日本音響学会 北陸支部　ジョイント研究会資料

PCに於けるGoogle音声認識の利用

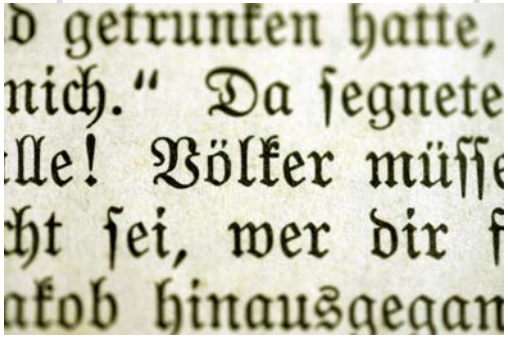

Google 日本

Wind-Craft（風工房）

- 山崎信久（ウィンドクラフト）
- 船田哲男（元金沢大）

音声認識の種類

方式	特定話者方式 （特定話者での学習が必要）		不特定話者方式 （学習不要）	
種類	連続認識	単語認識 （限定語認識）	連続認識	単語認識 （限定語認識）
例）	Windows搭載 ドラゴンスピーチ	音声コマンドTool	Julius AmiVoice Google音声認識	Julian(Julius統合)
用途例	口述筆記 翻訳	コマンド操作	口述筆記 翻訳	自動応答

