

(19) 日本国特許庁(JP)

## (12) 公開特許公報(A)

(11) 特許出願公開番号

特開2005-115386

(P2005-115386A)

(43) 公開日 平成17年4月28日(2005.4.28)

(51) Int.Cl.<sup>7</sup>

F 1

テーマコード(参考)

**G10L 15/28**

G10L 3/00

561A

5D015

**G10L 15/10**

G10L 3/00

531F

**G10L 15/14**

G10L 3/00

535A

**G10L 15/18**

G10L 3/00

537H

審査請求 未請求 請求項の数 14 O L 外国語出願 (全 20 頁)

(21) 出願番号 特願2004-294232 (P2004-294232)  
 (22) 出願日 平成16年10月6日 (2004.10.6)  
 (31) 優先権主張番号 03022646.8  
 (32) 優先日 平成15年10月6日 (2003.10.6)  
 (33) 優先権主張国 欧州特許庁 (EP)

(71) 出願人 598094506  
 ソニー インターナショナル (ヨーロッパ) ゲゼルシャフト ミット ベシェレンクテル ハツツング  
 ドイツ連邦共和国 10785 ベルリン  
 ケンパークラッツ 1  
 (74) 代理人 100067736  
 弁理士 小池 晃  
 (74) 代理人 100086335  
 弁理士 田村 榮一  
 (74) 代理人 100096677  
 弁理士 伊賀 誠司

最終頁に続く


(54) 【発明の名称】誤認識予測方法

## (57) 【要約】

【課題】 入力音声信号(2)における変動は信号(2)が音声信号であるか非音声イベントであるかによって異なるという洞察に基づいた誤認識予測方法を提案する。

【解決手段】 この誤認識予測方法は、音声信号を入力するステップ(S1)と、入力音声信号(2)の少なくとも1つの信号変動特性を抽出するステップ(S2)と、入力音声信号に信号変動メタを適用して信号変動尺度を導出するステップ(S5)とを有する。

【選択図】 図2



**【特許請求の範囲】****【請求項 1】**

音声認識システムにおいて誤認識を予測する誤認識予測方法において、  
音声信号を入力するステップと、  
上記入力音声信号の少なくとも 1 つの信号変動特性を抽出するステップと、  
上記入力音声信号に対して信号変動メータを適用して信号変動尺度を導出するステップ  
とを有する誤認識予測方法。

**【請求項 2】**

上記信号変動メータは、上記入力音声信号の部分語に適用されることを特徴とする請求  
項 1 に記載の誤認識予測方法。 10

**【請求項 3】**

上記入力音声信号の 2 つ以上の部分語から導出された信号変動尺度を組み合わせて、信  
頼度尺度を形成することを特徴とする請求項 2 に記載の誤認識予測方法。

**【請求項 4】**

上記入力音声信号の 2 以上の部分語から導出された信号変動尺度の組合せは、相加平均  
、相乗平均、最大値、最小値、あるいは分散尺度に基づくことを特徴とする請求項 3 に記  
載の誤認識予測方法。

**【請求項 5】**

上記分散尺度は、範囲、標準偏差又は相対分散であることを特徴とする請求項 4 に記載  
の誤認識予測方法。 20

**【請求項 6】**

上記信号変動メータは、ユニークステート比の評価に基づくことを特徴とする請求項 1  
乃至 5 のいずれか 1 項に記載の誤認識予測方法。

**【請求項 7】**

上記信号変動メータは、同ーステート比の評価に基づくことを特徴とする請求項 1 乃至  
6 のいずれか 1 項に記載の誤認識予測方法。

**【請求項 8】**

上記信号変動メータは、ユニークステートエントロピーの評価に基づくことを特徴とす  
る請求項 1 乃至 7 のいずれか 1 項に記載の誤認識予測方法。

**【請求項 9】**

上記信号変動メータは、平均スペクトル変動の評価に基づくことを特徴とする請求項 1  
乃至 8 のいずれか 1 項に記載の誤認識予測方法。 30

**【請求項 10】**

上記信号変動メータは、スペクトル不一致距離の評価に基づくことを特徴とする請求項  
1 乃至 9 のいずれか 1 項に記載の誤認識予測方法。

**【請求項 11】**

上記信号変動メータは、ステート長单一比の評価に基づくことを特徴とする請求項 1 乃  
至 10 のいずれか 1 項に記載の誤認識予測方法。

**【請求項 12】**

上記信号変動特性の抽出は、上記入力音声信号から取り出されたスペクトル特性に基づ  
くことを特徴とする請求項 1 乃至 11 のいずれか 1 項に記載の誤認識予測方法。 40

