

# 中文普通话语音数据库

AISHELL-ASR0009

产品说明书

北京希尔贝壳科技有限公司  
Beijing Shell Shell Technology Co.,Ltd

Add: Room 3-621, 6F, Zhongguancun Lifangting No. 1, Shanyuan Road, Haidian District, Beijing 100080, P.R.China

Tel: +86 10 80225006 E-mail: bd@aishelldata.com

## 目录

1 产品概述.....	2
2 录音语料.....	2
2.1 语料池的制作.....	2
2.1.1 语料池内容.....	2
2.1.2 语料池处理.....	3
2.2 录音文本的结构设计.....	3
3 发音人信息.....	4
3.1 基本信息记录.....	4
3.2 发音人结构特征.....	4
3.2.1 性别比例.....	4
3.2.2 年龄比例.....	4
3.2.3 方言区域比例.....	5
4 数据录制环境.....	5
4.1 录制环境.....	5
4.2 录制设备.....	5
4.3 录制方法.....	5
5 标注转写规范.....	6
6 产品目录结构.....	7
6.1 目录结构.....	7
6.2 命名规则.....	7
7 版权声明.....	8

# 1 产品概述

AISHELL-ASR0009 中文普通话语音数据库共 3000 小时。录音文本涉及智能家居、无人驾驶、工业生产等 15 个领域。邀请 2000 名来自中国不同口音区域发音人参与录制。录制过程在安静室内环境中，同时使用 3 种不同设备：高保真麦克风（44.1kHz，16bit，1000H）；Android 系统手机（16kHz，16bit，1000H）；iOS 系统手机（16kHz，16bit，1000H）。

此数据库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 97% 以上。

## 2 录音语料

### 2.1 语料池的制作

#### 2.1.1 语料池内容

考虑到语音识别在智能家居、无人驾驶、工业生产等领域的应用，语料在 15 个领域中选定，共 300 万句常用中文语句。

C0001-C1000		C9001-C9348	
序号	领域	序号	领域
1	家居家电名称和控制命令	1	家居
2	POI (地理信息)	2	POI
3	音乐类 (语控)	3	音乐类 (语控)
4	数字类 (语控)	4	数字类 (语控)
5	电视、电影名称	5	电视名称
6	财经	6	财经-政策
7	科技	7	财经-地产
8	体育	8	科技-国际
9	娱乐	9	科技-国内
10	时事新闻	10	体育
11	英文拼读	11	娱乐-欧美
		12	娱乐-港台
		13	时事新闻
		14	综合
		15	英文拼读

图表 2-1 语料池内容

## 2.1.2 语料池处理

- 脱敏处理。删除政治敏感、个人隐私、色情暴力等内容。
- 删除 <, >, [, ], ~, /, \, = 等符号。
- 删除含有中文和英文以外语言的内容。
- 统一格式。

## 2.2 录音文本的结构设计

考虑到语音覆盖及音素平衡，此数据库 C0001-C1000 录音文本采用每份 500 句的分配方式设计，C9001-C9348 录音文本采用每份 520 句的分配方式设计，从语料池中抽取，结构如下。

C0001-C1000			C9001-C9348		
序号	领域	每份分配量/句	序号	领域	每份分配量/句
1	家居家电和控制名称	5	1	家居	5
2	POI (地理信息)	30	2	POI	30
3	音乐类 (语控)	46	3	音乐类 (语控)	46
4	数字类 (语控)	29	4	数字类 (语控)	29
5	电视、电影名称	10	5	电视名称	13
6	财经	132	6	财经-政策	20
7	科技	85	7	财经-地产	20
8	体育	66	8	科技-国际	15
9	娱乐	27	9	科技-国内	10
10	时事新闻	66	10	体育	20
11	英文拼读	4	11	娱乐-欧美	4
			12	娱乐-港台	10
			13	时事新闻	10
			14	综合	200
			15	英文拼读	4
			16	问答	84
合计	11 项	500 句	合计	16 项	520 句

