：GMM，HMM（高斯混合模型，隐马尔可夫模型）

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为了一个低维、信息密集、相对鲁棒的特征向量序列。

信号处理 $\implies$ 特征 $\implies$ 机器学习模型

下一步是什么？

这些特征向量将作为输入，送入各种强大的机器学习模型中进行声学建模，例如：

- 传统模型：GMM，HMM（高斯混合模型，隐马尔可夫模型）
- 深度学习模型：

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为了一个低维、信息密集、相对鲁棒的特征向量序列。

信号处理 $\implies$ 特征 $\implies$ 机器学习模型

下一步是什么？

这些特征向量将作为输入，送入各种强大的机器学习模型中进行声学建模，例如：

- 传统模型：GMM，HMM（高斯混合模型，隐马尔可夫模型）
- 深度学习模型：
 - DNN, CNN, RNN/LSTM, Transformer...

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为了一个低维、信息密集、相对鲁棒的特征向量序列。

信号处理 $\implies$ 特征 $\implies$ 机器学习模型

下一步是什么？

这些特征向量将作为输入，送入各种强大的机器学习模型中进行声学建模，例如：

- 传统模型：GMM，HMM（高斯混合模型，隐马尔可夫模型）
- 深度学习模型：
 - DNN, CNN, RNN/LSTM, Transformer...

我们得到了什么？

我们成功地将一维、冗长、复杂的原始声波，转化为了一个低维、信息密集、相对鲁棒的特征向量序列。

信号处理 $\implies$ 特征 $\implies$ 机器学习模型

下一步是什么？

这些特征向量将作为输入，送入各种强大的机器学习模型中进行声学建模，例如：

- 传统模型：GMM，HMM（高斯混合模型，隐马尔可夫模型）
- 深度学习模型：
 - DNN, CNN, RNN/LSTM, Transformer...

这些模型将学习从特征到音素（或其他声学单元）的映射关系，从而实现各种任务。

思考：端到端系统的崛起

从手工特征到表征学习的范式迁移



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 深度学习把“特征提取器”与“任务头”合并到一个可微模型中：原始波形 → 多层时频卷积/注意力 → 任务。

思考：端到端系统的崛起

从手工特征到表征学习的范式迁移



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 深度学习把“特征提取器”与“任务头”合并到一个可微模型中：原始波形 → 多层时频卷积/注意力 → 任务。
- 自监督表征在低标注/跨任务迁移上展现压倒性优势。

思考：端到端系统的崛起

从手工特征到表征学习的范式迁移



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 深度学习把“特征提取器”与“任务头”合并到一个可微模型中：原始波形 → 多层时频卷积/注意力 → 任务。
- 自监督表征在低标注/跨任务迁移上展现压倒性优势。
- 但“特征工程”并未消失，而是上移为归纳偏置：窗口化、卷积核、频带分解、数据增强、目标函数、架构形态本身就是“可学习的特征框架”。

思考：端到端系统的崛起

从手工特征到表征学习的范式迁移



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 深度学习把“特征提取器”与“任务头”合并到一个可微模型中：原始波形 → 多层时频卷积/注意力 → 任务。
- 自监督表征在低标注/跨任务迁移上展现压倒性优势。
- 但“特征工程”并未消失，而是上移为归纳偏置：窗口化、卷积核、频带分解、数据增强、目标函数、架构形态本身就是“可学习的特征框架”。
- 经验律：数据越大、任务越复杂、部署资源越充分，端到端收益越明显；数据/算力受限时，合适的先验（如 Mel/STFT）可显著提升样本效率与鲁棒性。

Raw waveform vs. 频域先验

样本效率、鲁棒性、可解释性三角权衡



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 样本效率：在小数据场景，显式 STFT/Mel 引入强先验（短时平稳、感知频带）能减少假设空间，训练更稳；Raw 端到端易过拟合，需要强正则与数据扩增。