**【請求項 13】**

上記信号変動特性の抽出は、さらに、音声認識仮説ベースの隠れマルコフモデルによる  
音素配列に基づくことを特徴とする請求項 1 2 に記載の誤認識予測方法。

**【請求項 14】**

音声認識システムにおける入力音声信号に関する認識仮説のための信頼度尺度を定める  
コンピュータソフトウェア製品において、

請求項 1 乃至 13 のいずれか 1 項に記載の誤認識予測方法を実行するようなデータ処理  
手段により処理される一連の状態要素により構成されることを特徴とするコンピュータソ  
フトウェア製品。 50

**【発明の詳細な説明】****【技術分野】****【0001】**

音声認識システムにおいて、一音一音はっきりと発音された (articulated) 音声又は発話は、それぞれの音声信号を解釈することによって、それぞれ書き言葉 (written language) に変換される。最新技術の音声認識システムの場合でも、雑音の多い環境で使用すると、通常、認識エラーと呼ばれる誤解釈が起こることが多い。入力音声信号に重畠された周囲の雑音は、入力信号の特性を変化させ、あるいは音声認識装置によって誤って音素として解釈されてしまう。

**【背景技術】****【0002】**

誤認識が起こったことを検出するためには、所謂信頼度尺度 (confidence measure) が用いられる。信頼度尺度とは、ある単語又は部分語 (sub-word) が音声信号の特定部分に対応するときの信頼度を判定するものである。そして、単語又は部分語は、算出された信頼度尺度に基づき、認識処理において容認され又は拒否される。

**【0003】**

様々な種類の言葉による表現 (expression) が非常に類似した音声を有するので、ある発話の解釈として幾つかの選択肢がある場合が多い。いずれか1つを特定するには、例えば、信頼度尺度を、ある表現がそれぞれの発話に対応する尤度として計算する。これは通常、何らかの特別な統計的仮説検定により行われる。これらの処理は、通常、非常に複雑であり、特に、ある音素が隣接した音素の影響によって音響的変動を生じる可能性がある場合、すなわち同時調音 (coarticulation) として知られる効果がある場合は複雑である。

**【0004】**

また、上述の音声信号に重畠した周囲の雑音のような非音声イベント (non-speech event) も、音声信号に音響的変動を生じる。したがって、音声信号を書き言葉と同等なものに変換するための単語又は部分語の正しい認識処理は、煩雑な作業であり、満足な解決策は未だ得られていない。

**【発明の開示】****【発明が解決しようとする課題】****【0005】**

したがって、本発明の目的は、音声認識システムにおける認識エラーの検出を改善する方法を提案することである。

**【課題を解決するための手段】****【0006】**

上述の目的は、独立請求項に定める発明により達成される。

**【0007】**

音声信号の特性は、例えば、周囲の雑音やノイズバースト等の非音声信号の特性とは非常に異なる。非音声信号と異なり、音声信号は、準周期的に、比較的小さく変動するという性質を有する。このため、入力音声信号の通常安定している部分に急激な変化や大幅な変動があれば、非音声成分が存在する可能性が高い。

**【0008】**

この洞察に基づいて上述の目的を達成するために、本発明に係る誤認識予測方法は、音声認識システムにおいて、音声信号を入力するステップと、入力音声信号の少なくとも1つの信号変動特性を抽出するステップと、入力音声信号に対して信号変動メータを適用して信号変動尺度を導出するステップとを有する。

**【0009】**

さらに、上述の目的を達成するために、本発明は、音声認識システムにおける入力音声信号に関する認識仮説のための信頼度尺度を定めるコンピュータソフトウェア製品を提供する。このコンピュータソフトウェア製品は、本発明に係る誤認識予測方法を実行して信

10

20

30

40

50

頼度尺度評価システムを形成するようにデータ処理手段により処理される一連の状態要素により構成される。

【0010】

本発明の更なる有利な特徴については、各従属請求項に記載している。

【0011】

信号変動メータは、以下に説明するように、入力音声信号の部分語、特に、フレーム、ステート又は音素に適用することが有利である。有利な展開によれば、入力音声信号の2以上の部分語から導出された信号変動尺度を組み合わせて、信頼度尺度を形成する。ここで、入力音声信号の2以上の部分語から導出された信号変動尺度の組合せは、好ましくは、相加平均、相乗平均、最大値、最小値、あるいは分散尺度に基づくものであり、分散尺度は、範囲、標準偏差又は相対分散により形成される。10

