ESP32

ESP-SR 用户手册

Release master
乐鑫信息科技
2024 年 05 月 14 日

Table of contents

本文档仅包含针对 ESP32 芯片的 ESP-SR 使用。

Chapter 1

入门指南

乐鑫 ESP-SR 可以帮助用户基于 ESP32 系列芯片或 ESP32-S3 系列芯片，搭建 AI 语音解决方案。本文档将通过一些简单的示例，展示如何使用 ESP-SR 中的算法和模型。

1.1 概述

ESP-SR 支持以下模块：

- *声学前端算法 AFE*
- *唤醒词检测 WakeNet*
- *命令词识别 MultiNet*
- *语音合成（目前只支持中文）*

1.2 准备工作

1.2.1 必备硬件

- 一款音频开发版，推荐使用 ESP32-Korvo
- USB 2.0 数据线（标准 A 型转 Micro-B 型）
- 电脑（Linux）

备注： 目前一些开发板使用的是 USB Type C 接口。请确保使用合适的数据线连接开发板！

1.2.2 必备软件

- 下载 ESP-SKAINET，ESP-SR 将作为 ESP-SKAINET 的组件被一起下载。
- 配置安装 ESP-IDF，推荐使用 ESP-SKAINET 中包含的版本。安装方法请参考 ESP-IDF 编程指南 中的 快速入门 小节。

1.3 编译运行一个示例

- 进入 ESP-SKAINET/examples/cn_speech_commands_recognition 目录。
- 参考该示例目录下的配置和编译说明，运行该示例。

- 该示例为中文命令指令识别示例，通过说唤醒词（Hi, 乐鑫），触发语音指令识别。注意，当一段时间没有语音指令后，语音指令识别功能将关闭，并等待下一次唤醒词触发。

Chapter 2

AFE 声学前端

2.1 AFE 声学前端算法框架

2.1.1 概述

智能语音设备需要在远场噪声环境中，仍具备出色的语音交互性能，声学前端 (Audio Front-End, AFE) 算法在构建此类语音用户界面 (Voice-User Interface, VUI) 时至关重要。乐鑫 AI 实验室自主研发了一套乐鑫 AFE 算法框架，可基于功能强大的 ESP32 系列芯片进行声学前端处理，使用户获得高质量且稳定的音频数据，从而构建性能卓越且高性价比的智能语音产品。

名称	简介
AEC (Acoustic Echo Cancellation)	回声消除算法，最多支持双麦处理，能够有效的去除 mic 输入信号中的自身播放声音，从而可以在自身播放音乐的情况下很好的完成语音识别。
NS (Noise Suppression)	噪声抑制算法，支持单通道处理，能够对单通道音频中的非人声噪声进行抑制，尤其针对稳态噪声，具有很好的抑制效果。
BSS (Blind Source Separation)	盲信号分离算法，支持双通道处理，能够很好的将目标声源和其余干扰音进行盲源分离，从而提取出有用音频信号，保证了后级语音的质量。
MISO (Multi Input Single Output)	多输入单输出算法，支持双通道输入，单通道输出。用于在双麦场景，没有唤醒使能的情况下，选择信噪比高的一路音频输出。
VAD (Voice Activity Detection)	语音活动检测算法，支持实时输出当前帧的语音活动状态。
AGC (Automatic Gain Control)	自动增益控制算法，可以动态调整输出音频的幅值，当弱信号输入时，放大输出幅度；当输入信号达到一定强度时，压缩输出幅度。
WakeNet	基于神经网络的唤醒词模型，专为低功耗嵌入式 MCU 设计

2.1.2 使用场景

本节将介绍乐鑫 AFE 框架的两个典型使用场景。

语音识别场景

工作流程

数据流

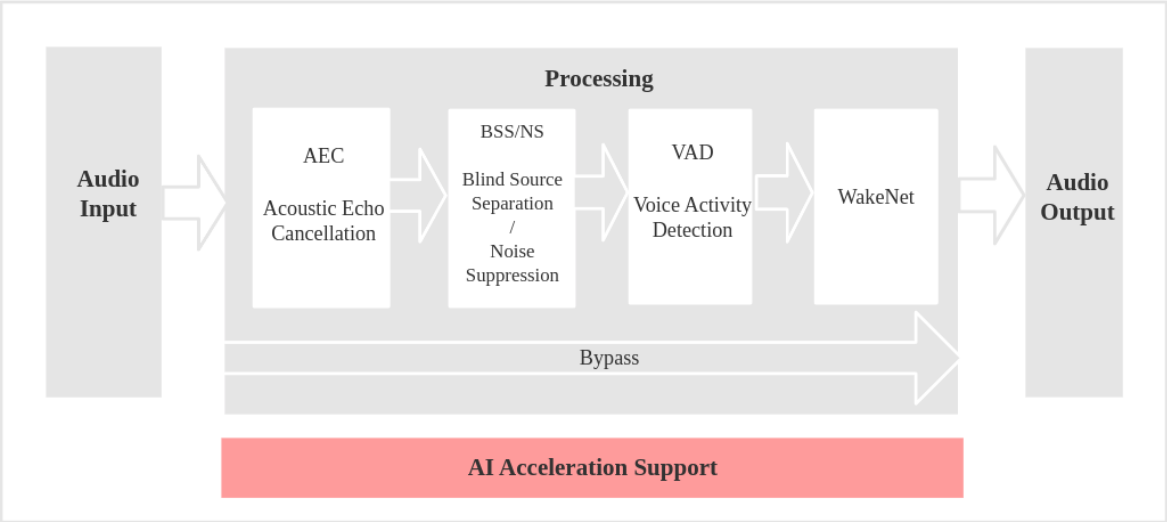
Audio Input
Processing
AEC
Acoustic Echo Cancellation
BSS/NS
Blind Source Separation / Noise Suppression
VAD
Voice Activity Detection
WakeNet
Audio Output
Bypass
AI Acceleration Support

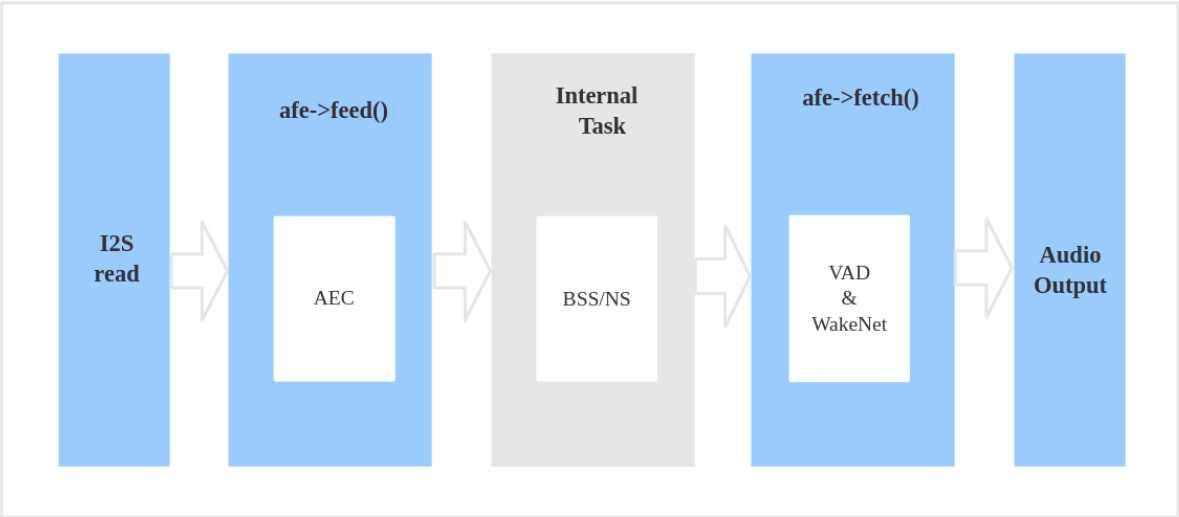
I2S read
afe->feed()
AEC
Internal Task
BSS/NS
afe->fetch()
VAD & WakeNet
Audio Output