Raw waveform vs. 频域先验

样本效率、鲁棒性、可解释性三角权衡



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 样本效率：在小数据场景，显式 STFT/Mel 引入强先验（短时平稳、感知频带）能减少假设空间，训练更稳；Raw 端到端易过拟合，需要强正则与数据扩增。
- 噪声鲁棒：频域滤波/子带建模易注入频率不变性与带噪可分性；Raw 端到端可学到更细粒度时域线索，但需更大数据来覆盖多种噪声/说话人/通道域。

Raw waveform vs. 频域先验

样本效率、鲁棒性、可解释性三角权衡



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 样本效率：在小数据场景，显式 STFT/Mel 引入强先验（短时平稳、感知频带）能减少假设空间，训练更稳；Raw 端到端易过拟合，需要强正则与数据扩增。
- 噪声鲁棒：频域滤波/子带建模易注入频率不变性与带噪可分性；Raw 端到端可学到更细粒度时域线索，但需更大数据来覆盖多种噪声/说话人/通道域。
- 可解释性与可控性：显式谱图利于可视化、调参与诊断（泄漏、过平滑、带限）；Raw 输入强但“黑箱化”，调优靠大规模验证与可解释工具（CAM、频带敏感度分析）。

Raw waveform vs. 频域先验

样本效率、鲁棒性、可解释性三角权衡



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 样本效率：在小数据场景，显式 STFT/Mel 引入强先验（短时平稳、感知频带）能减少假设空间，训练更稳；Raw 端到端易过拟合，需要强正则与数据扩增。
- 噪声鲁棒：频域滤波/子带建模易注入频率不变性与带噪可分性；Raw 端到端可学到更细粒度时域线索，但需更大数据来覆盖多种噪声/说话人/通道域。
- 可解释性与可控性：显式谱图利于可视化、调参与诊断（泄漏、过平滑、带限）；Raw 输入强但“黑箱化”，调优靠大规模验证与可解释工具（CAM、频带敏感度分析）。
- 推理代价：端到端可省显式特征计算（或以可学习前端替代），但整体模型更大；在边缘设备上，轻量显式特征+小模型仍具工程优势。

可学习前端：连接传统先验与端到端

从固定 STFT/Mel 到可训练滤波器组



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 可学习滤波器组：用参数化卷积核初始化为 **Gammatone/Mel** 滤波器，再端到端微调，兼得先验与适应性。

可学习前端：连接传统先验与端到端

从固定 STFT/Mel 到可训练滤波器组



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 可学习滤波器组：用参数化卷积核初始化为 **Gammatone/Mel** 滤波器，再端到端微调，兼得先验与适应性。
- 可学习 STFT：把 STFT 看作固定线性投影（余弦/正弦字典）；将其推广为可训练字典或多分辨率字典（多窗长、多采样 hop），提升时频自适应。

可学习前端：连接传统先验与端到端

从固定 STFT/Mel 到可训练滤波器组



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 可学习滤波器组：用参数化卷积核初始化为 **Gammatone/Mel** 滤波器，再端到端微调，兼得先验与适应性。
- 可学习 STFT：把 STFT 看作固定线性投影（余弦/正弦字典）；将其推广为可训练字典或多分辨率字典（多窗长、多采样 hop），提升时频自适应。
- 复数域/相位感知：显式在复数 STFT 上建模幅度与相位，或学习相位敏感前端（在增强与分离中提升清晰度与可重建性）。

可学习前端：连接传统先验与端到端

从固定 STFT/Mel 到可训练滤波器组



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 可学习滤波器组：用参数化卷积核初始化为 **Gammatone/Mel** 滤波器，再端到端微调，兼得先验与适应性。
- 可学习 STFT：把 STFT 看作固定线性投影（余弦/正弦字典）；将其推广为可训练字典或多分辨率字典（多窗长、多采样 hop），提升时频自适应。
- 复数域/相位感知：显式在复数 STFT 上建模幅度与相位，或学习相位敏感前端（在增强与分离中提升清晰度与可重建性）。
- 子带建模：把宽带任务拆成并行子带（变换域或可学习滤组），降低建模难度与计算，常见于高保真 TTS/音频生成。

