

# 尤度ベース言語識別における 待ち時間短縮法

---

T. Okamoto, A. Hiroe and H. Kawai, "Reducing latency for language identification based on large-vocabulary continuous speech recognition," *Acoust. Sci. & Tech.*, (accepted, to appear).

○岡本拓磨, 廣江厚夫, 河井恒

情報通信研究機構

# Outline

---

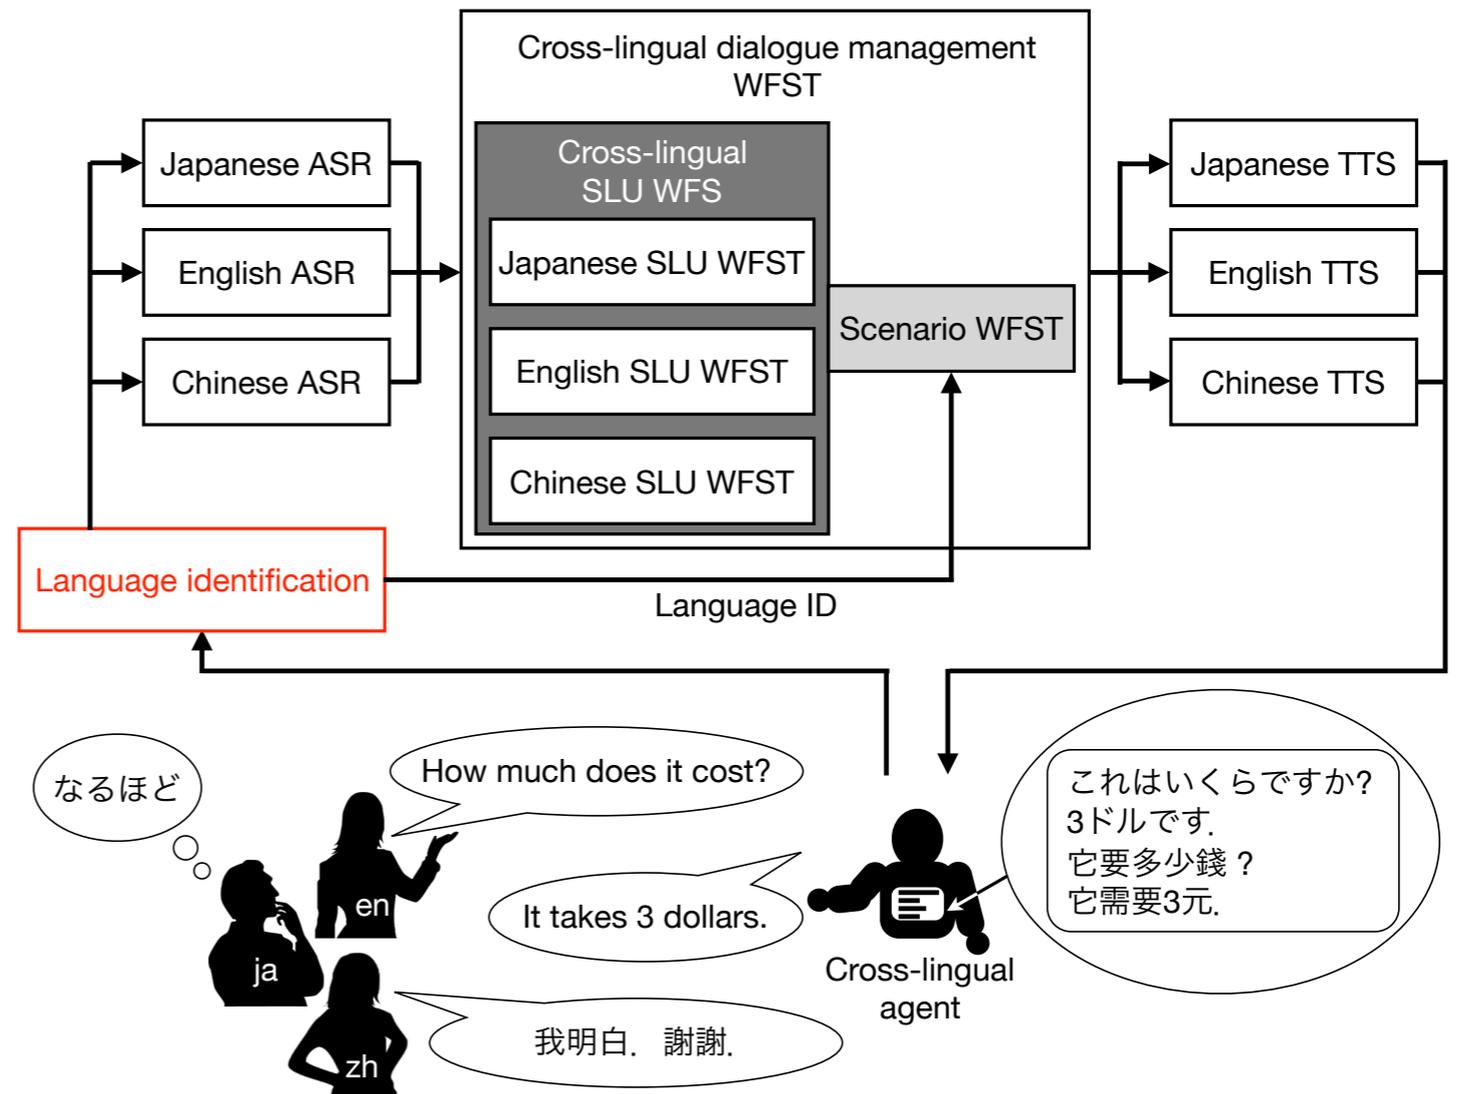
- Introduction
- Comparison of previous methods
  - Discriminative approaches
  - Multiple large vocabulary continuous speech recognition approach
- Latency problem in LVCSR based LID
  - Latency problem
  - Timeout
  - Tradeoffs between accuracy and latency
- Proposed method
- Experiments
- Concluding remarks