1. 使用 `ESP_AFE_SR_HANDLE()`，创建并初始化 AFE。注意，`voice_communication_init` 需配置为 false。
2. 使用 `feed()`，输入音频数据。feed 内部会先进行 AEC 算法处理
3. Feed 内部进行 BSS/NS 算法处理
4. 使用 `fetch()`，获得经过处理过的单通道音频数据及相关信息。这里，fetch 内部可以进行 VAD 处理并检测唤醒词等动作，具体可通过 `afe_config_t` 结构体配置。

语音通话场景

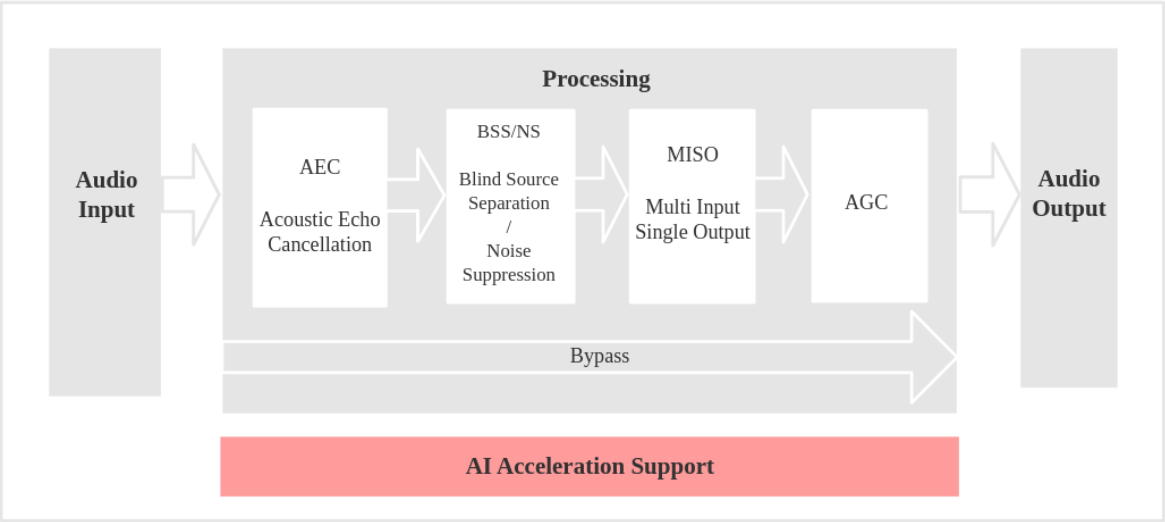

工作流程

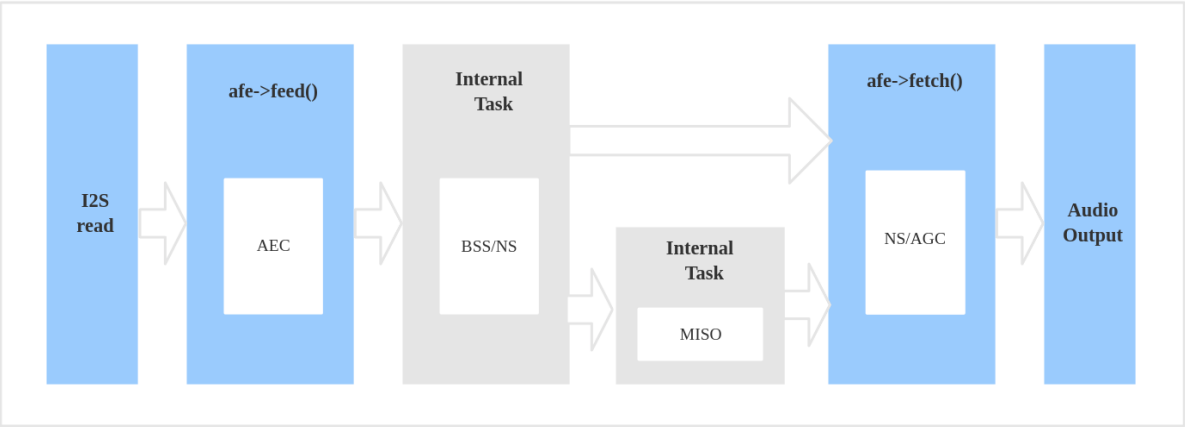

数据流

1. 使用 `ESP_AFE_VC_HANDLE()`，创建并初始化 AFE。注意，`voice_communication_init` 需配置为 true。
2. 使用 `feed()`，输入音频数据。feed 内部会先进行 AEC 算法处理
3. Feed 内部进行 BSS/NS 算法处理。若为双麦，还将额外进行 MISO 算法处理。
4. 使用 `fetch()`，获得经过处理过的单通道音频数据及相关信息。这里，可对输出数据进行 AGC 非线性放大，具体增益值可通过 `afe_config_t` 结构体配置。注意，若为双麦，则在进行 AGC 非线性放大前还会进行降噪处理。

备注:

1. afe_config_t 结构体中的 wakenet_init 和 voice_communication_init 不可同时配置为 true。
2. feed() 和 fetch() 对用户可见，其他内部 BSS/NS/MISO 算法处理为 AFE 的内部独立任务，对用户不可见。
3. AEC 算法处理在 feed() 中进行。
4. 当 aec_init 配置为 false，BSS/NS 算法处理在 feed() 中进行。

2.1.3 选择 AFE Handle

目前，乐鑫 AFE 框架支持单麦和双麦配置，并允许对算法模块进行灵活配置。

- **单麦配置：**
  - 内部 Task 由 NS 算法模块处理
- **双麦配置：**
  - 内部 Task 由 BSS 算法模块处理
  - 此外，如用于语音通话场景（即 wakenet_init = false 且 voice_communication_init = true），则会再增加一个内部 Task 由 MISO 处理。

获取 AFE handle 的命令如下：

- 语音识别场景

```
esp_afe_sr_iface_t *afe_handle = &ESP_AFE_SR_HANDLE;
```

- 语音通话场景

```
esp_afe_sr_iface_t *afe_handle = &ESP_AFE_VC_HANDLE;
```

2.1.4 输入音频

目前，乐鑫 AFE 框架支持单麦和双麦配置，可根据 esp_afe_sr_iface_op_feed_t() 的输入音频情况，配置所需的音频通道数。

具体方式为：配置 AFE_CONFIG_DEFAULT() 中的 pcm_config 结构体成员：

- total_ch_num：总通道数
- mic_num：麦克风通道数
- ref_num：参考回路通道数

注意，在配置时有如下要求：

1. total_ch_num = mic_num + ref_num
2. ref_num = 0 或 ref_num = 1 （由于目前 AEC 仅只支持单回路）

在上述要求下，几种支持的配置组合如下：

```
total_ch_num=1, mic_num=1, ref_num=0
total_ch_num=2, mic_num=1, ref_num=1
total_ch_num=2, mic_num=2, ref_num=0
total_ch_num=3, mic_num=2, ref_num=1
```

AFE 单麦配置

- 输入音频的 **格式**为 16 KHz、16 bit、双通道（其中 1 个通道为 mic 数据，另 1 个通道为参考回路）。注意，若不需要 AEC 功能，则可只包含 1 个通道输入 mic 数据，而无需配置参考回路（即可配置 ref_num = 0）。
- 根据用户配置的算法模块不同，输入音频的 **帧长** 将有所差异，具体可通过 get_feed_chunksize() 来获取需要的采样点数目（采样点数据类型为 int16）。

数据排布示意如下：

AFE 双麦配置

- 输入音频格式为 16 KHz、16 bit、三通道（其中 2 个通道为 mic 数据，另 1 个通道为参考回路）。注意，若不需要 AEC 功能，则可只包含 2 个通道 mic 数据，而无需配置参考回路（即可配置 `ref_num` = 0）。
- 根据用户配置的算法模块不同，输入音频的 **帧长** 将有所差异，具体可通过 `get_feed_chunksize()` 来获取需要填充的数据量（即 `get_feed_chunksize()` * `total_ch_num` * sizeof(short)）。