自监督与大模型时代：特征的“新角色”

从输入表示到训练目标与数据配方



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 表征的关键不止“输入长什么样”，更在于训练目标：对比学习、遮挡预测、跨模态对齐（语音-文本-说话人-情感）在很大程度决定“特征质量”。

自监督与大模型时代：特征的“新角色”

从输入表示到训练目标与数据配方



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 表征的关键不止“输入长什么样”，更在于训练目标：对比学习、遮挡预测、跨模态对齐（语音-文本-说话人-情感）在很大程度决定“特征质量”。
- 数据配方即强归纳偏置：多域混合（远讲/近讲、房间/户外）、语言/口音多样性、设备多样性，是鲁棒表征的核心“特征工程”。

自监督与大模型时代：特征的“新角色”

从输入表示到训练目标与数据配方



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 表征的关键不止“输入长什么样”，更在于训练目标：对比学习、遮挡预测、跨模态对齐（语音-文本-说话人-情感）在很大程度决定“特征质量”。
- 数据配方即强归纳偏置：多域混合（远讲/近讲、房间/户外）、语言/口音多样性、设备多样性，是鲁棒表征的核心“特征工程”。
- 适配与蒸馏：用大模型作“教师”，小模型蒸馏到轻量前端；或把自监督特征冻住作为可迁移输入，任务头轻量化微调，快速适配下游场景。

自监督与大模型时代：特征的“新角色”

从输入表示到训练目标与数据配方



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 表征的关键不止“输入长什么样”，更在于训练目标：对比学习、遮挡预测、跨模态对齐（语音-文本-说话人-情感）在很大程度决定“特征质量”。
- 数据配方即强归纳偏置：多域混合（远讲/近讲、房间/户外）、语言/口音多样性、设备多样性，是鲁棒表征的核心“特征工程”。
- 适配与蒸馏：用大模型作“教师”，小模型蒸馏到轻量前端；或把自监督特征冻住作为可迁移输入，任务头轻量化微调，快速适配下游场景。
- 多任务与指令化：ASR/说话人/语种/情感联合训练或指令式建模，让同一表征服务多个任务——“通用音频 backbone”成为新特征工程。

洞见：为何短时思想仍然长期有效？

不确定性原理、发声机理与多尺度表示



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 不确定性权衡：时间-频率分辨率的物理极限并未因深度学习消失；模型可以学到多尺度，但窗口化/多尺度栈仍是稳定高效的实现方式。

洞见：为何短时思想仍然长期有效？

不确定性原理、发声机理与多尺度表示



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 不确定性权衡：时间-频率分辨率的物理极限并未因深度学习消失；模型可以学到多尺度，但窗口化/多尺度栈仍是稳定高效的实现方式。
- 发声机理先验：声门脉冲列 + 声道共振是局部平稳的，短时谱天然对共振峰/谐波结构友好；端到端常隐式学到“近似 STFT”的第一层卷积核。

洞见：为何短时思想仍然长期有效？

不确定性原理、发声机理与多尺度表示



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 不确定性权衡：时间-频率分辨率的物理极限并未因深度学习消失；模型可以学到多尺度，但窗口化/多尺度栈仍是稳定高效的实现方式。
- 发声机理先验：声门脉冲列 + 声道共振是局部平稳的，短时谱天然对共振峰/谐波结构友好；端到端常隐式学到“近似 STFT”的第一层卷积核。
- 任务对齐：音素/子词级标签与短时窗匹配良好，便于强监督/CTC 对齐；完全时域端到端在对齐上往往需要更强的注意力与正则。