# Introduction

## 言語識別

■ 入力された言語が何語であるかを自動で推定する技術

✦ Applications: VoiceTra, クロスリンガル音声対話システム..

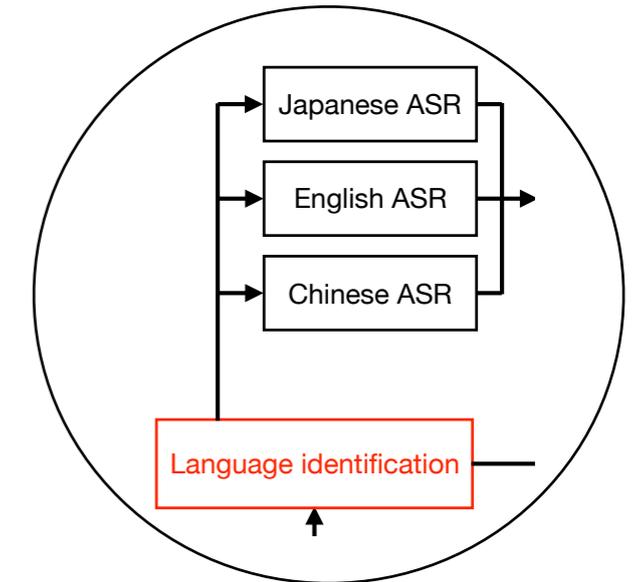


# Comparison of previous methods

## ■ 識別器による方式(現在の主流)

■ 入力音声特徴量から言語を直接識別 with i-vector and DNN

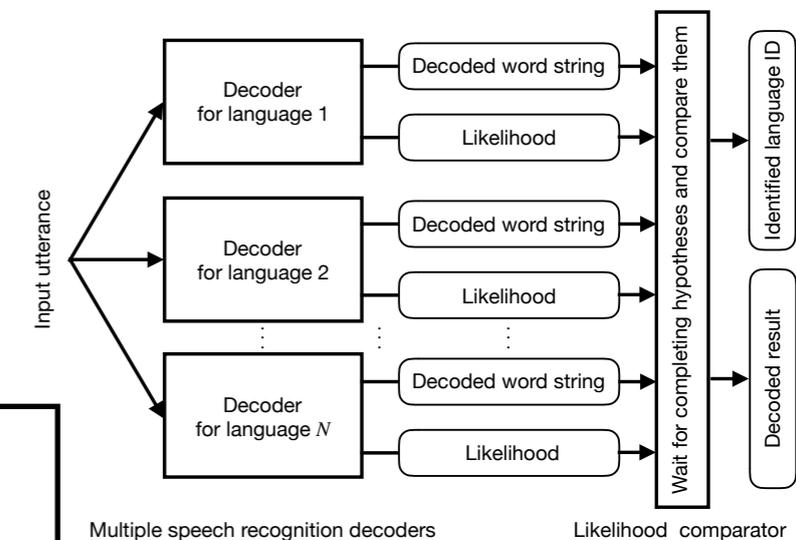
- ✱ ○ : 20~30言語でも高精度に識別可能(研究ベース)
- ✱ × : 識別学習要, 言語追加には再学習要