数据排布示意如下：

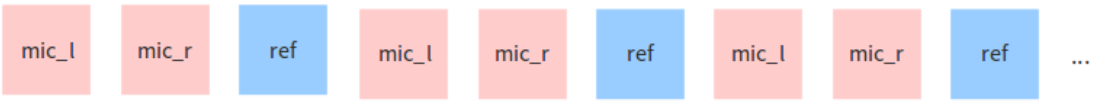

2.1.5 输出音频

AFE 的输出音频为单通道数据：

- 语音识别场景：在 WakeNet 开启的情况下，输出有目标人声的单通道数据
- 语音通话场景：输出信噪比更高的单通道数据

2.1.6 使能唤醒词识别 WakeNet

在进行 AFE 声学前端处理时，用户可选择是否使能 *WakeNet* 进行唤醒词识别。

当用户在唤醒后需要进行其他操作，比如离线或在线语音识别，这时候可以暂停 WakeNet 的运行，从而减轻 CPU 的资源消耗。此时，仅需调用 `disable_wakenet()`，进入 Bypass 模式。

当后续应用结束后又可以调用 `enable_wakenet()` 再次使能 WakeNet。

ESP32 芯片只支持一个唤醒词，不支持唤醒词切换。

2.1.7 使能回声消除算法 AEC

AEC 的使用和 WakeNet 相似，用户可以根据自己的需求来停止或开启 AEC。

- 停止 AEC
  ```
  afe->disable_aec(afe_data);
  ```
- 开启 AEC
  ```
  afe->enable_aec(afe_data);
  ```

2.1.8 资源消耗

有关本模型的资源消耗情况，请见资源消耗。

2.2 乐鑫麦克风设计指南

本指南基于乐鑫的 ESP32 系列语音开发板，对于整机 mic 设计做出要求。

2.2.1 麦克风电器性能推荐

- 麦克类型：全向型 MEMS 麦克风
- 灵敏度
  - 1 Pa 声压下模拟麦灵敏度不低于 -38 dBV，数字麦灵敏度要求不低于 -26 dB。
  - 公差控制在 ±2 dB，对于麦克阵列推荐采用 ±1 dB 公差。
- 信噪比 (SNR)
  - 信噪比：信噪比不低于 62 dB，推荐 > 64 dB
  - 频率响应在 50~16 KHz 范围内的波动在 ±3 dB 之内
  - 麦克风的 PSRR 应大于 55 dB

2.2.2 麦克风结构设计建议

- 麦克孔孔径或宽度推荐大于 1 mm，拾音管道尽量短，腔体尽可能小，保证麦克和结构组件配合的谐振频率在 9 KHz 以上。
- 拾音孔深度和直径比小于 2:1，壳体厚度推荐 1 mm，如果壳体过厚，需增大开孔面积。
- 麦克孔上需通过防尘网进行保护。
- 麦克风与设备外壳之间必须加硅胶套或泡棉等进行密封和防震，需进行过盈配合设计，以保证麦克的密封性。
- 麦克孔不能被遮挡，底部拾音的麦克风需结构上增加底部凸起，保证麦克风与桌面等平面有一定间隙。
- 麦克需远离喇叭等会产生噪音或振动的物体摆放，且与喇叭音腔之间通过橡胶垫等隔离缓冲。

2.2.3 麦克阵列设计建议

客户可采用双麦克或三麦克方案：

- 双麦克方案：2 个麦克风之间间距保持 4~6.5 cm，连接 2 个麦克风的轴线应平行于水平线，且 2 个麦克的中心尽量靠近产品水平方向的中心。
- 三麦克方案：3 个麦克风等间距并且成正圆分布（夹F互成 120 度），间距要求 4~6.5 cm。

在选择阵列中的麦克风时，有如下注意事项：

- 麦克类型：全向型硅麦，推荐同一个阵列内的麦克应使用同一厂家的同一型号，不建议混用。
- 灵敏度：麦克阵列中各麦克灵敏度差异在 3 dB 之内。
- 相位差：多麦克阵列中麦克之间的相位差控制在 10° 以内。
- 麦克阵列中各麦克的结构设计，推荐采用相同的设计，以保证结构设计的一致性。

2.2.4 麦克风结构密封性建议

用橡皮泥等材料封堵麦克拾音孔，密封前后麦克风采集信号的幅度衰减 25 dB 为合格，推荐 30 dB。测试方法：

1. 麦克风正上方 0.5 米处，播放白噪声，麦克风处音量 90 dB。
2. 使用麦克风阵列录制 10s 以上，存储为录音文件 A。
3. 用橡皮泥等材料封堵麦克拾音孔，使用麦克风阵列录制 10s 以上，存储为录音文件 B。
4. 对比两个文件的频谱，需保证 100~8 KHz 频段内整体衰减 25dB 以上。

2.2.5 回声参考信号设计建议

- 回声参考信号推荐尽量靠近喇叭侧，推荐从 DA 后级 PA 前级回采。
- 扬声器音量最大时，输入到麦克的回声参考信号不能有饱和失真，最大音量下喇叭功放输出 THD 满足 100 Hz 小于 10%，200 Hz 小于 6%，350 Hz 以上频率，小于 3%。
- 扬声器音量最大时，麦克处拾音的声压不超过 102 dB (1KHz)。
- 回声参考信号电压不超过 ADC 的最大允许输入电压，电压过高需增加衰减电路。
- 从 D 类功放输出引参考回声信号需增加低通滤波器，滤波器的截止频率推荐 > 22 KHz。
- 音量最大播放时，回采信号峰值 -3 到 -5 dB。