【0012】

信号変動メータは、ユニークステート比 (Unique State Ratio)、同ーステート比 (Same State Ratio)、ユニークステートエントロピー (Unique State Entropy)、平均スペクトル変動 (Average Spectral Variation)、スペクトル不一致距離 (Spectral Mismatch Distance) 又はステート長单一比 (State Length One Ratio) を評価し、あるいはこれらの2つ以上を組み合わせると、効果的である。

【0013】

本発明の更なる好ましい実施例では、信号変動特性の抽出は、入力音声信号から導出したスペクトル特性に基づくものとすることにより、信号変動特性の抽出は、隠れマルコフモデルベースの音声認識仮説の音素配列に、十分に基づくことができる。20

【発明を実施するための最良の形態】

【0014】

以下、図面を参照して、本発明の実施例を詳細に説明する。

【0015】

図1は、時間の経過に対する入力音声信号2振幅の一部を示す波形図である。入力音声信号2は、音素の境界4、4'により互いに分離された幾つかの音素3、3'、3''に分割される。音素は、例えば「b」を「p」と区別するような最小の単語を識別できる信号として特徴付けられる音声である。これは、例えば音節等の部分語 (sub-word) を既に表している場合もあるが、通常はもっと小さい単語成分である。この明細書においては、部分語という用語は、限定的なものではなく、音声として又は書き言葉として表現した場合の単語の一部を表すものである。30

【0016】

音声認識処理では、各音素が、所謂ステート (states)  $5_1$ 、 $5_2$ 、 $5_3$  及び  $5'_1$ 、 $5'_2$ 、 $5'_3$  等に細分化され、各ステートが更にフレーム6又は6' と呼ばれる小さい解析単位に細分化される。認識処理では、記録している信号の波形 (以下、記録信号波形という。) からステート  $5_2$  内の入力信号に一致しているものを探索する。通常、完全に一致した波形は存在せず、すなわち、記録信号波形は、各ステート  $5_2$  の1つ以上のフレーム6内の入力音声信号2からずれている。したがって、様々な記録信号波形をステート  $5_2$  内の入力音声信号2と比較して、そのステート  $5_2$  内に存在するフレーム6に基づいて一致するものを検出する。したがって、様々な記録信号波形がステート  $5_2$  の各フレーム6内においてそれぞれ最も一致する可能性がある。これを図1に示すが、ここでは各記録信号波形が指示符号7で示されている。記録信号波形番号「17」は、ステート  $5_2$  の1番目、4番目及び最後フレーム6においてよく一致し、記録信号波形番号「5」は、2番目、3番目及び5番目のフレームにおいて最も一致する。最後から3番目のフレームは、記録信号波形番号「20」と一致し、最後から2番目のフレームは番号「21」と一致する。40

【0017】

ステート  $5_2$  のレベル内の記録している信号からの上述の入力音声信号2のずれ (deviation) は、例えば背景雑音の侵入や話者の気分の変化等、非音声イベントにより生じる50

ことが多い。このため、完全に一致することは殆どなく、ある程度の変動 (variation) や不確実性を伴う。最も一致した場合であっても、間違っている可能性はある程度残る。

#### 【0018】

信頼度尺度 (confidence measure system) 方式の精度を向上させるために、本発明では、検出された各候補 (match) の信頼度の特徴付け (characterisation) を行う。この特徴付けには、検出された各候補の信頼度を評価するための仮説を導き出す。仮説では、ある候補がおそらく正しいか誤っているかについてのステートメント (statement) を作成する。ステートメントは、通常、音声認識システムの後続の処理を簡単にするために、数値という形態をとる。仮説の値は、例えば、非常に確実な (very certain)、確実な (certain)、確実であろう (possibly certain)、確実かもしれない (perhaps certain) 10、おそらく有り得ない (more or less unlikely)、完全に有り得ない (completely unlikely) 等、口語的な用語で表される判定に対応している。

#### 【0019】

本発明によれば、フレーム 6 のレベルまでの音声信号の変動を考慮した信号変動メータ (signal variation meter) を用いて仮説を生成する。本明細書の内容において理解される信号変動メータは、ステート 5<sub>2</sub> 内の各フレーム 6 に対する一致結果を用いて、入力音声信号 2 から信号変動特性を抽出し、音声イベントのみから得られる信号成分に関する最高の候補を特徴付ける値を探し出す。各信号変動メータは、好ましくは、音声認識システムの信頼度尺度評価部内で用いられる。

#### 【0020】

以下に詳細に説明するが、上述した方法により仮説を生成するために、以下の信号変動メータを提案する。すなわち、ユニークステート比 (Unique State Ratio: U S R)、同ーステート比 (Same State Ratio: S S R)、ユニークステートエントロピー (Unique State Entropy: U S E)、平均スペクトル変動 (Average Spectral Variation: A S V)、スペクトル不一致距離 (Spectral Mismatch Distance: S M D)、ステート長単一比 (State Length One Ratio: S L O R) である。