图表 2-2 录音文本结构

## 3 发音人信息

### 3.1 基本信息记录

发音人信息记录内容包括任务编号、性别、年龄段、籍贯。

任务编号	年龄区间	性别	口音区域
C0001	B	女	北方

图表 3-1 发言人信息表示例

**任务编号：**每个发言人领取 1 个任务编号，每个任务编号对应 1 份录音文本。每个发言人只能参加一次录制。

**年龄区间：**A(18 岁以下)、B(18-25 岁)、C(26-45 岁)、D(45 岁以上)。

**性别：**男-男性；女-女性。

**口音区域：**按照发言人原生语言所属区域，分为北方、南方、其他。

### 3.2 发音人结构特征

#### 3.2.1 性别比例

数据库总人数为 2000 人，男 863 人，女 1137 人。

性别	男性	女性	合计
比例	43%	57%	100%

图表 3-2-1 性别分布

#### 3.2.2 年龄比例

A(18 岁以下)18 人、B(18-25 岁)1528 人、C(26-45 岁)310 人、D(45 岁以上)144 人。

年龄段	人数	比例	男性	女性
A	18	9%	5	13
B	1528	76.4%	633	895
C	310	15.5%	159	151
D	144	7.2%	66	78
<b>合计</b>	<b>2000</b>	<b>100.00%</b>	<b>863</b>	<b>1137</b>

图表 3-2-2 年龄分布

### 3.2.3 方言区域比例

方言区域	人数	比例
北方	1267	63%
南方	710	36%
其他	23	1%

图表 3-2-3 方言区域分布

## 4 数据录制环境

### 4.1 录制环境

安静室内，不包括明显的其他人说话声音及其他噪音，无回音。发言人按照正常语速，朗读录音文本。

### 4.2 录制设备

录制设备包括高保真麦克风和录音机、手机。本数据库数据存储格式为高保真录制数据 44.1kHz、16bit 单声道和手机录制数据 16kHz、16bit 单声道两种格式。

### 4.3 录制方法

发音人距离高保真麦克风 20 厘米，以讲话正常音量，正常语速，朗读录音文本。Android 系统手机与 iOS 系统手机分别与麦克风间隔 20 厘米布置。



图表 4-3 录制示意图

## 5 标注转写规范

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。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) 数字要转写为汉字形式，如“一二三”，而不是“123”。注意区分“一”和“幺”，“二”和“两”。
- 3) 句中出现的英文按照发音写出单词，如“thank you”。按拼读朗读的字母，需转写成大写字母加空格的形式。如，“N B A”、“U F O”。
- 4) 句中包含的符号，按实际发言人发音转写。如“三 W 点 百度 点 com”。没有发音的符号，需要删掉。品牌名称，专有名称等按照实际惯用格式转写，如“QQ 空间”、“iPhone”、“喜马拉雅”。
- 5) 标注内容的完整性要与实际发音一致，不得删减。

## 6 产品目录结构

### 6.1 目录结构

数据目录结构	
数据目录结构	
AISHELL-ASR0009.pdf	(数据库简介)
└─DOC	(文本说明文件)
─wav_list.txt	(音频列表)
─content.txt	(语音文本内容)
─spk_info.xlsx	(录音人信息)
└─SPEECHDATA	(数据文件夹)
─C0001	(录音人文件夹)
ANDROID	(设备文件夹)
AC0001W0001.wav	(音频文件)
AC0001W0001.txt	(语音内容文本)
IOS	(设备文件夹)
IC0001W0001.wav	(音频文件)
IC0001W0001.txt	(语音内容文本)
MIC	(设备文件夹)
MC0001W0001.wav	(音频文件)
MC0001W0001.txt	(语音内容文本)

图表 6-1-1 数据目录结构

### 6.2 命名规则

**CORPUS/USAGE/SPEAKER\_NUM/EQUIPMENT\_ID/SPEECH\_ID**

e. g. AISHELL-ASR0009/SPEECHDATA/C0001/ANDROID/ H0001A0001. wav

目录名称	内容	备注
<b>CORPUS</b>	AISHELL-ASR0009	语音数据库编号
<b>USAGE</b>	SPEECHDATA	文件夹名称
<b>SPEAKER_NUM</b>	C0001	录音人文件夹
<b>EQUIPMENT_ID</b>	ANDROID/IOS/ MIC	设备文件夹
<b>SPEECH_ID</b>	AC0001W0001.wav	WAV 文件

图表 6-2-1 命名规则



## 7 版权声明

本文章内容禁止转载，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**  
A I S H E L L

**Copyright**