Google音声認識：単語認識に近いが限定語ではない

音声認識の状況

不特定話者認識ソフト例

・Julius （京都大学等）

〇オープンソースで高速な認識

△辞書が固定

学習機能がないため認識率が向上しない

・AmiVoice （アドバンスド・メディア社製品）

〇実用的な変換速度と認識率
学習機能があり、認識率向上可能

△入力依存性が高い
ヘッドセット以外では認識率低下
開発者利用は困難

＊その他
翻訳ソフトの「超速通訳 ツージル」などもある。

AmiVoiceのデモ（メーカ）

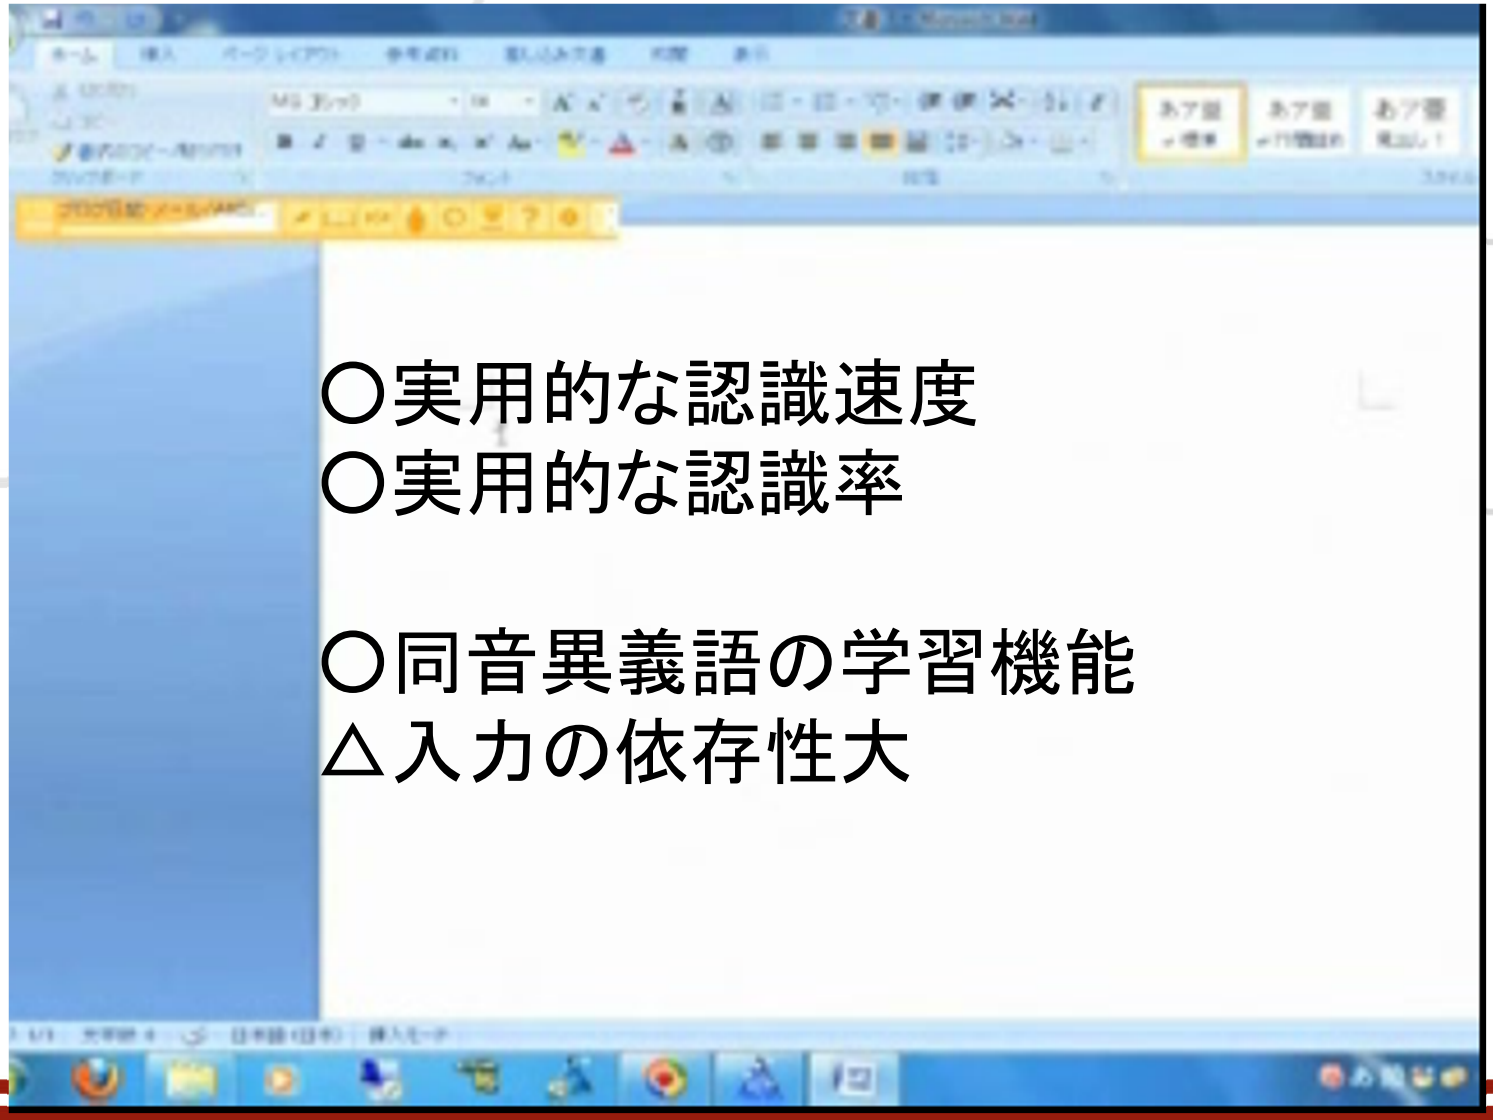

〇実用的な認識速度
〇実用的な認識率

〇同音異義語の学習機能
△入力の依存性大

Googleの音声認識の登場

・インフラの変化
　ネットワークの進歩（高速化）
　スマートホンの台頭（端末小型化）

・使用者の変化
　通信による情報参照
　キーボードレス時の入力手段

・Googleが音声認識を発表
　2009年にスマートホン向けから開始

Google音声認識デモ

〇実用的な認識率
　キーボードより高速な入力
〇入力の依存性小
　通常環境で良好な認識
△語句レベルでの認識
　長文に不向きだが検索には十分
△認識のタイムラグ
　話しながらの認識には不向き

Google音声認識（1）

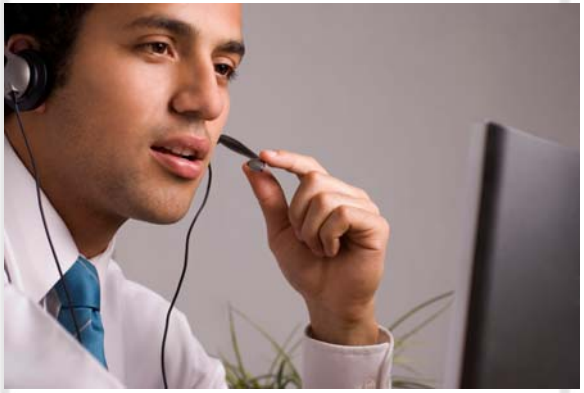

【経緯】
・2009年末Googleが発表
　スマートホン向けとしてiPhone・Android用に発表

【特徴】
・不特定話者認識（学習不要）
・実用的な認識率（検索で語彙の予測）

【条件】
・ネットワーク接続（要高速）

【ポイント】
サーバで認識する

・単語認識に近いが特定語ではない
（良く検索する語句は認識率が高い）
・速度は話す速度には追いつかない
（区切りが必要になる）

Google音声認識（2）

【スマートホンの状況】
iPhone：主に検索用のアプリとして提供されている
Android：上記以外に
・「音声認識インテント（入力ダイアログ風）」として開発利用可能
・IME版の開発によりどのアプリでも音声入力可能（ベータ）
google-voice-typing-integration
https://code.google.com/p/google-voice-typing-integration/source/browse/#git%2FVoiceImeDemo

【Googleの提供内容】
・**iPhone**
アプリ内部での利用のみ
（Googleの提供アプリのみの利用になる）

・**Android**
開発者が利用可能
音声認識をインテント（ダイアログ風）として呼び出し可能
IME版が利用可能
これによってあらゆる入力部分で利用可能
メモでも入力可能・ショートメールにも入力可能

Google音声認識（3）

【PCの状況】
・2011年春PC向けChromeに搭載

HTML5の音声入力拡張として動作

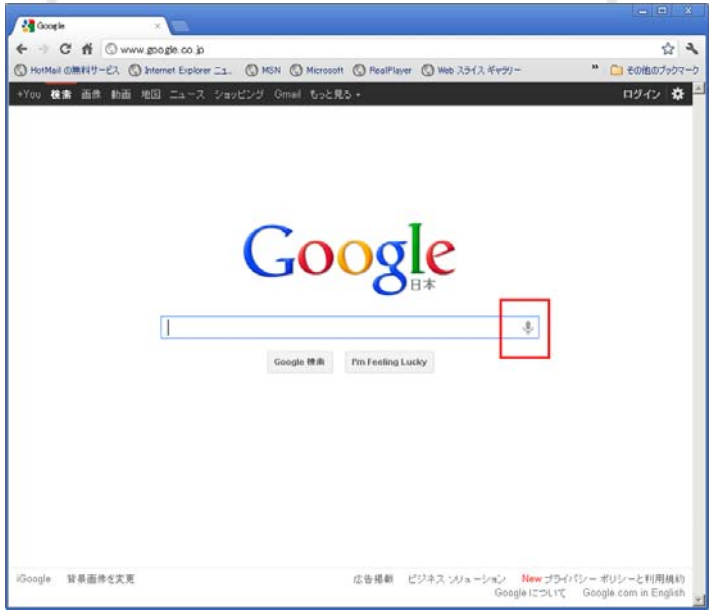

音声入力の手法）
HTMLで記述する。（HTML5）
<input x-webkit-speech type="text" />
で入力が扱える。
条件）
上のタグを解釈できるブラウザに限る。
現状はGoogleChromeのみ