#### 【0021】

ユニークステート比 (Unique State Ratio: U S R)：ステート 5<sub>2</sub> 内の各フレーム 6 において、入力音声信号 2 に最も一致している記録信号波形、すなわち最高のフレーム候補 (the best frame match) の識別子 7 を識別する。次に、ステート 5<sub>2</sub> 内において、異なる最高のフレーム候補の数をカウントし、この数をステート 5<sub>2</sub> 内にあるフレーム 6 の数で除算する。図 1 を参照して具体例を説明する。第 1 の音素 3 のステート 5<sub>2</sub> は、8 個のフレーム 6 から構成されている。最高のフレーム候補は、フレーム毎に異なり、合計 4 個の異なる識別子、すなわち「17」、「5」、「20」、「21」がある。ステート 5<sub>2</sub> 内には全部で 8 個のフレーム 6 が存在するので、この場合の U S R は 0.5 となる。

#### 【0022】

同ーステート比 (Same State Ratio: S S R)：上述と同様に、まず、ステート 5<sub>2</sub> 内のフレーム 6 每に最高のフレーム候補 (最適フレーム一致) を識別する。次に、同じ最高のフレーム候補 (最適フレーム一致) を有するフレームの数を判定する。そして、最も大きなカウント値を、各ステート 5<sub>2</sub> 内に存在するフレーム 6 の数で除算する。図 1 に示す具体例では、最高のフレーム候補の識別子 (最適フレーム一致) 「17」と「5」が、それぞれ 3 つの異なるフレームに対して識別されている。他の 2 つ、すなわち「20」と「21」は、それぞれ 1 つのフレーム 6 のみに対して識別されている。したがって、最も大きなカウント値は 3 であり、その結果、S S R = 0.375 となる。

#### 【0023】

ユニークステートエントロピー (Unique State Entropy: U S E) は、以下のように定義される。

#### 【0024】

## 【数1】

$$USE = \frac{-\sum_s^{Ns} \left( \frac{c(s)}{N} \cdot \log \left( \frac{c(s)}{N} \right) \right)}{\log(Ns)}$$

## 【0025】

ここで、 $N_s$ は、例えばステート5<sub>2</sub>等のステート内における様々な記録信号波形の総数であり、 $N$ は、ステート（例えば5<sub>2</sub>）内のフレーム6、6'の数であり、 $c(s)$ は、ステート（例えば5<sub>2</sub>）内の各記録信号波形についてのフレームカウント数であり、 $s$ は、記録信号波形の識別番号である。図1の具体例では、ステート5<sub>2</sub>内における一致を検出するために、4つの異なる記録信号波形、すなわち「17」、「5」、「20」、「21」という識別番号7の記録信号波形を用いている。したがって、 $N_s = 4$ であり、ステート5<sub>2</sub>を構成するフレームの総数( $N$ )は8であり、 $c(17) = 3$ 、 $c(5) = 3$ 、 $c(20) = 1$ 、 $c(21) = 1$ となる。1つのステートのみにおける1つの記録信号波形に基づいて計算を行う場合、すなわち $N_s = 1$ の場合、ゼロによる除算の問題が生じる。これについては、USEの値を0に設定することにより対処する。

10

## 【0026】

ステート5<sub>2</sub>内における隣接した2つのフレーム6間の平均スペクトル変動(Average Spectral Variation)は、スペクトルフラックス判定(spectral flux determination)に基づく一種のオーディオコンテンツ解析を表す。

20

## 【0027】

## 【数2】

$$ASV = \frac{1}{N_{coef} \cdot (W_{sw} - 1)} \sum_{n=b_{f_{sw}}}^{e_{f_{sw}}} \sum_{k=1}^{N_{coef}} [\log(|F_n(k)| + 1) - \log(|F_{n-1}(k)| + 1)]^2$$

30

## 【0028】

ここで、 $n$ は、ステート5<sub>2</sub>のユニットswにおけるフレームインデックスを表す。下限の値は、各ステートユニットswの開始フレーム $b_{f_{sw}}$ であり、上限の値は、終了フレーム $e_{d_{sw}}$ である。 $W_{sw}$ は、ステート5<sub>2</sub>内のフレーム数を表す。 $N_{coef}$ は、スペクトル係数の総数であり、 $|F_n(k)|$ は、 $k$ 番目のスペクトル係数に対応するn番目のフレームの振幅スペクトルである。

