

阿拉伯语语音数据库

AISHELL-ASR0028



希尔贝壳
产品说明书
A I S H E L L

Copyright

目录

1 产品概述	3
2 语音数据转写	3
3 目录结构与命名规则	3
3.1 目录结构	3
3.2 命名规则	4
4 版权声明	4



Copyright

1 产品概述

AISHELL-ASR0028 阿拉伯语语音数据库，共 899 小时，448611 句。采样率 16000Hz，比特率 16bit。共邀请 1348 名发音人通过手机在安静环境下进行录制。发音人主要来自阿尔及利亚、摩洛哥、沙特和埃及。

经过专业语音校对人员转写标注，并通过严格质量检验，文本正确率在 95%以上。

2 语音数据转写

数据转写人员根据所听到的音频写出内容，力求使文本内容与音频发音内容保持一致。

一般准则如下：

- 1) 转写的内容必须和听到的语音完全一致，不能多字、少字、错字。
- 2) 数字要转写为英文拉丁形式，如 “واحد اثنین ثلاثة”，而不是 “123”。
- 3) 英文按单词小写，拼读发音需写成大写字母加空格，如，“W W W dot Google dot com”，“CEO”。
- 4) 标注内容的完整性要与实际发音一致，不得删减。

3 目录结构与命名规则

3.1 目录结构

数据目录树	
数据目录结构	
AISHELL-ASR0028.pdf	(数据库简介)
└─DOC	(文本说明文件)
└─wav_list.txt	(音频列表)
└─content.txt	(转写内容列表)
└─SPEECHDATA	(音频文件夹)
└─F0004	(录音人编号)
F0004W0001.wav	(音频文件)

图表 3-1-1 目录结构

3.2 命名规则

CORPUS/USAGE/SPEAKER_ID/SPEECH_ID

e.g. AISHELL-ASR0028/SPEECHDATA/F0004/F0004W0001.wav

目录名称	内容	备注
CORPUS	AISHELL-ASR0028	语音数据库编号
USAGE	SPEECHDATA	音频文件夹
SPEAKER_ID	F0004	录音人编号
SPEECH_ID	F0004W0001.wav	音频文件

图表 3-2-1 命名规则

4 版权声明

本文内容禁止转载，AISHELL(北京希尔贝壳科技有限公司)对本文拥有修改权、更新权及最终解释权。



希尔贝壳
AISHELL

Copyright