

콜센터 서비스를 위한 한국어 음성인식 기술 version 2.0

지능정보연구본부



제4차 산업혁명을 선도하는 ICT Innovator

ETRI

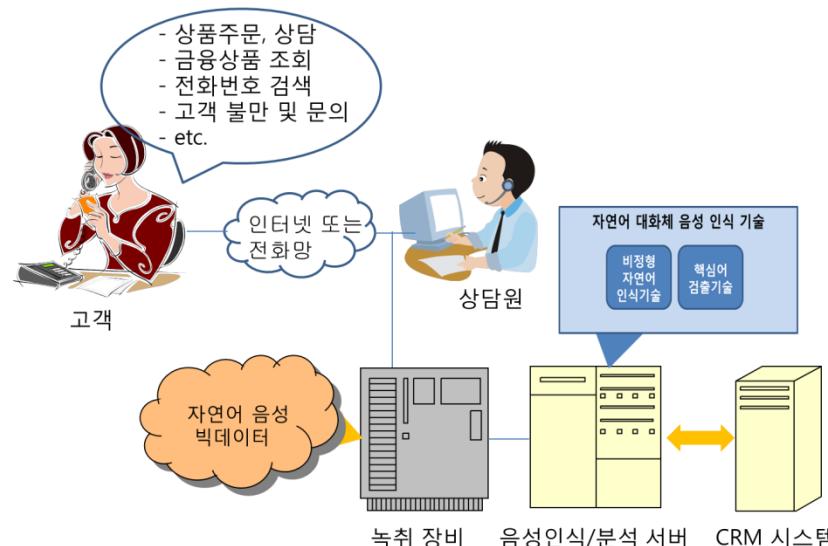
● 정의

- “콜센터 서비스를 위한 한국어 음성인식 기술”은 콜센터의 상담원과 고객과의 통화 녹음 데이터를 자동으로 음성인식 하는 기술로써 자연어 대화체 음성 인식 기술이다.

● 활용 방법

- 이 음성인식 기술은 종래 ARS 시스템을 일부 대체하거나 SA(Speech Analytics) 서비스에 적용 가능하다.
- 1차적으로 고객 센터로 걸려오는 전화에 대해 24시간 365일 무휴 고객응대서비스가 가능하여 고객 만족도를 제고할 수 있다.
- 2차적으로 콜센터 녹취 데이터를 음성 인식하여 문자정보로 자동 변환한 후, 이를 분석하여 상담원 대응의 타당성 여부, 고객 불만 사항 및 이슈 조기탐지 등을 수행하는데 이용한다.

● 시스템 구성



- 기술명 : 콜센터 서비스를 위한 한국어 음성인식기술 version 2.0
- 기술이전의 범위
 - 음성인식 엔진
 - ❖ 음성인식 SDK (리눅스 라이브러리 및 그 API 제공) 및 사용자 지침서
 - ❖ 음성인식 SDK 적용 예제 코드
 - 한국어 음향 및 언어 모델, 이에 기반하는 적응 훈련 도구
 - ❖ 기본 음향 모델: 8kHz
 - ❖ 음향 모델 적응 훈련 도구 및 스크립트
 - ❖ 기본 언어 모델: 10만 단어급 지원
 - ❖ 언어 모델 적응 훈련 도구 및 스크립트
- 기술이전 특이 사항
 - 기존 “콜센터 녹취데이터 음성인식 기술” 및 “콜센터 서비스를 위한 한국어 음성인식기술” version 1.0의 업그레이드 기술임
 - DNN(Deep Neural Network)에 기반하는 딥러닝(Deep Learning)에 따른 고도화된 음향 모델, 그 훈련 도구 및 스크립트가 추가됨
- 상세한 기술 구성은 <첨부> 참조

- 기술개발 기간 : 2013. 3. 1 ~ 2015. 7. 31.(29개월)
- 투입 연구비 : 24억원
- 경상 기술료 방식 적용 (공동연구 참여기업이 있으나 본 기술개발에 기여가 없음)

| 구분 | 중소기업 | 중견기업 | 대기업 |
|---|---|--|--|
| 착수기본료 (천원) | 120,000 | 240,000 | 240,000 |
| 매출정률 사용료 조건 1 | 총 판매석수에 따라 변경적용 • 1만석이하 : 11,000원/석 • 1만석~3만석 : 10,000원/석 • 3만석이상 : 9,500원/석 | 총 판매석수에 따라 변경적용 • 1만석이하 : 33,000원/석 • 1만석~3만석 : 30,000원/석 • 3만석이상 : 28,500원/석 | 총 판매석수에 따라 변경적용 • 1만석이하 : 44,000원/석 • 1만석~3만석 : 40,000원/석 • 3만석이상 : 38,000원/석 |
| 매출정률 사용료 조건 2 (※ 석당 기준을 적용 불가할 경우에 한하여 적용함) | 1.25% | 3.75% | 5% |

※ 매출정률사용료 산정 기준 : 제품(Speech Analytics)의 예상 가격은 약 80만원 정도이며 중소기업기준 1.25%의
매출정률 사용료를 적용할 경우 1만원임