## 【0029】

スペクトルを表すのに、この具体例のような振幅スペクトルではなく、メル周波数ケブストラム係数(Mel Frequency Cepstrum Coefficient: MFCC)等の別のスペクトルベクトルも用いることができる。

40

## 【0030】

スペクトル不一致距離(Spectral Mismatch Distance: SMD)：記録信号による最高の候補の仮説と、各ステート5<sub>2</sub>内における入力音声信号2との間の不一致量を、好ましくは、距離メータ(distance meter)によって判定する。例えば、平均ユークリッド距離を用いると、仮説の最高ガウスフレーム候補(最適ガウスフレーム一致) $\mu(k)$ とステート5<sub>2</sub>のユニットsw内のスペクトルベクトルの間のスペクトル不一致距離SMDは、以下のようになる。

## 【0031】

## 【数3】

$$SMD = \frac{1}{W_{sw}} \sum_{n=bf_{sw}}^{ef_{sw}} \left( \sum_{k=1}^{N_{coef}} (F_n(k) - \mu(k))^2 \right)^{1/2}$$

## 【0032】

平均マハラノビス距離 (average Mahalanobis Distance) を用いると、仮説の最高ガウスフレーム候補 (仮説の最適ガウスフレーム一致) とステート<sub>5<sub>2</sub></sub>のユニット<sub>sw</sub>内のスペクトルベクトルとの間の SMD は、以下のようなになる。

10

## 【0033】

## 【数4】

$$SMD = \frac{1}{W_{sw}} \sum_{n=bf_{sw}}^{ef_{sw}} \left( \sum_{k=1}^{N_{coef}} \frac{(F_n(k) - \mu(k))^2}{\sigma(k)} \right)^{1/2}$$

## 【0034】

これは、重み付けユークリッド距離分散 (weighted Euclidian distance variance) に対応する。

20

## 【0035】

平均スペクトル変動メータについて既に述べたように、MFCC 等、他のスペクトルベクトルをスペクトル表現を用いることもできる。

## 【0036】

ステート長単一比 (State Length One Ratio: SLOR) は、ステート<sub>5<sub>2</sub></sub>内のフレーム数 N でステート<sub>5<sub>2</sub></sub>を分割することによって得られる单一のフレーム<sub>6</sub>内の最高フレーム候補の数によってられる。図 1 の具体例では、ステート<sub>5<sub>2</sub></sub>の 6 番目 (識別番号 7 が「20」と 7 番目 (識別番号 7 が「21」) のフレームのみが一度だけ起こっている。したがって、この 2 つのフレームが条件を満たし、ステート<sub>5<sub>2</sub></sub>内のフレーム総数 N が 8 であるので、ステート長単一比は 0.25 となる。

30

## 【0037】

上述の信号変動メータの全てを組み合わせて、入力音声信号<sub>2</sub>を認識するための信頼度尺度を導き出すことができる。信頼度尺度は、ステート<sub>5<sub>2</sub></sub>のレベル又はそれより高レベルのいずれかに基づいて得ることができる。特に、発話が 2 つ以上のステート<sub>5<sub>2</sub></sub>からなる場合、後続のステート<sub>5<sub>2</sub></sub>に対して得られる信頼度尺度を組み合わせて、高レベルの信頼度尺度を形成することが有利である。高レベルは、一音素、一連の音素、一単語、あるいは発話全体とすることができます。組合せは、ステート<sub>5<sub>2</sub></sub>のレベルで算出された一連の信頼度尺度の相加平均又は相乗平均に基づくものでもよいが、最大値又は最小値の判定、あるいは範囲、標準偏差又は相対分散等の分散尺度に基づくものでもよい。分散尺度は、1 つの単語及び / 又は発話仮説におけるステート<sub>5<sub>2</sub></sub>のユニット信号変動尺度の統計的分布を抽出するのに用いられる。

40

## 【0038】

信頼度スコアは、上述した信号変動メータの 1 つ又はそれらの組合せから直接導出することができ、あるいは多層パーセプトロン (multilayer perceptron) 等の最新の分類による 1 つ以上の信号変動メータを組み合わせることによって、導き出すことができる。

## 【0039】

本発明に係る信号変動メータの適用例について、図 2 を参照して説明する。フローチャート<sub>20</sub>は、本発明に基づく信頼度スコア又は尺度を生成する音声認識処理の各ステップを示す。ステップ<sub>S1</sub>において、入力音声信号<sub>2</sub>が供給される。ステップ<sub>S2</sub>において、入力音声信号<sub>2</sub>からスペクトル特性を導出する。これは、振幅スペクトルでもよいが、メ