## ■ 尤度ベースによる方式(20年前に登場)

■ すべての音声認識器でデコードし, 尤度最大を選択

- ✱ ○(当時) : 言語追加容易, 実装が容易
- ✱ ×(当時) : (20言語などの場合)精度は識別器に劣る  
計算コスト高



- ・ 深層学習による音声認識モデルの向上
- ・ 計算機性能の向上
- ・ 比較的少ない言語(~10)での識別

- ✱ ○ : 識別学習不要, 言語追加容易, 実装&ラピッドプロトタイピング容易
- ✱ × : すべての認識結果を待つため, レイテンシーの発生

# Latency problem in LVCSR based LID

## ■ レイテンシー発生理由

### ■ モデルミスマッチ

- ✳ 入力とデコーダで言語が食い違う場合，モデルミスマッチのため仮説が膨大となり，言語が合っている場合と比べて計算時間がよけいにかかる

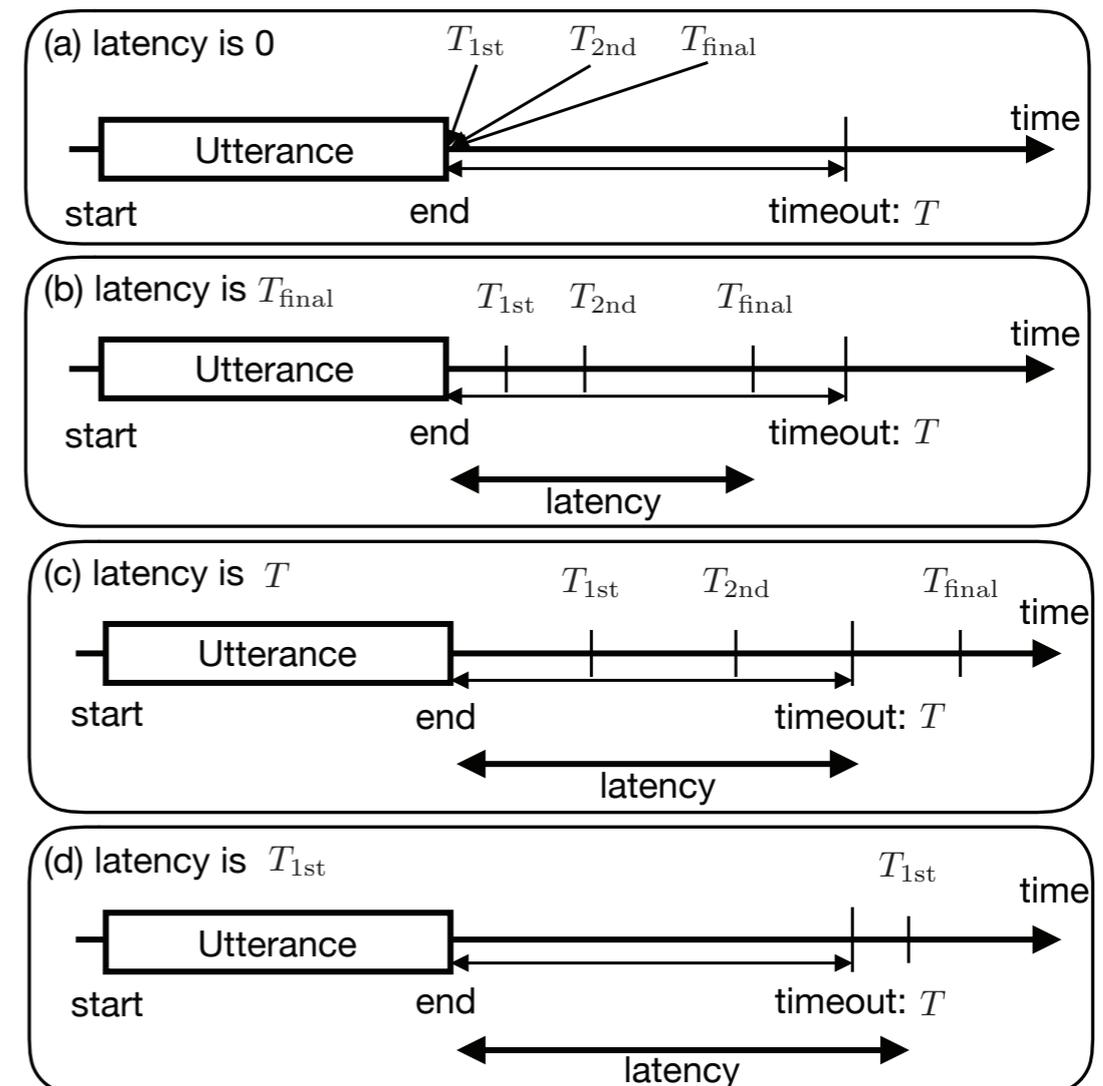
## ■ タイムアウトの導入

### ■ 単純タイムアウト

- ✳ 発話終了後，特定の時間内に届いた結果のみで尤度比較

### ■ 発話長に応じた可変型タイムアウト

- ✳ 固定値ではなく，発話長に応じてタイムアウトを設定

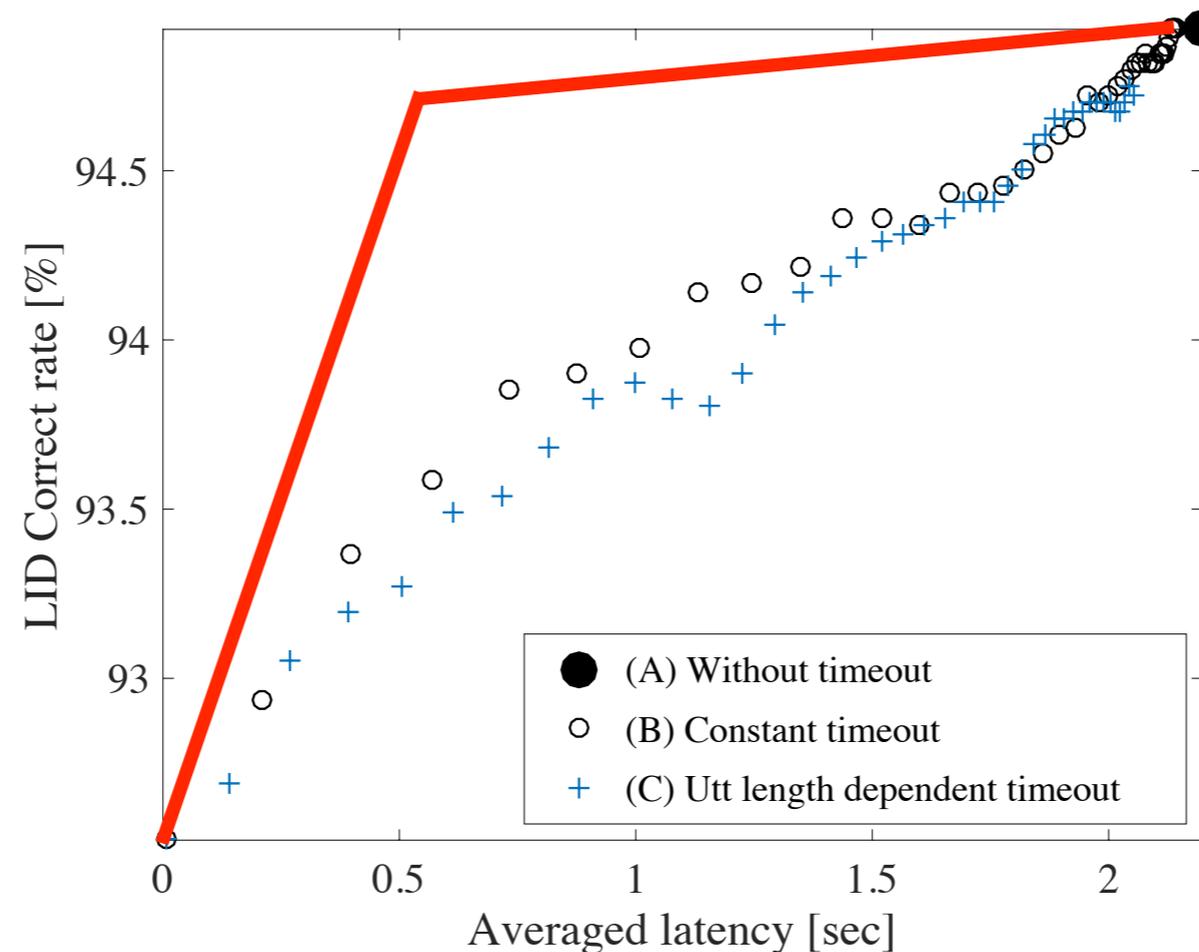