※ **착수기본료 차감 조건 1:** 본 건의 평가용 기술을 전수받은 기관에 대해 착수기본료를 차감하고 계약을 추진함

- 기술명: “IVR서비스를 위한 연속어 음성인식 기술(평가용)” (계획번호: 7040-2012-0001)
- 기술료: 20,000천원/중소기업, 40,000천원/대기업 (매출정률사용료 없음)

※ **착수기본료 차감 조건 2:** 본 건의 하위 버전을 전수받은 기관에 대해 착수기본료를 차감하고 계약을 추진함

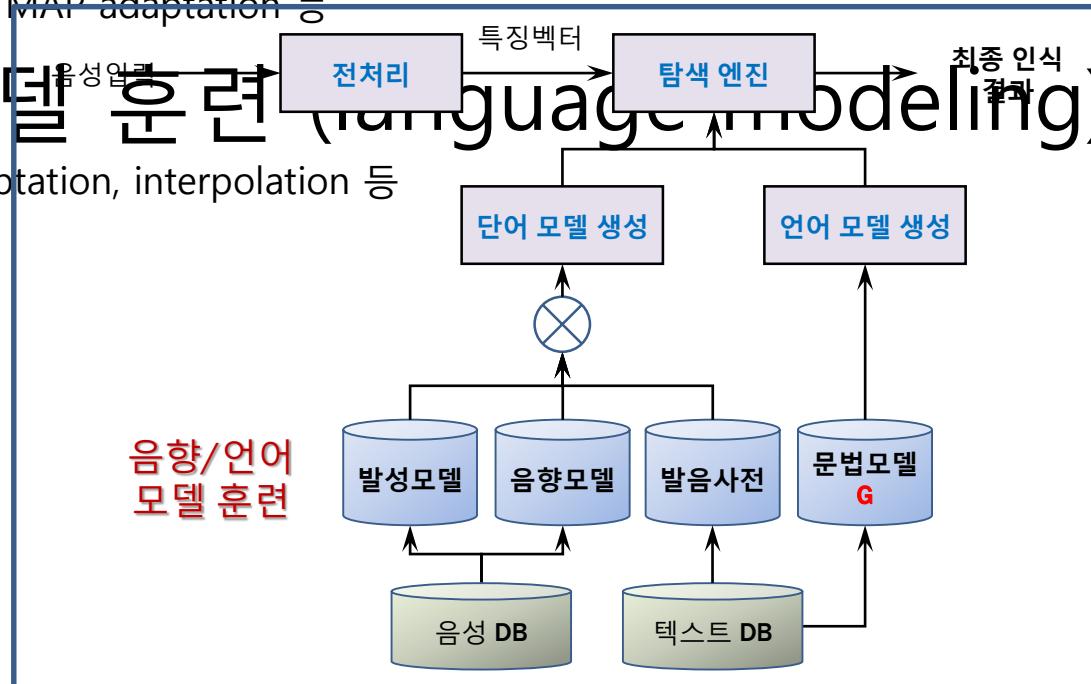
- 기술명1: “콜센터 서비스를 위한 한국어 음성인식기술” (계획번호: 1122-2014-10226)
- 기술명2: “콜센터 녹취데이터 음성인식 기술” (계획번호: 1122-2014-0001)
- 기술료(공통): 100,000천원/중소기업, 200,000천원/대기업

첨부



- ESTk-laser: ETRI Speech Toolkit - Large Scale Speech Recognizer
- ESTk-laser is developed to recognize very large scale of recognition domain on both high-end servers and resource-limited embedded devices.
- Technical features
 - Language independency
 - Platform independency
 - Single channel speech enhancement
 - Noise-robust endpoint detection
 - Speaker and environment adaptation
 - Speaker and channel normalization
 - Deep Learning (deep neural network) support

- 탐색 엔진 (search engine 또는 decoder)
 - 음향 및 언어 모델 등의 지식 베이스에 기반하여 고속/고성능 음성인식을 수행
- 음향 모델 훈련 (acoustic modeling)
- 언어 모델 훈련 (language modeling)
 - full training, MAP adaptation 등
 - domain adaptation, interpolation 등



LASER Specifications

| Consideration | | High-end device | Low-end embedded device |
|--------------------------|----------------------|-----------------|-----------------------------------|
| Language | Supporting languages | Korean, English | Korean, English |
| Platform | Supporting platforms | Linux, Windows | Windows, Android, iphone, nucleus |
| Recognition Mode | Continuous | Vocabulary size | >100K (140M trigrams) |
| | | RTF | 1.0xRT |
| | One-shot | Vocabulary size | - |
| | | RTF | - |
| Minimum H/W requirements | CPU | | 2.6 GHz |
| | Storage memory | | 30GB |
| | Running memory | | 40GB |
| etc | Grammar definition | ARPA, BNF, JSGF | ARPA, BNF, JSGF |

- Base layer
 - Wrapper for platform independency
- Decoding layer
 - Acoustic search
 - Lexical search
 - Rescoring
 - Multi-stage search
- Interface layer
 - low-level APIs : DLLs
 - Script-level interfaces : python, java