50

ル周波数ケプストラム係数等、他のスペクトルベクトルでもよい。ステップ S 3 において、ステップ S 2 で取り出したスペクトル特性から、認識仮説を生成する基礎をつくる。仮説を評価する音声認識装置は、隠れマルコフモデル（HMM）21に基づいている。ステップ S 4 において、音素配列により、ステート  $5_2$  に対する少なくともフレーム単位で一致する記録信号波形の識別情報に基づいて、最高候補の情報を得る。ステップ S 5 において、上述の信号変動メータのうちの 1 つ以上により、ステップ S 2 ~ S 4 のスペクトル特性解析、ステップ S 3 の認識の仮説、ステップ S 4 の音素配列の各結果を統合して、信号変動特性の抽出（signal variation feature extraction: SVFE）を行う。ステップ S 6 において、ステップ S 2 ~ S 4 で得られた結果を用いて、信頼度尺度器 CM はステップ S 5 の結果を信頼度尺度に変換し、ステップ S 7 において、この信頼性尺度を信頼度スコアとして出力する。なお、ステップ S 6 において、ステップ S 2、S 3、S 4 の結果を必ずしも利用しなくてもよいが、これらの結果を利用することにより、音声認識を大幅に改善することができる。

10

20

## 【図面の簡単な説明】

## 【0040】

【図 1】例えば信号変動尺度を導出するのに用いる、幾つかに細分化された部分を有する入力音声信号を示す波形図である。

【図 2】本発明に係る信号変動測定を用いて、信頼度尺度を決定する処理を示すフローチャートである。



## 【符号の説明】

## 【0041】

2 入力音声信号、3, 3', 3" 音素、4, 4' 音素の境界、5, 5<sub>1</sub>, 5<sub>2</sub>, 5<sub>3</sub> ステート、6, 6' フレーム、7 記録信号波形の識別番号、S1 音声信号の入力、S2 スペクトル特性の導出、S3 音声認識仮説の生成、S4 最高候補の情報の取得、S5 結果の統合、S6 結果を信頼度尺度に変換、S7 信頼度スコアの出力

【図 1】

【図 2】



---

フロントページの続き

(72)発明者 イン ハイ ラム

ドイツ連邦共和国、70327 シュトゥットガルト ヘデルフィンガ シュトラーセ 61  
ソニー インターナショナル (ヨーロッパ) ゲゼルシャフト ミット ベシュレンクテル ハ  
フツング シュトゥットガルト テクノロジーセンター内

(72)発明者 トーマス ケンプ

ドイツ連邦共和国、70327 シュトゥットガルト ヘデルフィンガ シュトラーセ 61  
ソニー インターナショナル (ヨーロッパ) ゲゼルシャフト ミット ベシュレンクテル ハ  
フツング シュトゥットガルト テクノロジーセンター内

(72)発明者 キルジストフ マラセク

ドイツ連邦共和国、70327 シュトゥットガルト ヘデルフィンガ シュトラーセ 61  
ソニー インターナショナル (ヨーロッパ) ゲゼルシャフト ミット ベシュレンクテル ハ  
フツUNG シュトゥットガルト テクノロジーセンター内

F ターム(参考) 5D015 HH23 LL03

【外國語明細書】

### Signal Variation Feature Based Confidence Measure

In speech recognition systems articulated sounds or utterances, respectively, are converted in written language by interpreting a respective speech signal. Misinterpretations which are usually referred to as recognition errors frequently occur with state-of-the-art speech recognition systems when used in a noisy environment. Ambient noise superimposing an input speech signal either modifies the characteristic of the input signal or may mistakenly be interpreted as a phoneme by a speech recogniser.

In order to detect if misrecognition occur, so called confidence measures are used. A confidence measure judges the reliability with which a word or sub-word corresponds to a particular part of a signal. The word or sub-word is then accepted or rejected by the recognition process on the base of the confidence measure calculated for it.

As many different expressions sound very similar, there are often several alternatives possible for interpreting a certain utterance. To decide for one in particular, a confidence measure is e.g. calculated as the likelihood with which a certain expression corresponds to a respective utterance. This is usually accomplished by some form of special statistical hypothesis testing. These processes are usually very complicated, particularly as a phoneme can undergo certain acoustic variations under the influence of neighbouring phonemes, an effect which is known as coarticulation.

But also non-speech events, like the above mentioned ambient noise superimposing a speech signal result in an acoustic variation of the speech signal. A correct identification of the word or sub-word being the speech signal's written equivalent is therefore an elaborate task which is yet not been brought to a satisfactory solution.

It is therefore an object of the present invention to propose a system for improving the detection of recognition errors in a speech recognition system.

The above object is achieved by the invention as defined in the independent claims.