そのままでは音声検索がしにくいので以下のエクステンションを入れる
Speakable Textareas
http://userscripts.org/scripts/show/108011

スマートホンと同じ環境の実現

GoogleChromeデモ

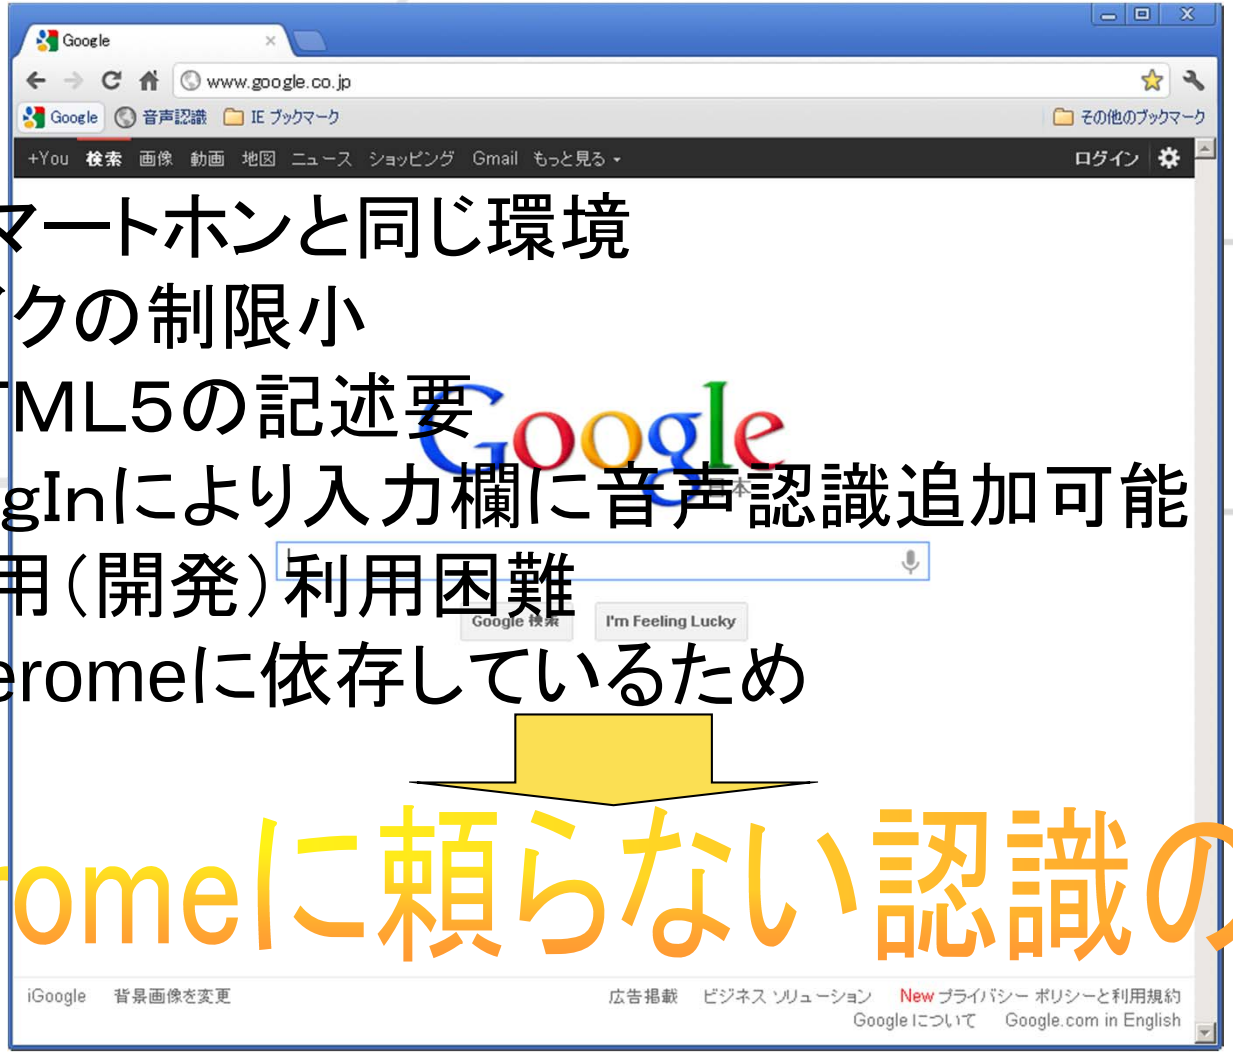

○スマートホンと同じ環境
　マイクの制限小
△HTML5の記述要
　PlugInにより入力欄に音声認識追加可能
×応用（開発）利用困難
　Cheromeに依存しているため