洞见：为何短时思想仍然长期有效？

不确定性原理、发声机理与多尺度表示



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 不确定性权衡：时间-频率分辨率的物理极限并未因深度学习消失；模型可以学到多尺度，但窗口化/多尺度栈仍是稳定高效的实现方式。
- 发声机理先验：声门脉冲列 + 声道共振是局部平稳的，短时谱天然对共振峰/谐波结构友好；端到端常隐式学到“近似 STFT”的第一层卷积核。
- 任务对齐：音素/子词级标签与短时窗匹配良好，便于强监督/CTC 对齐；完全时域端到端在对齐上往往需要更强的注意力与正则。
- 可逆与可控：STFT/iSTFT 保证能量守恒与可逆重建，是生成/增强/编辑的工业硬基座；可学习前端可在其上叠加，而非完全替代。

工程建议：如何在项目中做取舍？

三步决策树



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

1 资源与数据量评估：

工程建议：如何在项目中做取舍？

三步决策树



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。

工程建议：如何在项目中做取舍？

三步决策树



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。
- 大数据/服务器端：端到端原始波形或可学习前端 + 自监督预训练，再微调。

工程建议：如何在项目中做取舍？

三步决策树



① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。
- 大数据/服务器端：端到端原始波形或可学习前端 + 自监督预训练，再微调。

② 目标与可解释性需求：

工程建议：如何在项目中做取舍？

三步决策树



① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。
- 大数据/服务器端：端到端原始波形或可学习前端 + 自监督预训练，再微调。

② 目标与可解释性需求：

- 可控生成/音质可诊断（TTS/后期）：保留频域可视化与可逆流程（iSTFT），必要时复数域建模。

工程建议：如何在项目中做取舍？

三步决策树



① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。
- 大数据/服务器端：端到端原始波形或可学习前端 + 自监督预训练，再微调。

② 目标与可解释性需求：

- 可控生成/音质可诊断（TTS/后期）：保留频域可视化与可逆流程（iSTFT），必要时复数域建模。
- 纯识别/检索：可直接用大表征（SSL）嵌入，冻结或小步微调下游头。

工程建议：如何在项目中做取舍？

三步决策树



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。
- 大数据/服务器端：端到端原始波形或可学习前端 + 自监督预训练，再微调。

② 目标与可解释性需求：

- 可控生成/音质可诊断（TTS/后期）：保留频域可视化与可逆流程（iSTFT），必要时复数域建模。
- 纯识别/检索：可直接用大表征（SSL）嵌入，冻结或小步微调下游头。

③ 泛化与鲁棒：

工程建议：如何在项目中做取舍？

三步决策树



① 资源与数据量评估：

- 小数据/边缘设备/强实时：优先 STFT/Mel + 轻量模型（Conformer-lite/TCN）；善用数据增强（混响、噪声、SpecAugment）。
- 大数据/服务器端：端到端原始波形或可学习前端 + 自监督预训练，再微调。

② 目标与可解释性需求：

- 可控生成/音质可诊断（TTS/后期）：保留频域可视化与可逆流程（iSTFT），必要时复数域建模。
- 纯识别/检索：可直接用大表征（SSL）嵌入，冻结或小步微调下游头。

③ 泛化与鲁棒：

- 跨域部署，优先多域自监督 + 多任务正则；保持前端多尺度或子带并行以缓解分布偏移。

小结：特征设计没有消失，它进化了

从手工参数到可学习先验



南京大学
NANJING UNIVERSITY



智能科学与技术学院
School of Intelligence Science and Technology

- 端到端不是“不要特征”，而是把特征变成可训练的前端与目标函数。
- STFT/短时思想仍是稳定、高效、可逆的工程支点；可学习滤组与多尺度建模把它升级为数据驱动的版本。
- 真正的“特征工程 2.0”：数据配方、自监督任务、架构归纳偏置、鲁棒性增强与蒸馏/适配。

- MFCC 教程
- 傅里叶变换“掐死”教程（着重看图示）