The characteristic features of a speech signal are quite different to those of a non-speech signal like e.g. ambient noise or noise bursts. In contrast to a non-speech signal, the

quasi-periodic behaviour of a speech signal results in comparatively small signal variation. A rapid change or considerable variation in normally steady parts of a speech input signal therefore most likely indicates the presence of a non-speech component.

Based on this insight, the above defined object is achieved by a method for predicting a misrecognition in a speech recognition system with steps for receiving a speech input signal, extracting at least one signal variation feature of the speech input signal, and applying a signal variation meter to the speech input signal for deriving a signal variation measure.

The above object is further achieved by a Computer-software-product for defining a confidence measure for a recognition hypothesis concerning a speech input signal in a speech recognition system. The computer-software-product comprises hereto a series of state elements which are adapted to be processed by a data processing means such, that a method according the present invention may be executed thereon to form a confidence measure evaluation system.

Additional advantageous features of the present invention are claimed in the respective sub-claims.

The signal variation meter is advantageously applied to a sub-word of the speech input signal, particularly to a frame, a state or a phoneme as described below. According to an advantageous development, the signal variation measures derived for two or more sub-words of the speech input signal are combined to form a confidence measure. Hereby, the combination of the signal variation measures derived for two or more sub-words of a speech input signal may preferably be based on an arithmetic mean, geometric mean, maximum value, minimum value or on a dispersion measure, whereby the dispersion measure is formed by a range, standard deviation or relative dispersion.

The signal variation meter is effectively based on a Unique State Ratio, Same State Ratio, Unique State Entropy, Average Spectral Variation, Spectral Mismatch Distance or State Length One Ratio evaluation or a combination of two or more of these.

According to a further advantageous embodiment of the present invention, the extraction of the signal variation is based on a spectral feature derived from the speech input signal, whereby the extraction of the signal variation may suitably be based on a phoneme alignment of a Hidden Markov Model based speech recognition hypothesis.

In the following, the present invention will be explained in detail and by way of example only, with reference to the attached Figures, wherein

Figure 1 shows a speech input signal with an indication of several subdivisions as for example used to derive a signal variation measure, and

Figure 2 shows a system for determining a confidence measure with a signal variation metering according to the present invention.

The diagram 1 of Figure 1 shows part of a speech input signal 2 in an amplitude versus time representation. The speech input signal 2 is divided into several phonemes 3, 3' and 3'' which are separated from each other by phoneme boundaries 4 and 4'. A phoneme is a sound characterised as the minimal word distinguishing signal like e.g. a *b* in contrast to a *p*. It may already represent a sub-word like for instance a syllable but usually it is a smaller word component. The term sub-word is used within this specification without any restriction and to indicate that only a part of a word in its acoustical or written representation is referred to.

For the speech recognition process, each phoneme is subdivided into so called states  $5_1$ ,  $5_2$ ,  $5_3$ , and  $5'_1$ ,  $5'_2$ ,  $5'_3$  etc., and each state is further subdivided into the smallest analysing unit called frame 6 or 6', respectively. The recognition process looks for matches of a recorded signal form to the input signal within a state  $5_2$ . Usually, there will be no exact match which means that the recorded signal form will deviate from the speech input signal 2 in one or more frames 6 of a respective state  $5_2$ . Different recorded signals forms are therefore compared to the input signal 2 within a state  $5_2$  of interest, and the matching is controlled on the basis of the frames 6 present in that state  $5_2$ . Different recorded signal forms are therefore likely to form the respective best match in different frames 6 of a state  $5_2$ . This is indicated in Figure 1 where each recorded signal form is referenced by an identification number 7. While the recorded signal form number '17' produces a good match in the first, fourth and last frame 6 of state  $5_2$ , the recorded signal form number '5' fits best in the second, third and fifth frame. The third last frame is found to match with the recorded signal form number '20', and the last but one frame with number '21'.

The described deviation of the speech input signal 2 from a recorded signal within the level of a state unit  $5_2$  is mostly caused by non-speech events like e.g. background noise insertions or changes in the mood of the person talking. A match will therefore seldom be perfect but rather tainted with a certain variation or uncertainty. Even for the best match there remains a certain probability for it being wrong.

To improve the accuracy of a confidence measure system the present invention introduces a characterisation of the reliability of each detected match. For the characterisation a hypothesis is derived for assessing the reliability of each match found. The hypothesis forms a statement about a certain match being probably right or wrong. It usually takes on the form of a numerical value for an easy further processing by a speech recognition system. The value of the hypothesis corresponds to a judgement which may be expressed in colloquial terms as e.g. very certain, certain, possibly certain, perhaps certain, more or less unlikely, completely unlikely or something like that.

