クラウド・テクノロジー活用部会活動報告
実践機械学習システム　音声編

2016年9月16日

先端IT活用推進コンソーシアム
クラウド・テクノロジー活用部会
富士通株式会社　松井　唯

機械学習の背景

- 機械学習では画像や自然言語に対する処理が盛ん

- 画像分野
  - Googleの猫
- 画像＋言語
  - 画像からの説明文生成

People play soccer

※この発表は個人の見解であり、所属する組織の公式見解ではありません

音響分野における機械学習

- 音響分野では音声認識に対する適用が研究
  - Siri
  - Google音声認識
  - ロボット対話

クラウド化により大量のデータを
処理可能となり性能向上

音響分野における機械学習

- 機械学習（特にDeepLearningの領域）では画像や自然言語に対する処理が盛ん
- 音声認識の分野も研究

- 「音声認識（文字の書き起こし）」以外の機械学習は注目度が低い

音声認識以外の適用先

- 環境音識別
  - ライフログ管理

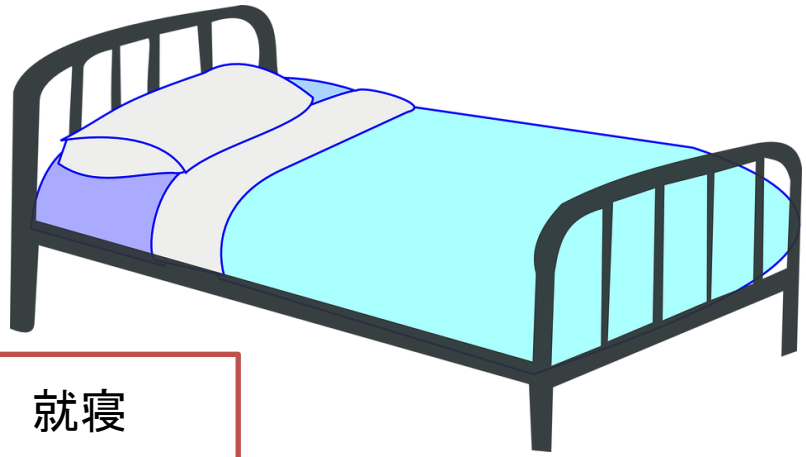

就寝

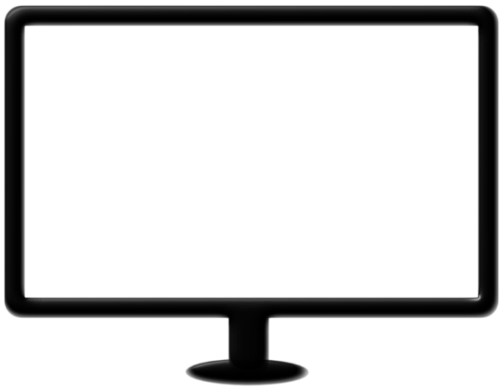

TVを視聴

人混みを歩行

音声認識以外の適用先

- 危険音認識
  - 子供，老人見守り

泣き声を検知し両親に連絡

一人暮らしのお年寄りが
倒れた音を家族に連絡

音声認識以外の適用先

- 話者識別

- その他にも
  - 音声合成，機械異常検査，音楽分類，感情分析 etc…

今回の実施内容

- 機械学習の足がかりとして音声を
  プログラムで取り扱う必要

- 機械学習と親和性の高いpythonでの
  音声の取り扱いをクラウド・テクノロジー活用
  部会で実践してみました

デモ

- 声でドアの鍵を開けるシステム

まではいたらなかったので

- 言っている合言葉があっていて，
  話者がそれっぽいかを判定するシステム

音声処理の流れ

1. 音声入力
↓ (共通部分)
2. 特徴量抽出
↓
3. 機械学習 (分野ごとに多様)

ソースコード

```
1.  from scikits.talkbox.features import mfcc
2.  import sys
3.  import numpy as np
4.  from scipy.io.wavfile import read
5.  import math
6.  argvs = sys.argv
7.  def calc_mfcc(data, fs):
8.          mfcc_data, trush, trush = mfcc(data, nwin=256, nfft=512,fs=fs,nceps=13)
9.          meanceps = np.zeros(mfcc_data[0].size)
10.         for mc in mfcc_data:
11.                 meanceps += mc
12.         return meanceps/mfcc_data[0].size
13. def build_model(datas):
14.     mue=np.zeros(len(datas[0]))
15.     sigma=np.zeros(len(datas[0]))
16.     for d in datas:
17.         mue = mue+d
18.     mue = mue/len(datas)
19.     for d in datas:
20.         sigma = sigma+(mue-d)*(mue-d)
21.     sigma = sigma/len(datas)
22.     return mue, sigma
23. def gausian(x,mue,sigma):
24.     delda = 0.001
25.     return 1/math.sqrt(2*math.pi*sigma+delda)*(math.exp(-1*pow(x-mue,2)/(2*sigma+delda)))
```