# Tradeoffs between accuracy and latency

## ■ 識別精度とレイテンシーのトレードオフ問題

### ■ タイムアウトを小さくすると識別精度劣化

=速いものを選択すればいいわけではない：何故か？



日英中3言語識別

目標：精度を保ちつつレイテンシーを小さくする方式の開発

# Proposed method

## ■ 速いものを選択すればよいわけでない理由

- 各認識器ごとに処理速度が異なる
- 速い認識器では言語が食い違っているにもかかわらず速く届く

	training data	vocablaly	averaged RTF
English (en)	370 h	262 k	0.47
Japanese (ja)	360 h	684 k	0.66
Chinese (zh)	560 h	213 k	0.27

言語 認識器	入力発話言語		
	en	ja	zh
en	0.42	0.92	0.90
ja	1.55	0.67	1.44
zh	0.58	0.72	0.28

SPREDSの平均RTF結果

単純タイムアウトでは、ある識別器ではタイムアウト時間が長過ぎて、レイテンシーの原因となるが、別の識別器では短過ぎて正解がドロップアウト

## ■ 各認識器の処理速度に応じた可変型タイムアウト

- 各認識器の平均リアルタイムファクターRTF(発話長と処理時間の比)を使用し、認識器ごとにタイムアウト長を設定
  - ✳ 平均RTFはモデルリリースの際、容易に取得可能

$$T_{vt,l} = \begin{cases} w_{vt}RTF_l L - L & (\text{if } w_{vt}RTF_l > 1) \\ 0 & (\text{elsewhere}) \end{cases} \quad \text{✳ } T_{vt,lang} < 0 \text{を防ぐため}$$

# Experiments

## ■ 日英中3言語識別実験

### ■ DNN型音声認識(MCML音声インタラクションSDKモデル)

✱ MFCC39次元(11フレーム=429次元)

✱ 隠れ層5, 512ノード

✱ 音素数 英: 39, 日: 26, 中: 30

### ■ 尤度を発話長で正規化

	training data	vocablaly	averaged RTF
English (en)	370 h	262 k	0.47
Japanese (ja)	360 h	684 k	0.66
Chinese (zh)	560 h	213 k	0.27

$$l = \arg \min_{l \in \{en, ja, zh\}} \left( \frac{S_{utt, l}}{L_l} \right)$$

### ■ テストセット

	en	ja	zh	$L_{avg}$ (sec)
BTEC	510	510	510	3.1
XTEC	1500	1500	912	4.6
VoiceTra	1726	5000	607	3.2
SPREDS	1133	1498	1501	6.5