Chromeに頼らない認識の実現

アプリケーションの現状（1）

OSAPIからWebAPIへ

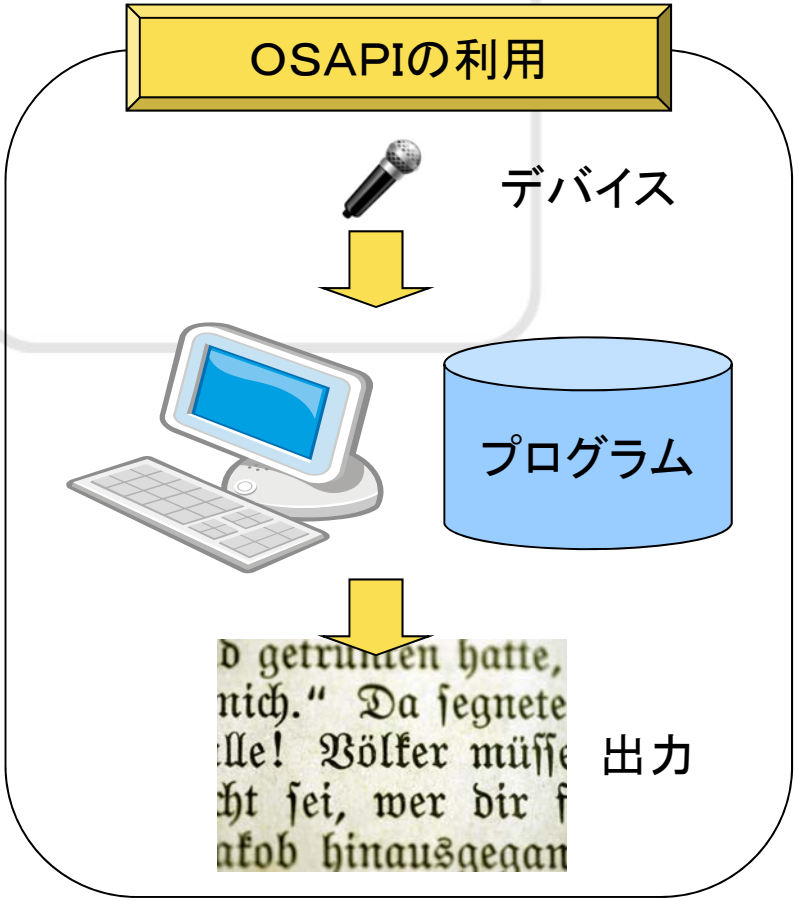

構成）
処理はすべてOS上のプログラムで処理される。
長所）
　ネットワーク接続が不要である
短所）
・処理能力がPCで決まる
・複雑なプログラムでは多くの知識を必要とする
　開発分量が膨大になる
　専門知識が必要になる
・OSによる依存性が高い
　機種への移植が煩雑

アプリケーションの現状（2）

OSAPIからWebAPIへ

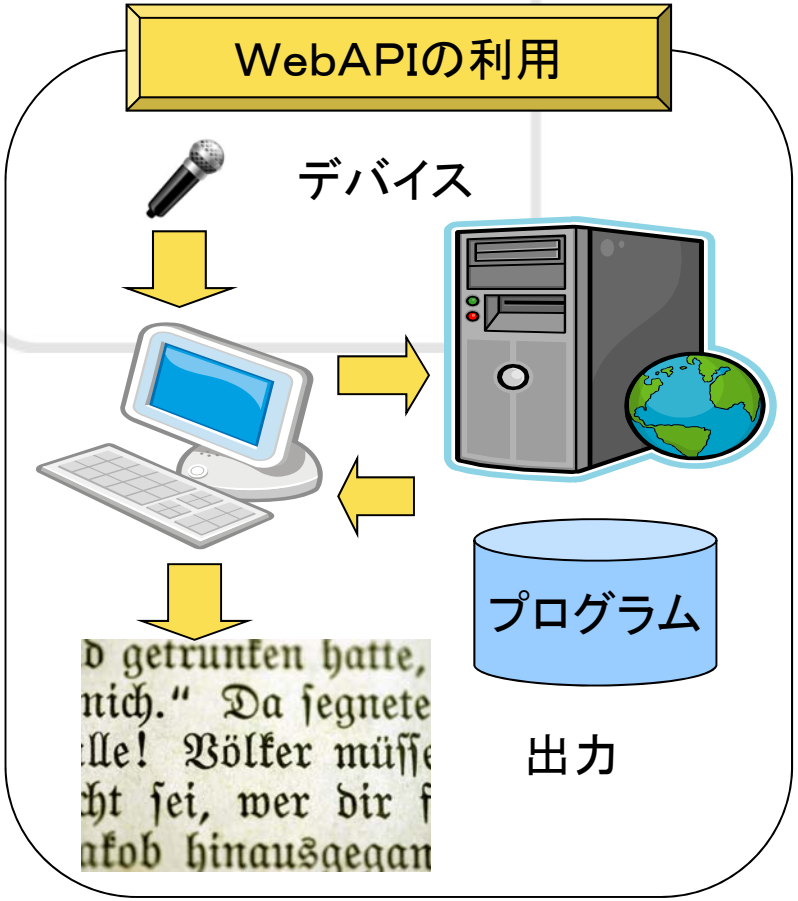

構成）
処理の中核はサーバ上のプログラムで処理される。
長所）
・PCの処理能力に依存しない
・複雑なプログラムが不要
　パラメータを送信し結果を受け取る
・OS依存性が低い
　HTTP通信があれば可能
短所）
・ネットワークが必須になる
　パラメータによっては高速必須
・中身はブラックボックス
　プログラムは相手次第