インポート

特徴量抽出

機械学習
モデル学習

ソースコード

```
26. def Likelihood_average(ary):
27.     ave=0
28.     for n in ary:
29.         ave+=n
30.     return n/len(ary)
31. def ditect(model_mue,model_sigma,target):
32.     likelihood = []
33.     for i in range(len(target)):
34.         likelihood.append(gausian(target[i],model_mue[i],model_sigma[i]))
35.     return Likelihood_average(likelihood)
36. def judge(val):
37.         if val > -2:
38.                 print "Open"
39.         else:
40.                 print "Close"
41. if __name__ == '__main__':
42.         mfccs = []
43.         fnames = ['hirake5.wav','hirake2.wav','hirake3.wav','hirake4.wav']
44.         target = argvs[1]
45.         for fname in fnames:
46.                 fs, data = read(fname,'rb')
47.                 mfccs.append(calc_mfcc(data, fs))
48.         mue, sigma = build_model(mfccs)
49.         trush, t_data = read(target,'rb')
50.         t_mfcc = calc_mfcc(t_data, fs)
51.         val=math.log10(ditect(mue, sigma, t_mfcc))
52.         judge(val)
```

機械学習
認識部分

入力等
メイン部分

計算フロー

1. モデル構築用ファイル読み込み
2. 特徴量抽出
3. モデル構築
4. 被判定ファイル読み込み
5. 特徴量抽出
6. モデルを使って尤度を算出
7. 尤度から最終判定

今回のデモの内部処理

- 入力 : scipy
- 特徴量抽出 : scikits.talkbox
- 機械学習(自作)

音声の入力

- C言語などではメモリ確保やファイルオープン，開放など大変

- Pythonの場合は一行で記述可能
  - scipy.io.read(ファイル名)

特徴量抽出

- MFCC（メル周波数ケプストラム係数）
  - 一般的に音声認識に用いられる特徴量
  - 人間の聴覚に基づいた特徴
- 計算手順
  1. FFT
  2. 高域強調
  3. メル軸射影
  4. フィルタバンク処理
  5. 離散コサイン変換

特徴量抽出

- scikits.talkboxを使うと
- 計算手順

1. ceps, mspec, spec = scikits.talkbox.feature(
   input, nwin=256, nfft=512, fs=fs, nceps=13)

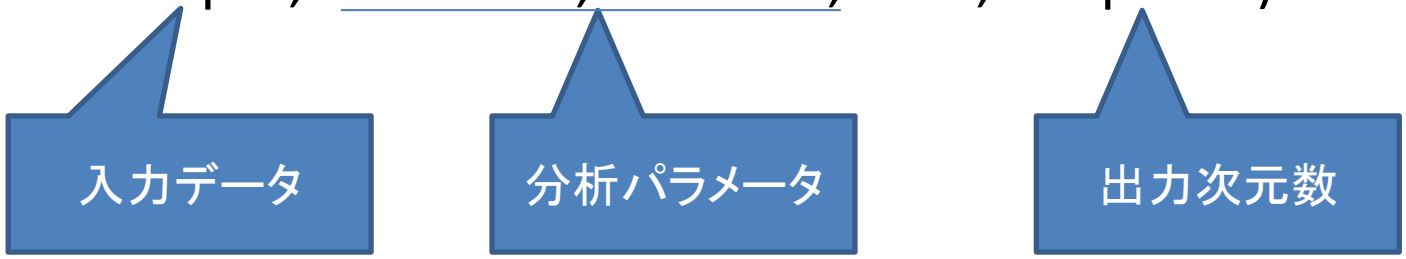

機械学習

- ４つの音声ファイルを元にMFCC算出
- １３次元それぞれに正規分布に従うモデルを学習
- 入力音声に対する尤度を計算

- ここはまだまだ工夫の余地がある

今回のデモの内部処理

- 入力や前処理はライブラリが行ってくれる
- 難しく，工夫のしがいがある学習部分だけを頑張れば良い
- 一番難しいところ
  - 環境構築：windows上でpythonを行うとライブラリが動かなかったり非常に困難

まとめ

- 音声認識以外でも音の機械学習の余地が多い
- 音声の特徴量にはMFCCが使用されている
- 実践機械学習を元に声を認識してみた
- 音声入力や特徴量抽出はpythonを使えば簡単