2.2.6 麦克风阵列一致性验证

要求各个麦克风采样信号幅度相差小于 3 dB，测试方法：

1. 麦克风正上方 0.5 米处，播放白噪声，麦克风处音量 90 dB。
2. 使用麦克风阵列录制 10s 以上，查看各 mic 录音幅度和音频采样率是否一致。

Chapter 3

唤醒词

3.1 WakeNet 唤醒词模型

WakeNet 是一个基于神经网络，为低功耗嵌入式 MCU 设计的唤醒词模型，目前支持 5 个以内的唤醒词识别。

3.1.1 概述

WakeNet 的流程图如下：

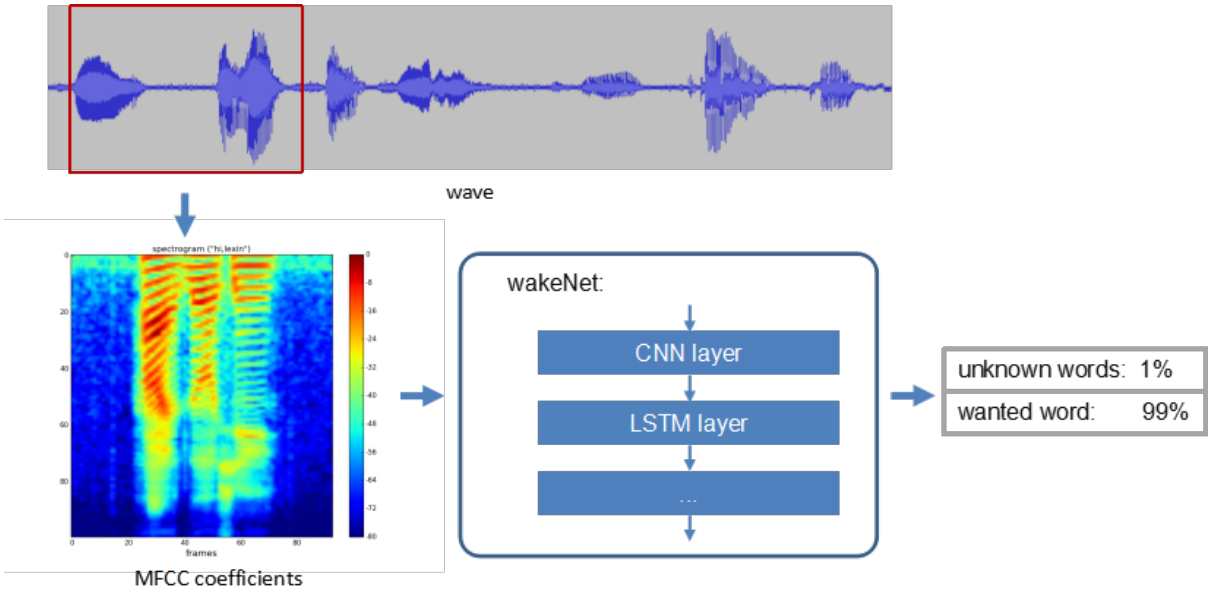

- **语音特征 (Speech Feature)** 我们使用 MFCC 方法提取语音频谱特征。输入的音频文件采样率为 16 KHz，单声道，编码方式为 signed 16-bit。每帧窗宽和步长均为 30 ms。
- **神经网络 (Neural Network)** 神经网络结构已经更新到第 9 版，其中：
  - WakeNet1、WakeNet2、WakeNet3、WakeNet4、WakeNet6 and WakeNet7 已经停止使用。
  - WakeNet5 应用于 ESP32 芯片。
  - WakeNet8 和 WakeNet9 应用于 ESP32-S3 芯片，模型基于 Dilated Convolution 结构。

注意，WakeNet5、WakeNet5X2 和 WakeNet5X3 的网络结构一致，但是 WakeNet5X2 和 WakeNet5X3 的参数比 WakeNet5 要多。请参考资源消耗 来获取更多细节。

- **Keyword Trigger Method** 对连续的音频流，为准确判断关键词的触发，我们通过计算若干帧内识别结果的平均值 M，来判断是否触发。当 M 大于指定阈值，则发出触发的命令。

以下表格展示在不同芯片上的模型支持：

Chip	ESP32			ESP32S3			
model	WakeNet 5			WakeNet 8		WakeNet 9	
	WakeNet 5	WakeNet 5X2	WakeNet 5X3	Q16	Q8	Q16	Q8
Hi,Lexin	√	√	√				√
nihaoxiaozhi	√		√				√
nihaoxiaoxin			√				
xiaoaitongxue							√
Alexa				√			√
Hi,ESP							√
Customized word							√

3.1.2 WakeNet 的使用

- WakeNet 模型选择
  WakeNet 模型选择请参考*flash model 介绍* 。
  自定义的唤醒词，请参考*乐鑫语音唤醒词定制流程* 。
- WakeNet 模型运行
  WakeNet 目前包含在语音前端算法*AFE* 中，默认为运行状态，并将识别结果通过 AFE fetch 接口返回。
  如果用户无需使用 WakeNet 唤醒，请在 AFE 配置时选择：

```
afe_config.wakenet_init = False.
```

  如果用户想临时关闭/打开 WakeNet, 请在运行过程中调用：

```
afe_handle->disable_wakenet(afe_data)
afe_handle->enable_wakenet(afe_data)
```

3.1.3 资源消耗

有关本模型的资源消耗情况，请见资源消耗。

3.2 乐鑫语音唤醒方案客户定制流程

3.2.1 唤醒词定制服务

乐鑫提供 **语音唤醒词定制**服务，详情如下：

1. “HI 乐鑫”，“你好小鑫”等官方开放的唤醒词，客户可直接商用
   - 完整列表可见乐鑫免费商用唤醒词
   - 同时，乐鑫会逐渐开放更多可免费商用的唤醒词
2. 除官方开放的唤醒词，乐鑫还可为客户提供 **唤醒词定制服务**，主要分如下两种情况：
   - 客户提供唤醒词语料
     - 需要提供大于 2 万条合格的语料，具体语料需求见训练语料要求
     - 语料提供给乐鑫后，需要 2 ~ 3 周进行模型训练及调优
     - 根据量级收取少量模型定制费用
   - 如果客户不提供唤醒词语料
     - 所有训练语料由乐鑫采集提供
     - 乐鑫需要一定时间收集语料，具体需要分别讨论；语料准备好后，需要 2 ~ 3 周进行模型训练及调优
     - 根据量级收取少量模型定制费用，语料采集费用另算
   - 定制的具体时间和费用取决于 **唤醒词定制的数量**以及 **产品量产数量**，详情请联系 乐鑫销售人员 。
3. 对于乐鑫唤醒词模型：
   - 目前单个模型最多支持 5 个及以内的唤醒词识别
   - 每个唤醒词通常由 3-6 音节组成，比如 “hi 乐鑫”，“Alexa”，“小爱同学”，“你好天猫” 等
   - 可多个唤醒模型一起使用，具体需根据客户应用的资源消耗确定
   - 更多详情，请见 *WakeNet* 唤醒词模型

训练语料要求

客户可自备训练语料或向第三方采购，对于语料有以下要求：

- 语料音频格式要求
  - 采样率（sample rate）：16 KHz
  - 编码（encoding）：16-bit signed int
  - 通道数（channel）：mono
  - 格式：wav
- 语料采集要求
  - 采样人数：最好样本可以大于 500 人，其中男女，年龄分布均衡，儿童不小于 100 人
  - 采样环境：环境噪声低（< 40 dB），建议在语音室等专业环境下录制
  - 录制设备：高保真麦克风
  - **录制场景：**
    - 距离麦克风 1 m 处每人录制 15 遍，其中 5 遍快语速，5 遍正常语速，5 遍慢语速；
    - 距离麦克风 3 m 处每人录制 15 遍，其中 5 遍快语速，5 遍正常语速，5 遍慢语速
  - 样本命名需体现样本信息：如 `female_age_fast_id.wav` 或有单独表格记录每个样本的年龄，性别等信息

3.2.2 硬件设计与测试服务

语音唤醒效果与硬件设计以及腔体结构有很大关系。因此，请认真阅读以下内容：

1. 硬件设计要求
   - 各类语音音箱类设计：乐鑫可提供 **原理图** / **PCB** 等设计参考，客户可以根据自身具体需求设计修改，设计完毕后，乐鑫还可提供审阅服务，避免常见设计问题。
   - 腔体结构：建议有专门的声学人员参与设计，乐鑫不提供 ID 设计类参考，客户可参考市面上的主流音箱腔体设计，例如天猫精灵、小度音箱、谷歌音箱等。
2. 硬件设计好后，客户可通过以下简单测试，验证硬件设计效果（下列测试都是基于语音室环境，客户可以根据自身测试环境做调整）
   - 录音测试，验证 mic、codec 录音增益以及失真情况
     - 音源 90 dB，距离 0.1 m 播放样本，调节增益，保证录音样本不饱和
     - 使用扫频文件 (0~20 KHz)，使用 16 KHz 采样率录音，音频不会出现明显频率混叠
     - 录制 100 个语音样本，使用公开的云端语音识别端口识别，识别率达到指定标准
   - 播音测试，验证功率放大器 (PA)、喇叭的失真情况
     - 测试 PA 功率 @1% 总谐波失真 (THD)
   - 语音算法测试，验证 AEC、BFM、NS 效果
     - 首先需要注意下参考信号延时，不同的 AEC 算法有不同的要求
     - 以实际产品场景为测试指标，例如 mic 播放 `85DB-90DB 大梦想家.wav`，设备回采
     - 保存回声参考信号、回声消除后的信号分析，对比查看 AEC、BFM、NS 等效果
   - DSP 性能测试，验证 DSP 参数是否合适，同时尽可能减少 DSP 算法中的非线性失真
     - 降噪 (Noise Suppression) 算法性能测试
     - 回声消除 (Acoustic Echo Cancellation) 算法性能测试
     - 语音增强 (Speech Enhancement) 算法性能测试
3. 硬件设计完毕后，**可寄送** 1-2 台硬件至乐鑫，乐鑫会基于客户整机做唤醒词性能调优。