WebAPIの例（1）

例1）
住所の地図を表示する（金沢大学の住所）
http://maps.google.co.jp/maps?q=石川県金沢市角間町&hl=ja

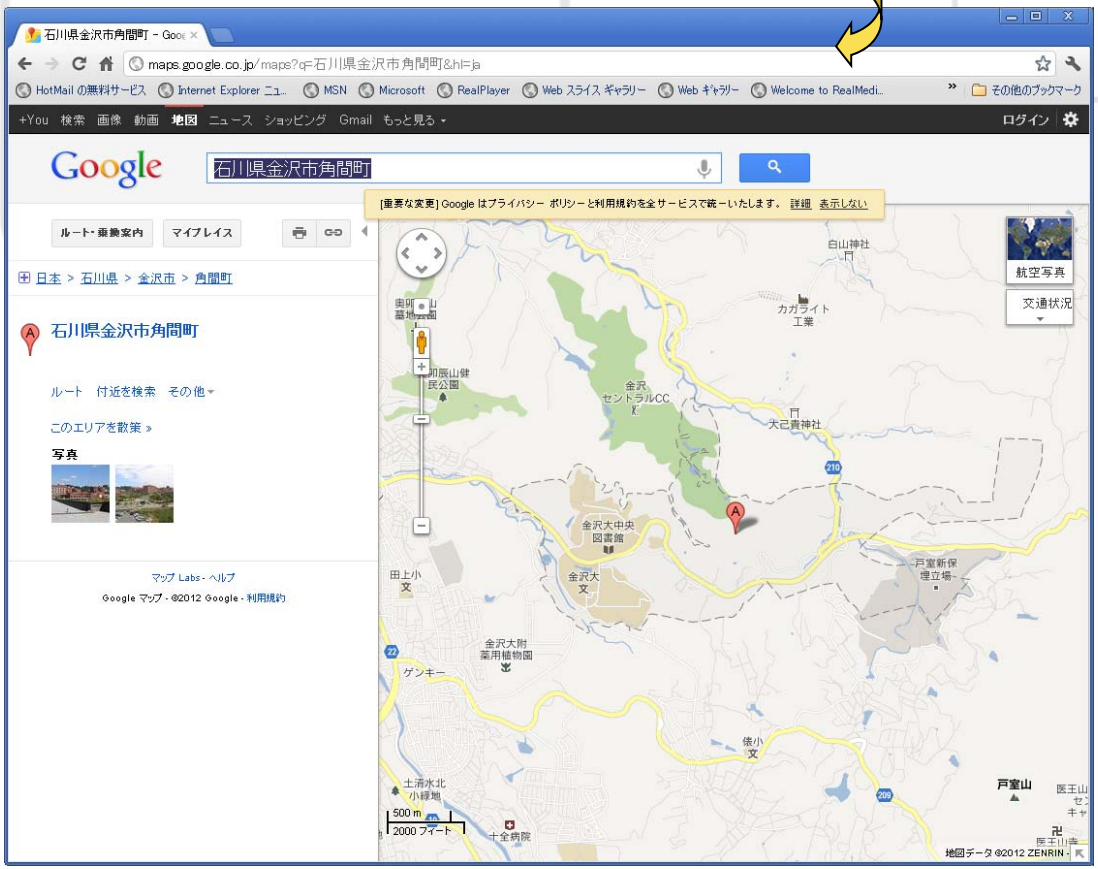

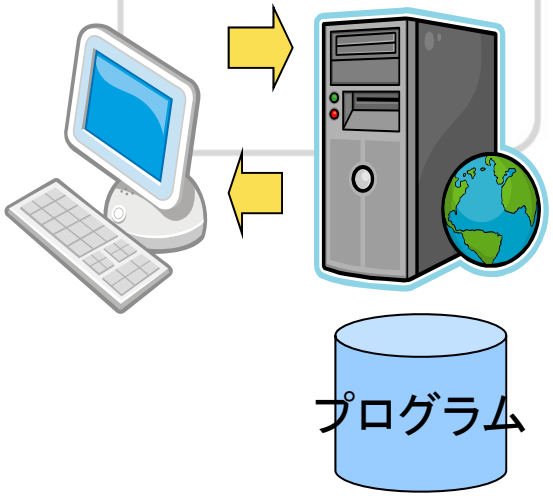

WebAPIの例（2）

例2）
TTS（テキストの読み上げ）
http://translate.google.com/translate_tts?tl=ja&q=こんにちは、船田先生

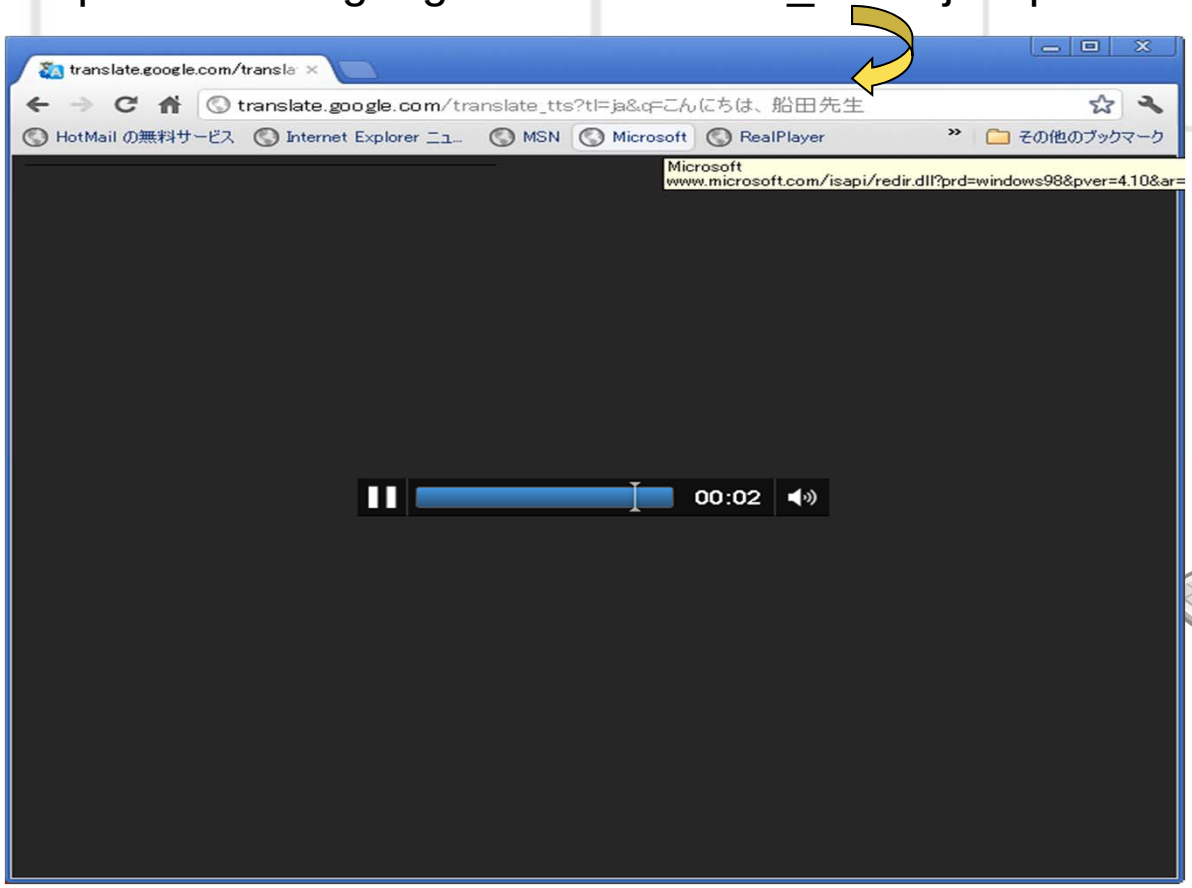

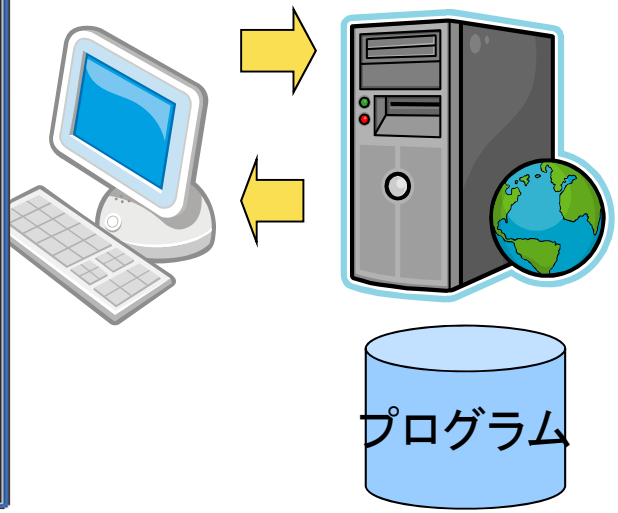

WebAPIの使い方まとめ

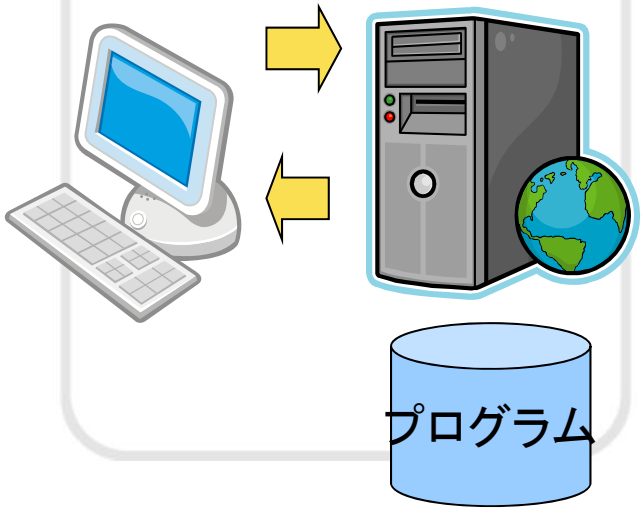

入力）
GETやPOSTで特定のURLに通知する
出力）
結果として定められた形式で出力される
例）
・地図
　入力：住所や緯度経度（座標）など
　出力：画像やマーカ
・TTS（読み上げ）
　入力：テキスト（＋言語）
　出力：mp3形式のファイル

【WebAPIの特徴】
・基本はブラウザを前提としている
　記述はHTMLやJavaScriptで行う。
　HTMLも時代に応じて拡張がなされている（HTML5）
・ローカルPCのプログラムでも
　GET／POSTでHTTP通信を行うことでパラメータを送信できる
　返答された結果を処理することで、プログラムとして動作できる

WebAPIのデモ


石川県金沢市角間町 - Goo
maps.google.co.jp/maps?q=石川県金沢市角間町&hl=ja
HotMail の無料サービス
Internet Explorer ニュ...
MSN
Microsoft
RealPlayer
その他のブックマーク
+You 検索 画像 動画 地図 ニュース ショッピング Gmail もっと見る
ログイン
Google
石川県金沢市角間町
[重要な変更] Google はプライバシー ポリシーと利用規約を全サービスで統一いたします。 詳細 表示しない
ルート・乗換案内
マイプレイス
日本 > 石川県 > 金沢市 > 角間町
石川県金沢市角間町
ルート 付近を検索 その他
このエリアを散策 »
写真
マップ Labs - ヘルプ
Google マップ - ©2012 Google - 利用規約
航空写真
交通状況
金沢セントラルCC
大己貴神社
金沢大中央図書館
500 m
2000 フィート
地図データ ©2012 ZENRIN
www.google.co.jp/shopping?q=石川県金沢市角間町&hl=ja&tab=lf