読み上げ音声, 旅行会話, マイク収録

模擬対話, マイク収録

自然発話, スマホ収録, 雑音込

模擬対話, スマホ収録

### ■ 平均認識率

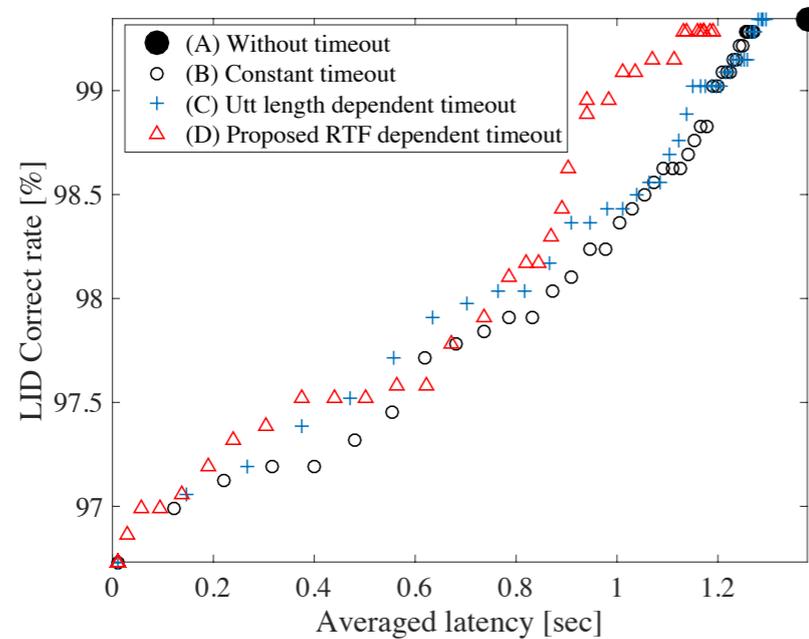
英: 90.96 %

日: 89.25 %

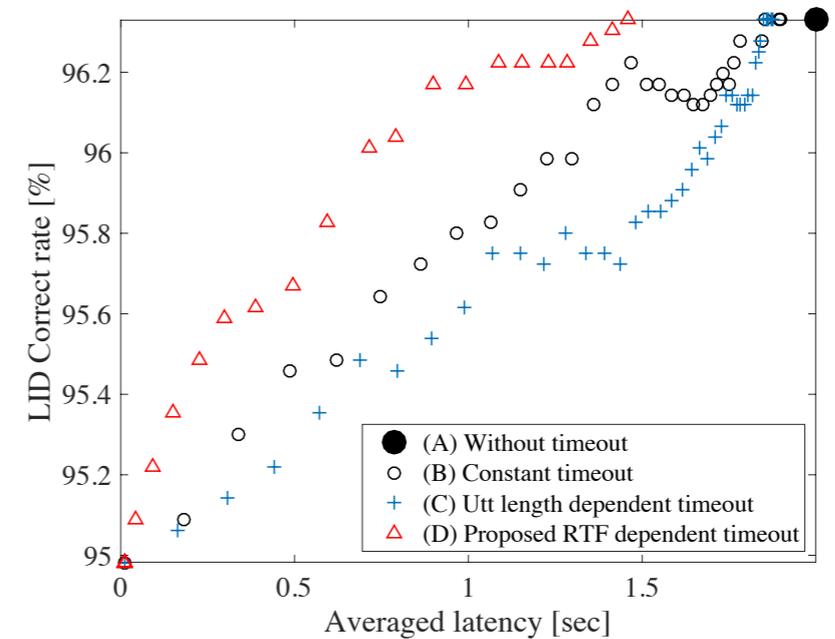
中: 79.89 %