Chapter 4

命令词

4.1 MultiNet 命令词识别模型

MultiNet 是为了在 ESP32 系列上离线实现多命令词识别而设计的轻量化模型，目前支持 200 个以内的自定义命令词识别。

- 支持中文命令词识别
- 支持用户自定义命令词
- 支持运行过程中增加/删除/修改命令词语
- 最多支持 200 个命令词
- 支持单次识别和连续识别两种模式
- 轻量化，低资源消耗
- 低延时，延时 500 ms 内
- 模型单独分区，支持用户应用 OTA

MultiNet 输入为经过前端语音算法（AFE）处理过的音频（格式为 16 KHz，16 bit，单声道）。通过对音频进行识别，则可以对应到相应的汉字或单词。

请参考*Models Benchmark* 去查看当前不同芯片支持的模型。

用户选择不同的模型的方法请参考模型加载 。

备注： 其中以 `Q8` 结尾的模型代表模型的 8 bit 版本，表明该模型更加轻量化。

4.2 命令词识别原理

命令词识别原理如下图所示：

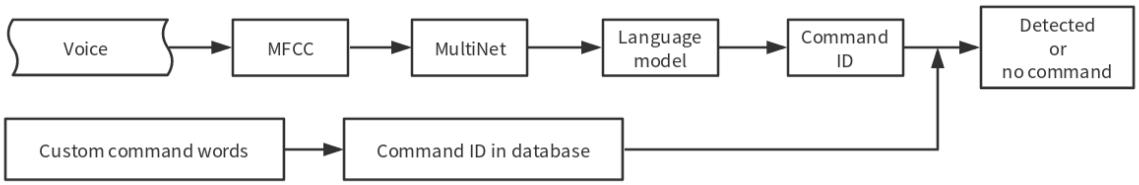

图 1: speech_command-recognition-system

4.3 命令词格式要求

不同版本的 MultiNet 命令词格式不同。命令词需要满足特定的格式，具体如下：

4.4 自定义命令词方法

备注： 不支持中英文混合

不能含有阿拉伯数字和特殊字符

英语自定义命令词方法请参考英文文档

MultiNet 支持多种且灵活的命令词设置方式，可通过在线或离线方法设置命令词，还允许随时动态增加/删除/修改命令词。

MultiNet5 和 MultiNet6 使用汉语拼音作为基本识别单元。比如 "打开空调"，应该写成 "da kai kong tiao"，请使用以下工具将汉字转为拼音：tool/multinet_pinyin.py 。

4.4.1 MultiNet6 定义方法：

- 中文通过修改 model/multinet_model/fst/commands_cn.txt
  格式如下，第一个数字代表 command id, 后面为指令的中文拼音，两者由空格隔开，拼音间也由空格隔开，Command id 不能为 0

```
# command_id command_sentence
1 da kai kong tiao
2 guan bi kong tiao
```

4.4.2 MultiNet5 定义方法：

- 通过 `menuconfig`
  1. `idf.py menuconfig` > `ESP Speech Recognition` > `Add Chinese speech commands/Add English speech commands`，添加命令词。具体也可参考 ESP-Skainet 中的 example。

  注意，单个 Command ID 可以支持多个短语，比如 "打开空调" 和 "开空调" 表示的意义相同，则可以将其写在同一个 Command ID 对应的词条中，用英文字符 "," 隔开相邻词条（"," 前后无需空格）。

  2. 在代码里调用以下 API：

```
/**
* @brief Update the speech commands of MultiNet by menuconfig
*
* @param multinet            The multinet handle
*
* @param model_data          The model object to query
*
* @param langugae            The language of MultiNet
*
* @return
*     - ESP_OK                  Success
*     - ESP_ERR_INVALID_STATE   Fail
*/
esp_err_t esp_mn_commands_update_from_sdkconfig(esp_mn_iface_t␣
↪*multinet, const model_iface_data_t *model_data);
```

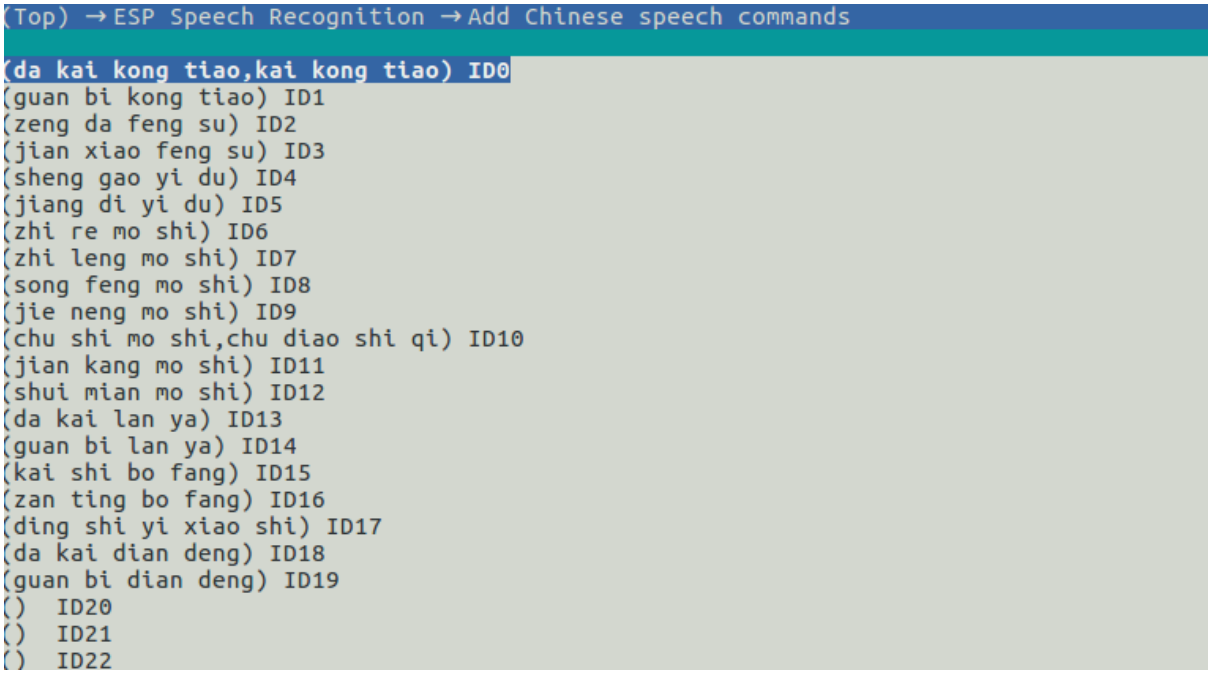

图 2: menuconfig_add_speech_commands

4.4.3 通过调用 API 修改

指令还可以通过调用 API 修改，这种方法对于 MultiNet5 和 MultiNet6 都适用。

- 应用新的修改操作，所有添加、移除、修改及清空操作在调用后才会被应用。

```
/**
* @brief Update the speech commands of MultiNet
*
* @Warning: Must be used after [add/remove/modify/clear] function,
*           otherwise the language model of multinet can not be␣
↪updated.
*
* @return
*     - NULL                  Success
*     - others                The list of error phrase which can not be␣
↪parsed by multinet.
*/
esp_mn_error_t *esp_mn_commands_update();
```

- 添加一条新指令，如果指令格式不正确则返回 ESP_ERR_INVALID_STATE。

```
/**
* @brief Add one speech commands with command string and command ID
*
* @param command_id      The command ID
* @param string  The command string of the speech commands
*
* @return
*     - ESP_OK                  Success
*     - ESP_ERR_INVALID_STATE   Fail
*/
esp_err_t esp_mn_commands_add(int command_id, char *string);
```

- 移除一条指令，如果该指令不存在则返回 ESP_ERR_INVALID_STATE。

```
/**
```

(下页继续)

(续上页)

```
* @brief Remove one speech commands by command string
*
* @param string  The command string of the speech commands
*
* @return
*     - ESP_OK                  Success
*     - ESP_ERR_INVALID_STATE   Fail
*/
esp_err_t esp_mn_commands_remove(char *string);
```