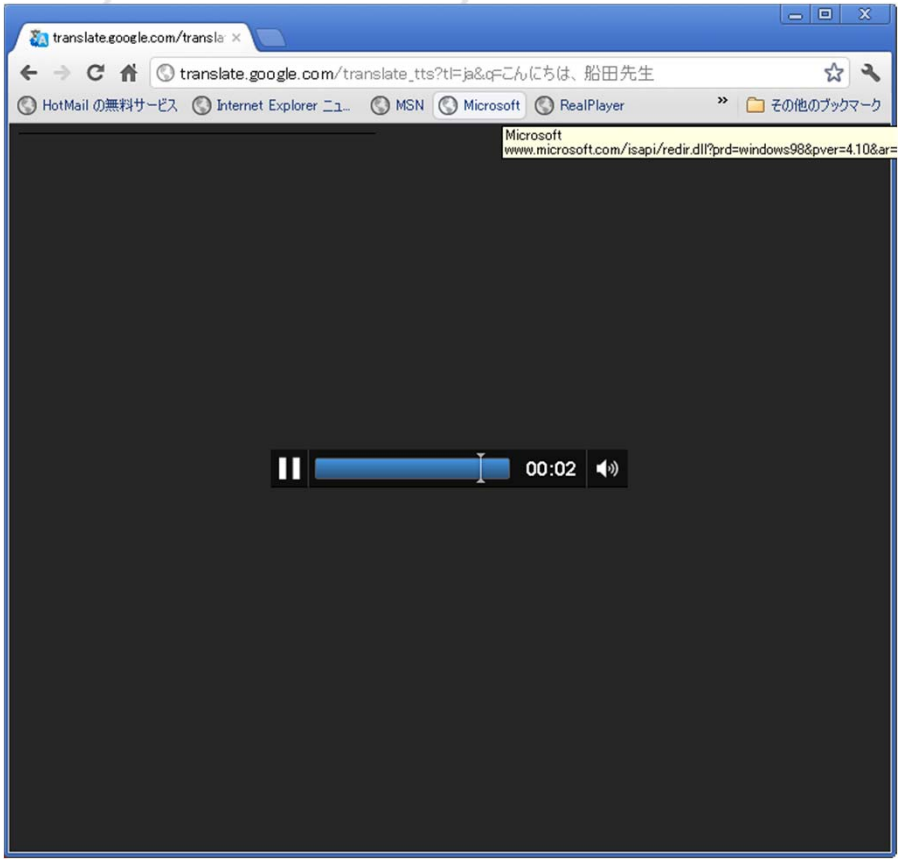
translate.google.com/transla
translate.google.com/translate_tts?tl=ja&q=こんにちは、船田先生
HotMail の無料サービス
Internet Explorer ニュ...
MSN
Microsoft
RealPlayer
その他のブックマーク
Microsoft
www.microsoft.com/isapi/redir.dll?prd=windows98&pver=4.10&ar=
00:02

PCに於けるGoogle音声認識（1）

【Chromeの動作分析】
・HTML5の構文解釈
音声入力→音声をサーバに
入力表示←サーバから結果受信

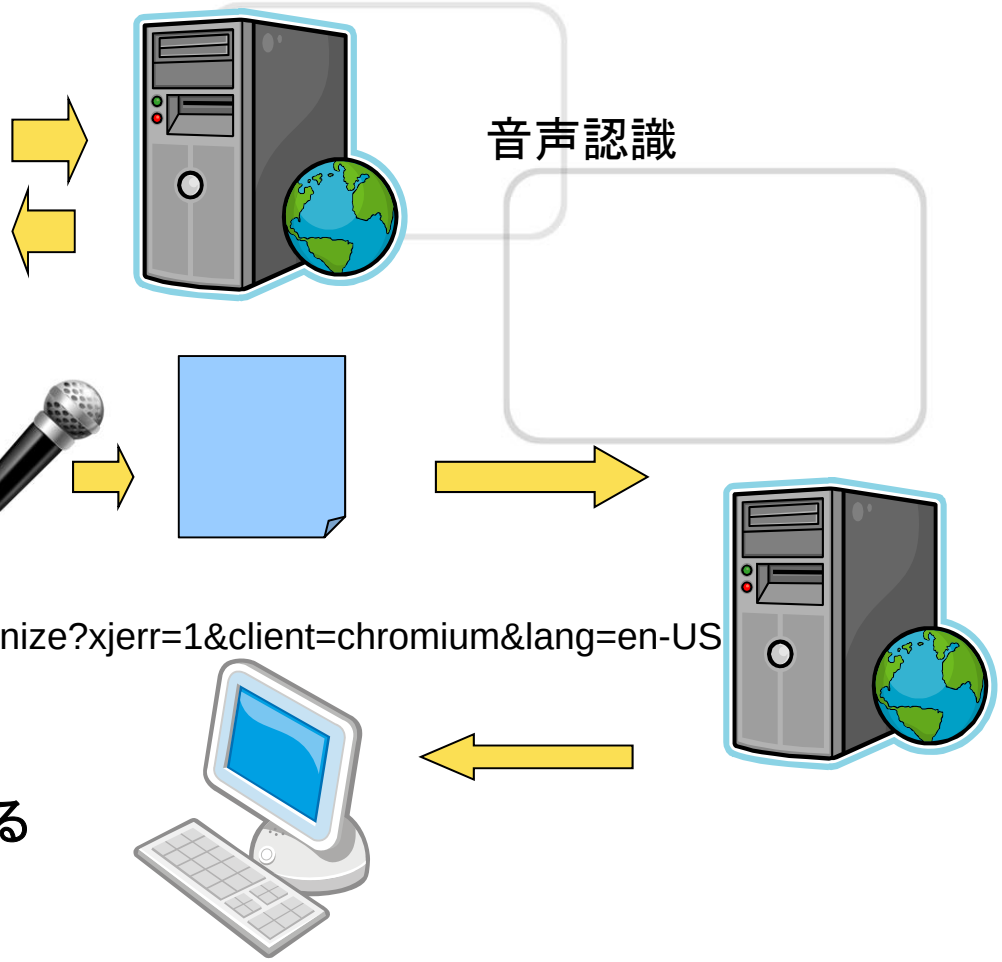

【具体的な内部動作】
・マイクから音声データを生成
（音声ファイル化する）

・それを以下にPOSTする
https://www.google.com/speech-api/v1/recognize?xjerr=1&client=chromium&lang=en-US
（引数に関しては後述する）