# Results with BTEC, XTEC and VoiceTra

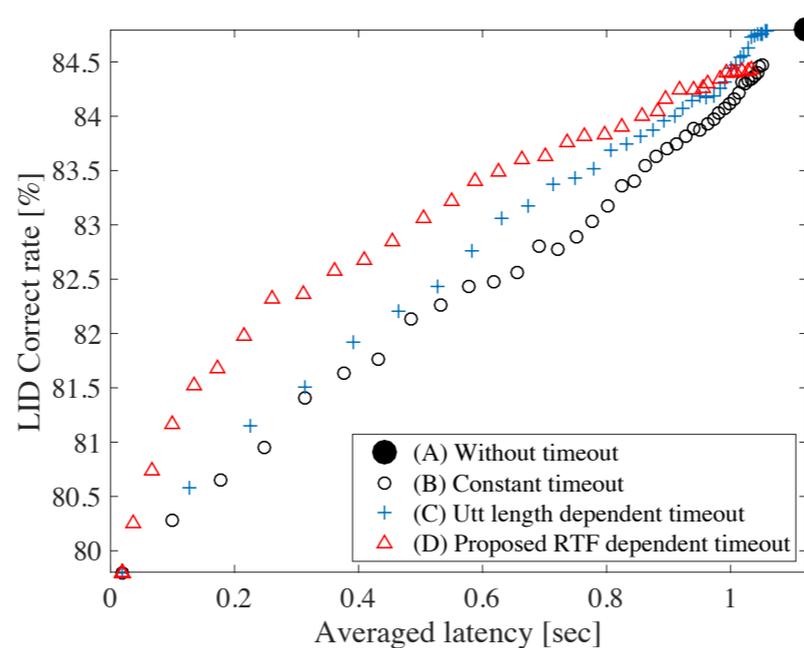
## 日英中3言語識別



BTEC



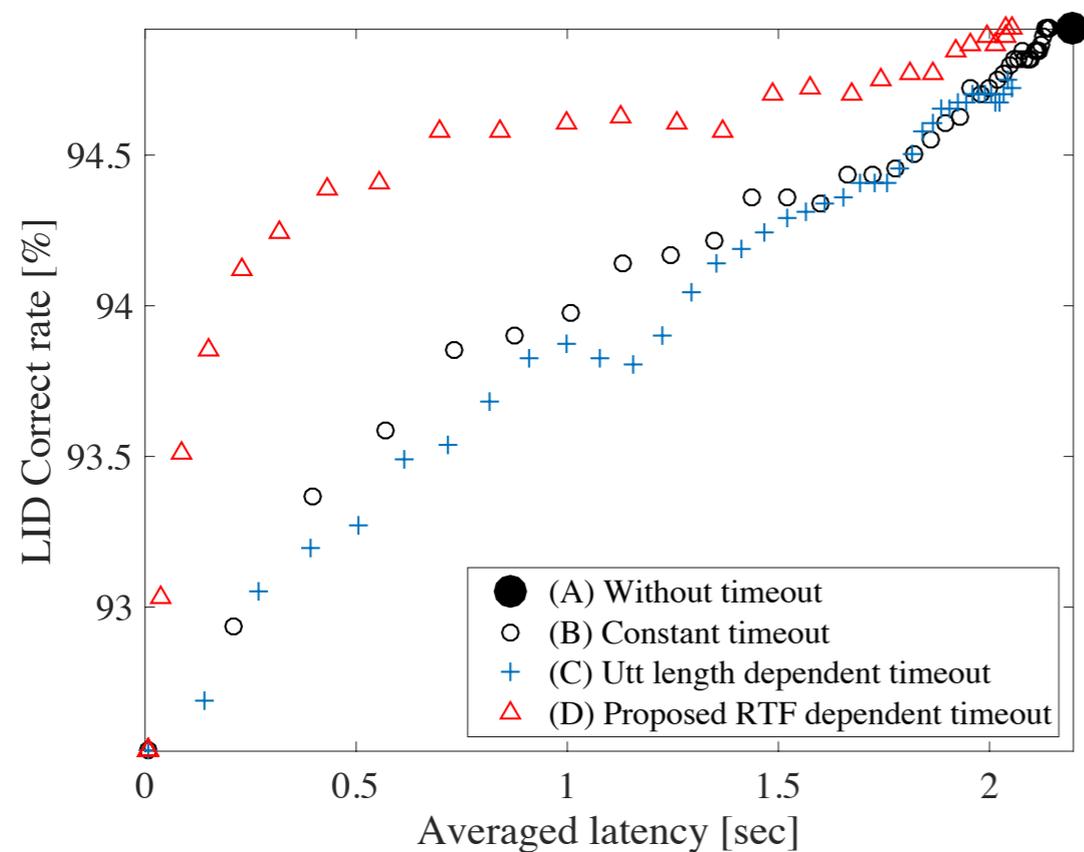
XTEC



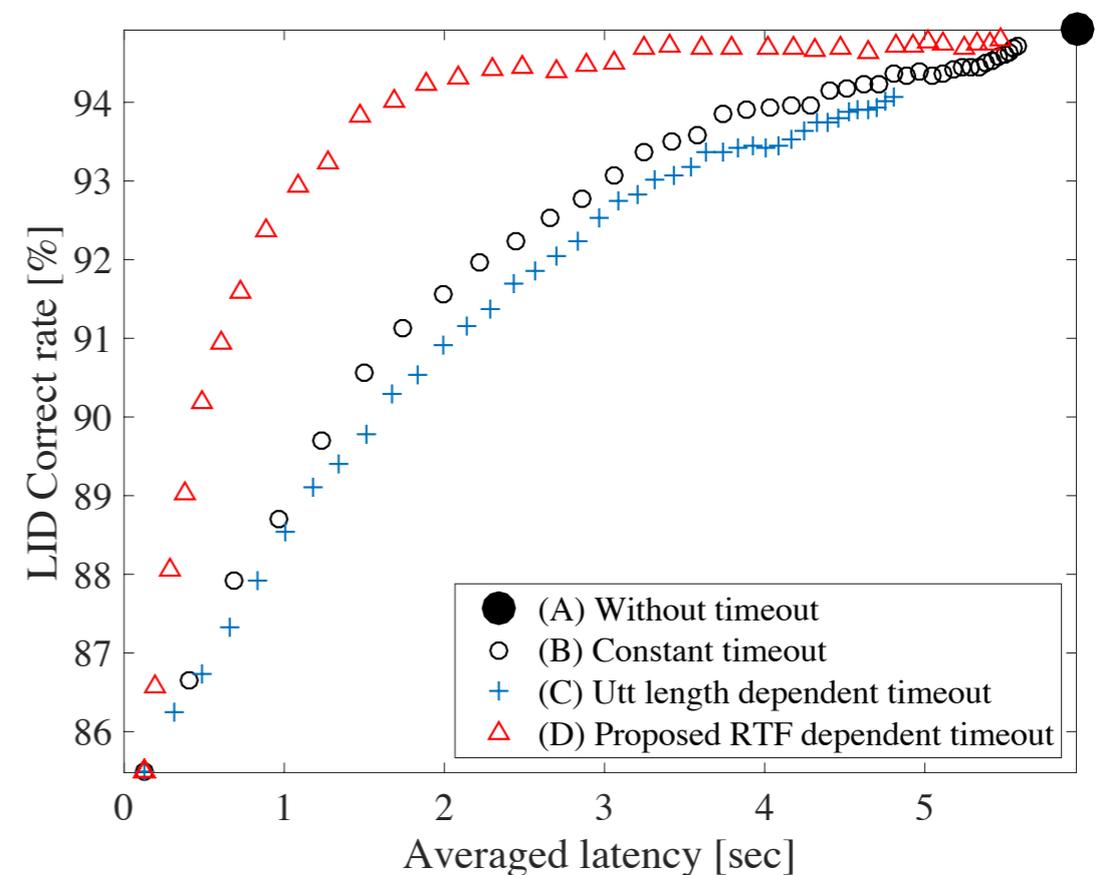
VoiceTra

# Results with SPREDS corpus

## 日英中3言語識別



実測結果



1.5倍処理時間がかかった場合  
(遅いマシンでの計算を再現)

精度を保ちつつレイテンシーを小さくする方式の実現

# Concluding remarks

---

- 尤度ベース言語識別における待ち時間短縮法の提案
  - 尤度ベース言語識別の有用性
  - 待ち時間問題と単純タイムアウトのトレードオフ
  - 平均RTFを用いたデコーダごとの可変タイムアウト方式の提案
  - 日英中3言語識別実験による提案法の有効性の確認