- 修改一条指令，如果该指令不存在则返回 ESP_ERR_INVALID_STATE。

```
/**
* @brief Modify one speech commands with new command string
*
* @param old_string  The old command string of the speech commands
* @param new_string  The new command string of the speech commands
*
* @return
*     - ESP_OK                  Success
*     - ESP_ERR_INVALID_STATE   Fail
*/
esp_err_t esp_mn_commands_modify(char *old_string, char *new_string);
```

- 清空所有指令。

```
/**
* @brief Clear all speech commands in linked list
*
* @return
*     - ESP_OK                  Success
*     - ESP_ERR_INVALID_STATE   Fail
*/
esp_err_t esp_mn_commands_clear(void);
```

- 打印缓存的指令, 只有当调用 esp_mn_commands_update() 缓存指令才会被应用.

```
/**
* @brief Print all commands in linked list.
*/
void esp_mn_commands_print(void);
```

- 打印当前已经被应用的指令.

```
/**
* @brief Print all commands in linked list.
*/
void esp_mn_active_commands_print(void);
```

4.5 MultiNet 的使用

MultiNet 命令词识别建议和 ESP-SR 中的 AFE 声学算法模块一起运行，具体请参考*AFE 介绍及使用*)。当用户配置完成 AFE 后，请按照以下步骤配置和运行 MultiNet。

4.5.1 MultiNet 初始化

- 模型加载与初始化，请参考模型加载
- 设置命令词，请参考命令词格式要求

4.5.2 MultiNet 运行

当用户开启 AFE 且使能 WakeNet 后，则可以运行 MultiNet。但需要注意以下几点要求：

- 传入帧长和 AFE fetch 帧长长度相等
- 支持音频格式为 16 KHz，16 bit，单通道。AFE fetch 拿到的数据也为这个格式
- 确定需要传入 MultiNet 的帧长

  ```
  int mu_chunksize = multinet->get_samp_chunksize(model_data);
  ```

  `mu_chunksize` 是需要传入 MultiNet 的每帧音频的 `short` 型点数，这个大小和 AFE 中 fetch 的每帧数据点数完全一致。
- MultiNet 识别

  我们将 AFE 实时 `fetch` 到的数据送入以下 API：

  ```
  esp_mn_state_t mn_state = multinet->detect(model_data, buff);
  ```

  `buff` 的长度为 `mu_chunksize * sizeof(int16_t)`。

4.5.3 MultiNet 识别结果

命令词识别必须和唤醒搭配使用，当唤醒后可以运行命令词的检测。

命令词模型在运行时，会实时返回当前帧的识别状态 `mn_state` ，目前分为以下几种识别状态：

- ESP_MN_STATE_DETECTING

  该状态表示目前正在识别中，还未识别到目标命令词。
- ESP_MN_STATE_DETECTED

  该状态表示目前识别到了目标命令词，此时用户可以调用 `get_results` 接口获取识别结果。

  ```
  esp_mn_results_t *mn_result = multinet->get_results(model_data);
  ```

  识别结果的信息存储在 `get_result` API 的返回值中，返回值的数据类型如下：

  ```
  typedef struct{
      esp_mn_state_t state;
      int num;                    // The number of phrase in list, num<=5.␣
  ↪When num=0, no phrase is recognized.
      int phrase_id[ESP_MN_RESULT_MAX_NUM];       // The list of phrase␣
  ↪id.
      float prob[ESP_MN_RESULT_MAX_NUM];          // The list of␣
  ↪probability.
  } esp_mn_results_t;
  ```

  其中，
  - `state` 为当前识别的状态
  - `num` 表示识别到的词条数目，`num` <= 5，即最多返回 5 个候选结果
  - `phrase_id` 表示识别到的词条对应的 Phrase ID
  - `prob` 表示识别到的词条识别概率，从大到到小依次排列

  用户可以使用 `phrase_id[0]` 和 `prob[0]` 拿到概率最高的识别结果。
- ESP_MN_STATE_TIMEOUT

  该状态表示长时间未检测到命令词，自动退出。等待下次唤醒。

单次识别模式和连续识别模式：当命令词识别返回状态为 `ESP_MN_STATE_DETECTED` 时退出命令词识别，则为单次识别模式；当命令词识别返回状态为 `ESP_MN_STATE_TIMEOUT` 时退出命令词识别，则为连续识别模式；

4.6 资源消耗

有关本模型的资源消耗情况，请见资源消耗。

Chapter 5

TTS 语音合成模型

乐鑫 TTS 语音合成模型是一个为嵌入式系统设计的轻量化语音合成系统，具有如下主要特性：

- 目前 **仅支持中文**
- 输入文本采用 UTF-8 编码
- 输出格式采用流输出，可减少延时
- 多音词发音自动识别
- 可调节合成语速
- 数字播报优化
- 自定义声音集（敬请期待）

5.1 简介

乐鑫 TTS 的当前版本基于拼接法，主要组成部分包括：

- 解析器 (Parser)：根据字典与语法规则，将输入文本（采用 UTF-8 编码）转换为拼音列表。
- 合成器 (Synthesizer)：根据解析器输出的拼音列表，结合预定义的声音集，合成波形文件。默认输出格式为：单声道，16 bit @ 16000Hz。

系统框图如下：

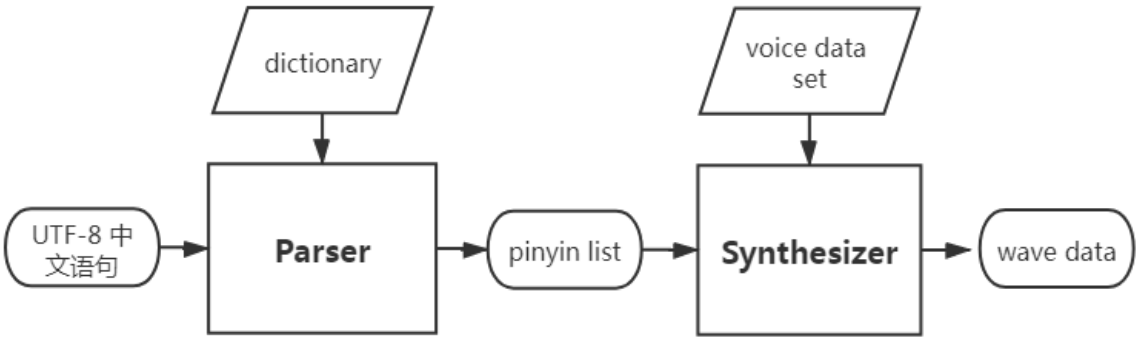

5.2 简单示例

- esp-tts/samples/xiaoxin_speed1.wav (voice=xiaoxin, speed=1)：欢迎使用乐鑫语音合成，支付宝收款 72.1 元，微信收款 643.12 元，扫码收款 5489.54 元
- esp-tts/samples/S2_xiaole_speed2.wav (voice=xiaole, speed=2)：支付宝收款 1111.11 元

5.3 编程指南

```
#include "esp_tts.h"
#include "esp_tts_voice_female.h"
#include "esp_partition.h"

/*** 1. create esp tts handle  ***/


// initial voice set from separate voice data partition

const esp_partition_t* part=esp_partition_find_first(ESP_PARTITION_TYPE_DATA, ESP_
↪PARTITION_SUBTYPE_DATA_FAT, "voice_data");
if (part==0) printf("Couldn't find voice data partition!\n");
spi_flash_mmap_handle_t mmap;
uint16_t* voicedata;
esp_err_t err=esp_partition_mmap(part, 0, part->size, SPI_FLASH_MMAP_DATA, (const␣
↪void**)&voicedata, &mmap);
esp_tts_voice_t *voice=esp_tts_voice_set_init(&esp_tts_voice_template, voicedata);

// 2. parse text and synthesis wave data
char *text="欢迎使用乐鑫语音合成";
if (esp_tts_parse_chinese(tts_handle, text)) {  // parse text into pinyin list
    int len[1]={0};
    do {
        short *data=esp_tts_stream_play(tts_handle, len, 4); // streaming synthesis
        i2s_audio_play(data, len[0]*2, portMAX_DELAY);  // i2s output
    } while(len[0]>0);
    i2s_zero_dma_buffer(0);
}
```

更多参考，请前往 esp-tts/esp_tts_chinese/include/esp_tts.h 查看 API 定义，或参考 ESP-Skainet 中 chinese_tts 示例.