・認識結果はJSON形式で返答される
（結果の内容に関しては後述する）

原理サイト
http://mikepultz.com/2011/03/accessing-google-speech-api-chrome-11/

PCに於けるGoogle音声認識（2）

【技術内容】

1）音声入力をファイルにする

語句を区切るため「無音検出」で区切る
ファイル形式はflacまたはSpeex形式(flac形式が無難)
サンプリングレートは8KHzまたは16KHz。
16KHzのflacの時Content_Typeは"audio/x-flac; rate=16000"を指定することでGoogleに通知。

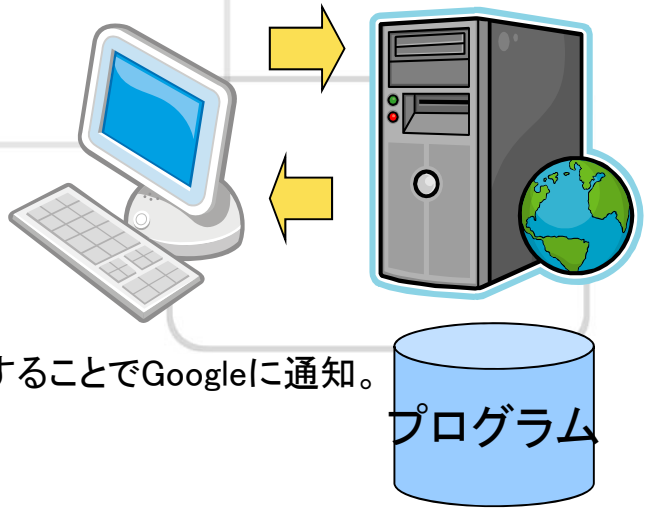

2）音声ファイルをURLにPostする

引数は言語指定（英語はlang=en-US,日本語はlang=ja-JP）候補数指定（maxresult=10）などがある。

3）結果をJSON形式で受け取る

結果はstatus（0以外は認識できず）id（順序判定用）に候補指定の分以下が付属する。
hypotheses（予測）：utterance（発声）が認識結果、confidence（信頼性）が確からしさ。

解説サイト
http://sebastian.germes.in/blog/2011/09/

PCに於けるGoogle音声認識（3）

【応用例】

IEでの音声認識

1）音声入力ファイル作成

入力からFlashにてwavファイル作成

中継サーバにてwav形式をflac形式に変換

2）音声ファイルのPost

中継サーバからPHPでGoogleにPost。

3）結果を受け取る

中継サーバで結果のトークンを受け取りFlashに通知。

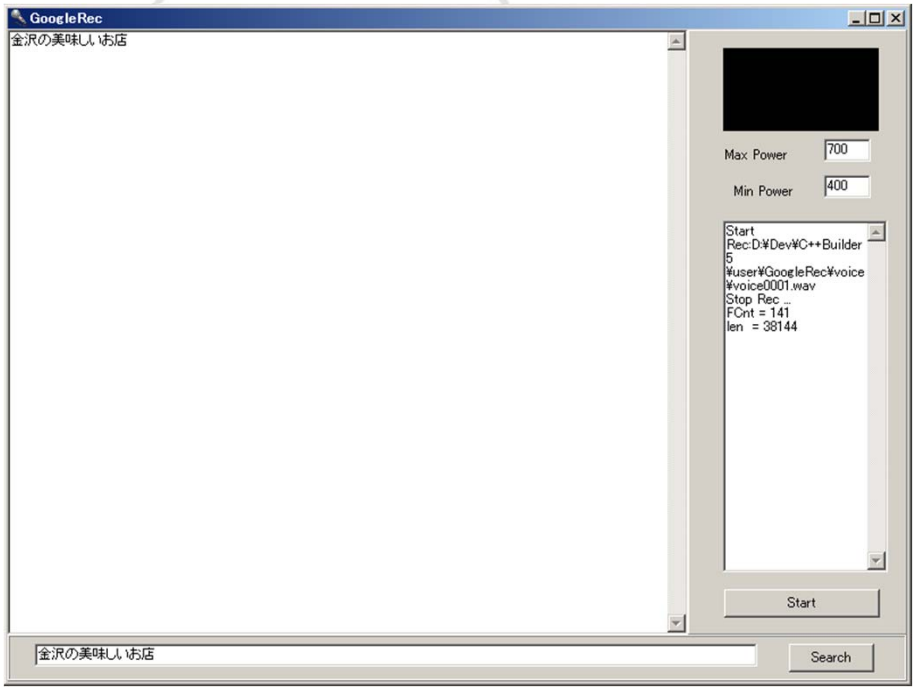

作成ソフトのデモ

IEデモサイト

http://select-items.net/pfu/google/speech/

終わりに（まとめ）

スマートホンの発達（PC+モバイル）

ネットワークの発達（常時接続＆高速化）

・機種依存性の少ない開発
  HTML＋JavaScript
  またはそれに類する通信＋処理
・WebAPIの活用が加速
  通信前提のアプリケーション開発
  複雑な内容はサーバがサービス提供
例）音声認識・音声合成・翻訳・ OCR・地図．．．

Google 日本