5.4 资源消耗

有关本模型的资源消耗情况，请见资源消耗。

Chapter 6

模型加载

在人工智能行业中，模型是指一个系统或过程的数学表示。它用于基于输入数据做出预测或决策，有许多不同类型的模型，如决策树、神经网络和支持向量机，每种模型都有其优缺点。乐鑫也提供经过训练的 WakeNet 和 MultiNet 模型（数据模型见 model）。

使用模型前需先将其加载至你的项目，目前 ESP-SR 支持以下模型加载方式：

ESP32：从 Flash 中直接加载

6.1 配置方法

运行 `idf.py menuconfig` 进入 `ESP Speech Recognition`:

```
(Top) → ESP Speech Recognition

    model data path (spiffs partition)  --->
[*] use afe
        Afe interface (afe interface(version: v1))  --->
[*] use wakenet
        Select wake words (Hi,Lexin (wn9_hilexin))  --->
[*] use multinet
        Chinese Speech Commands Model (chinese recognition (mn4_cn))  --->
        English Speech Commands Model (None)  --->
    Add Chinese speech commands  --->
```

图 1: overview

6.1.1 使用 AFE

此选项需要打开，用户无须修改，请保持默认配置。

6.1.2 使用 WakeNet

此选项默认打开。当用户只使用 AEC 或者 BSS 等，而无须运行 WakeNet 或 MultiNet 时，请关闭次选项，这将会减小工程固件的大小。

根据 `menuconfig` 列表选择唤醒词模型，`ESP Speech Recognition` > `Select wake words`。括号中为唤醒词模型的名字，在代码中初始化 WakeNet 时需写入对应的名字。

```
(Top) → ESP Speech Recognition → use wakenet → Select wake words

( ) Alexa (wn8_alexa)
(X) Hi,Lexin (wn9_hilexin)
( ) xiaoaitongxue (wn9_xiaoaitongxue)
( ) Alexa (wn9_alexa)
( ) Hi,ESP (wn9_hiesp)
( ) customized word (wn9_customizedword)
( ) Load Multiple Wake Words
```

如果想加载多个唤醒词，以便在代码中进行唤醒词的切换，首选选择 `Load Multiple Wake Words`

```
(Top) → ESP Speech Recognition → use wakenet → Select wake words

( ) Alexa (wn8_alexa)
( ) Hi,Lexin (wn9_hilexin)
( ) xiaoaitongxue (wn9_xiaoaitongxue)
( ) Alexa (wn9_alexa)
( ) Hi,ESP (wn9_hiesp)
( ) customized word (wn9_customizedword)
(X) Load Multiple Wake Words
        Load Multiple Wake Words  --->
```

然后按照列表选择多个唤醒词：

```
(Top) → ESP Speech Recognition → use wakenet → Select wake words → Load Multiple Wake Words → Load Multiple Wake Words
                                                                    Espressif IoT Development Framework Config
[*] Hi,Lexin (wn9_hilexin)
[*] xiaoaitongxue (wn9_xiaoaitongxue)
[*] Alexa (wn9_alexa)
[ ] Hi,ESP (wn9_hiesp) (NEW)
```

备注： ESP32 不支持多唤醒词选项。

更多细节请参考 *WakeNet* 。

6.1.3 使用 MultiNet

此选项默认打开。当用户只使用 WakeNet 或者其他算法模块时，请关闭此选项，将会在一些情况下减小工程固件的大小。

中文命令词识别模型 (Chinese Speech Commands Model)

ESP32 芯片只支持中文命令词识别：

- None
- Chinese single recognition (MultiNet2)

用户按照需求自定义添加命令词，具体请参考 *MultiNet* 。

6.2 模型使用

当用户完成以上的配置选择后，可参考 ESP-Skainet 应用层仓库中的介绍，进行初始化和使用。

这里主要介绍模型加载在用户工程中的代码实现，用户也可直接参考代码 model_path.c 。

ESP32 仅支持从 Flash 中直接加载模型数据，因此代码中模型数据会自动按照地址从 Flash 中读取所需数据。为了和 ESP32-S3 进行兼容，ESP32 代码中模型的初始化方法与 ESP32-S3 相同。

6.2.1 模型数据存储在 Flash

1. 编写分区表：

```
model,  data, data,         , SIZE,
```

   其中 SIZE 可以参考在用户使用 `idf.py build` 编译时的推荐大小，例如：`Recommended model partition size: 500K` 。
2. 初始化 partition 分区：用户可以直接调用提供的 `esp_srmodel_init(partition_label)` API 来获取 partition 中的模型。
   - partition_label：为 partition table 中定义的模型的分区，需要和上述函数的入参保持一致

完成上述配置后，模型会在工程编译完成后自动生成 `srmodels.bin` ，并在用户调用 `idf.py flash` 时烧写到指定分区。

Chapter 7

性能测试结果

7.1 AFE

7.1.1 资源消耗

Algorithm Type	RAM	Average cpu loading(compute with 2 cores)	Frame Length
AEC(HIGH_PERF)	114 KB	11%	32 ms
NS	27 KB	5%	10 ms
AFE Layer	73 KB		

7.2 WakeNet

7.2.1 资源消耗

Model Type	Parameter Num	RAM	Average Running Time per Frame	Frame Length
Quantised WakeNet5	41 K	15 KB	5.5 ms	30 ms
Quantised WakeNet5X2	165 K	20 KB	10.5 ms	30 ms
Quantised WakeNet5X3	371 K	24 KB	18 ms	30 ms

7.2.2 性能测试

Distance	Quiet	Stationary Noise (SNR = 4 dB)	Speech Noise (SNR = 4 dB)	AEC I nterruption (-10 dB)
1 m	98%	96%	94%	96%
3 m	98%	96%	94%	94%

误触发率：12 小时 1 次

备注： 我们在测试中使用了 ESP32-S3-Korvo V4.0 开发板和 WakeNet9(Alexa) 模型。

7.3 MultiNet

7.3.1 资源消耗

Model Type	Internal RAM	PSRAM	Average Running Time per Frame	Frame Length
MultiNet 2	13.3 KB	9KB	38 ms	30 ms

7.3.2 Word Error Rate 性能测试

Model Type	aishell test
MultiNet 5_cn	9.5%
MultiNet 6_cn	5.2%

备注： 中文使用没有声调的拼音单元去计算 WER。

7.3.3 Speech Commands 性能测试 (空调控制场景)

Model Type	Distance	Quiet	Stationary Noise (SNR=5~10dB dB)	Speech Noise (SNR=5~10dB dB)
MultiNet 5_cn	3 m	88.9%	66.1%	67.5%
MultiNet 6_cn	3 m	98.8%	88.3%	88.0%
MultiNet 6_cn_ac	3 m	97.1%	95.1%	96.8%

备注： MultiNet6_cn_ac 在空调场景数据集上进行了进一步的微调，所以在空调控制场景具有更好的性能。

7.4 TTS

7.4.1 资源消耗

Flash image size: 2.2 MB

RAM runtime: 20 KB

7.4.2 性能测试

CPU 负载测试（ESP32 @240 MHz）：

Speech Rate	0	1	2	3	4	5
Times faster than real time	4.5	3.2	2.9	2.5	2.2	1.8

7.5 NSNET

7.5.1 性能测试

7.5.2 数据集：array_onemic_nnoise_20230608(按照亚马逊声学认证标准录制测试集)

	dnsmos
nsnet1	2.4
nsnet2	2.71

Chapter 8

测试方法与测试报告

为了保证 DUT 的性能，可通过测试确定 DUT 在以下方面的表现：

- 唤醒率
- 识别率
- 误唤醒率
- 唤醒打断率
- 响应时间

8.1 测试场景要求

以上测试需在合适的测试房间中进行，测试房间应满足如下要求：

- **房间大小**
  - 面积：不小于 4 m * 3.2 m
  - 高度：不低于 2.3 m
- **房间装饰**
  - 地板需配有地毯，天花板需配备常见声学阻尼材料，墙面应有 1 到 2 面墙上挂有窗帘，防止强反射。
  - 房间混响 (RT60) 3 在 [125, 8k] 范围内，要满足 0.2-0.7s 的要求。
  - 不要使用消音室。
- **环境底噪**：必须 < 35 dBA，最好 < 30 dBA
- **温度和湿度要求**：20±10°C，相对湿度为 50%±20%。
- **DUT、外部噪声、人声的放置**：
  - DUT、外部噪声、人声的具体位置和相对位置应根据 DUT 的实际应用场景进行安排。

备注： RT60、环境底噪和 DUT、外部噪声、人声的放置应在所有测试中保持不变。

8.2 测试案例设计

在设计测试案例时，建议按照产品的实际应用场景，考虑 **以下部分或全部参数**：

- **不同噪声源**
  - 白噪声
  - 人类噪声
  - 音乐
  - 新闻
  - ……

  - 有必要时还可以增加多噪声源的测试场景。
- **不同噪声分贝**
  - < 35 dBA
  - 45 dBA
  - 55 dBA
  - 65 dBA
- **不同人声分贝**
  - 54 dBA
  - 59 dBA
  - 64 dBA
- **不同 SNR**
  - 9 dBA
  - 4 dBA
  - -1 dBA

8.3 乐鑫测试与结果

在本章节描述的所有测试中，DUT、外部噪声、人声的具体位置和相对位置如下所述。

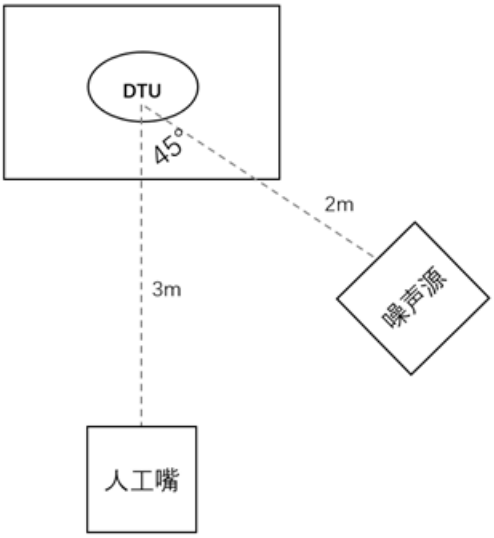

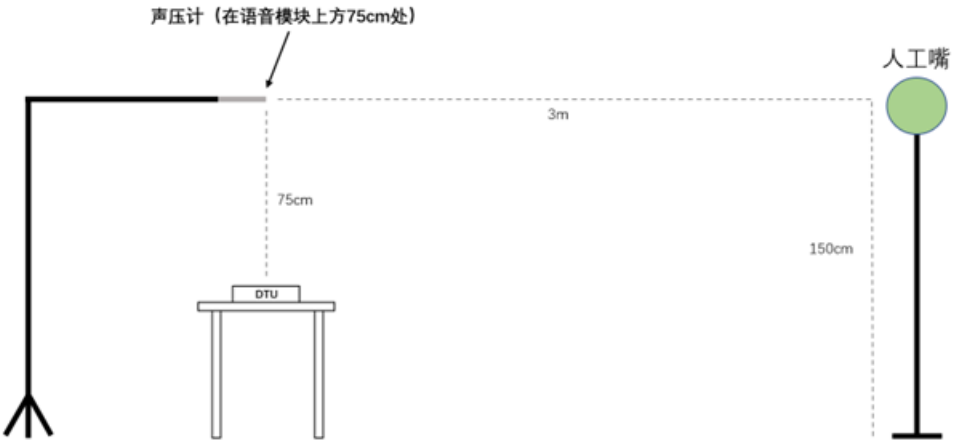

具体来说，

- DUT 距离地面高度 0.75 米
- 人工嘴（人声源）距离地面高度 1.5 米，距离 DUT 直线水平距离 3 米
- 噪声源在相对人工嘴 45°C 角处，距离地面高度 1.2 米，距离 DUT 直线水平距离 2 米
- 声压计位于 DUT 正上方 0.75 米

8.3.1 唤醒率测试

唤醒率：指当设备处于待唤醒状态时被唤醒成功的概率。

乐鑫唤醒率测试和结果

测试案例	噪声类型	噪声分贝	人声分贝	SNR	唤醒率
1	/	/	59 dBA	/	99%
2	白噪声	55 dBA	59 dBA	≥4 dBA	99%
3	人声噪声	55 dBA	59 dBA	≥4 dBA	99%

8.3.2 语音识别率测试

语音识别率：指当设备处于识别状态时，成功识别词表里包含的命令词的概率。

乐鑫语音识别率测试和结果

测试案例	噪声类型	噪声分贝	人声分贝	SNR	语音识别率
1	/	/	59 dBA	/	91.5%
2	白噪声	55 dBA	59 dBA	≥4 dBA	78.25%
3	人声噪声	55 dBA	59 dBA	≥4 dBA	82.77%

8.3.3 误唤醒率测试

误唤醒率：指设备在产品定义的应用场景下被非唤醒词成功唤醒的概率。

乐鑫误唤醒率测试和结果

测试案例	噪声类型	噪声分贝	测试时长	误唤醒次数
1	音乐	55 dBA	12 小时	1 次
2	新闻	55 dBA	12 小时	1 次

8.3.4 唤醒打断率测试

唤醒打断率：唤醒打断率是指设备有自噪时，即有 TTS3 播报或播放音频时，被唤醒成功的概率。对于有 AEC 功能的产品需要进行该测试。

乐鑫唤醒打断率测试和结果

测试案例	噪声类型	噪声 / 人声分贝	SNR	唤醒率	语音识别率
1	音乐	69 dBA / 59 dBA	≥10 dBA	100%	96%
2	TTS	69 dBA / 59 dBA	≥10 dBA	100%	96%

8.3.5 响应时间测试

响应时间：代表 DUT 响应语音命令的时间，具体测量为语音指令与播报之间的时间间隔（见下图）。

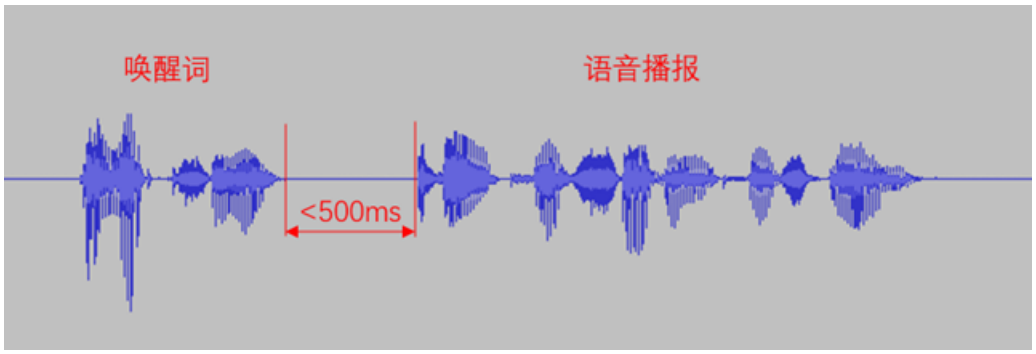

乐鑫响应时间测试和结果

测试案例	噪声 / 人声分贝	SNR	响应时间
1	NA / 59 dBA	/	< 500 ms

Chapter 9

术语表

9.1 通用术语

ESP-SR 仓库中的大多数术语均与 乐鑫 ADF 音频应用开发框架 共用，具体请访问 ADF 中英术语库。

9.2 特别术语

ESP-SR 仓库独有术语，请见下方。

语音用户界面 (Voice-User Interface, VUI)