According to the present invention a hypothesis is generated by utilising signal variation meters which consider the speech signal variations down to a frame 6 level. A signal variation meter as it is understood in the context of this specification uses the matching results for each frame 6 in a state  $S_2$  to extract signal variation features from the speech input signal 2 so as to ascertain a value characterising the best match regarding the signal component originating from a speech event only. A respective signal variation meter is preferably used within a confidence measure evaluation unit of a speech recognition system.

The following signal variation meters, which are explained in detail below are proposed to generate a hypothesis according to the previously explained: Unique State Ratio (USR), Same State Ratio (SSR), Unique State Entropy (USE), Average Spectral Variation (ASV), Spectral Mismatch Distance (SMD), and State Length One Ratio (SLOR).

**Unique State Ratio:** For each frame 6 in a state  $S_2$ , the identity 7 of the recorded signal form which matches the speech input signal 2 therein best, i.e. the best frame match, is identified. Next, the number of different best frame matches for a state  $S_2$  is counted and divided by the number of frames 6 present within said state  $S_2$ . An example can be given with reference to Figure 1. The state  $S_2$  of the first phoneme 3 is composed of eight frames 6. The best frame matches differ from frame to frame with a total of four different identities, namely '17', '5', '20', and '20'. As there are altogether eight frames 6 present in state  $S_2$ , its USR is computed to 0.5.

**Same State Ratio:** Like before, first the best frame matches are identified for each frame 6 within a state  $S_2$ . Next, the number of frames having the same best frame match are determined. The highest count is then divided by the number of frames 6 present in the respective state  $S_2$ . In the example illustrated in Figure 1, the best frame matches

'17' and '5' are each identified for three different frames respectively.. The other two, '20' and '21' each only for one frame 6. The highest count therefore amounts to three, resulting in an  $\text{SSR} = 0.375$ .

The Unique State Entropy is defined as:

$$\text{USE} = - \sum_s^{\text{Ns}} \left( \frac{c(s)}{N} \cdot \log \left( \frac{c(s)}{N} \right) \right) / \log(\text{Ns}), \quad (1)$$

wherein  $\text{Ns}$  denotes the total number of different recorded signal forms in a state as e.g.  $5_2$ ,  $N$  the number of frames 6,  $6'$  within the state (e.g.  $5_2$ ),  $c(s)$  the count of frames for a respective recorded signal form in the state (e.g.  $5_2$ ), and 's' is the identification number of a recorded signal form. In the example of Figure 1, four different recorded signal forms were used to match state  $5_2$ , namely the signal forms with the identification numbers 7 of '17', '5', '20', and '21'. Hence  $\text{Ns}=4$ , the total number of frames ( $N$ ) constituting state  $5_2$  is 8, and  $c(17)=3$ ,  $c(5)=3$ ,  $c(20)=1$ ,  $c(21)=1$ . If the calculation is performed on the basis of one recorded signal form only in one state, eg., i.e.  $\text{Ns}=1$ , a division-by-zero problem arises, which is handled by setting the value for USE to 0 for this case.

The Average Spectral Variation between two adjacent frames 6 in a state  $5_2$  represents a sort of audio content analysis based on a spectral flux determination. It is defined by:

$$\text{ASV} = \frac{1}{N_{\text{coef}} \cdot (W_{\text{sw}} - 1)} \sum_{n=bf_{\text{sw}}}^{ef_{\text{sw}}} \sum_{k=1}^{N_{\text{coef}}} [\log(|F_n(k)|+1) - \log(|F_{n-1}(k)|+1)]^2; \quad (2)$$

Herein  $n$  signifies the frame index in the state  $5_2$  unit  $\text{sw}$ ; Its lower value is the begin frame  $bf_{\text{sw}}$  and its upper value is the end frame  $ef_{\text{sw}}$  of the respective state unit  $\text{sw}$ .  $W_{\text{sw}}$  denotes the number of frames within said state  $5_2$ ,  $N_{\text{coef}}$  the total number of the spectral coefficients, and  $|F_n(k)|$  the amplitude spectrum of the  $n^{\text{th}}$  frame corresponding to the  $k^{\text{th}}$  spectral coefficient.

Instead of an amplitude spectrum like in the example given, other spectral vectors such as a Mel Frequency Cepstrum Coefficient (MFCC) may be used for the spectral representation.

**Spectral Mismatch Distance:** The amount of mismatch between a hypothesis for the best match formed by a recorded signal form and the speech input signal 2 in a respective

state  $S_2$ , is preferably determined by a distance meter. By e.g. using the average Euclidean distance, the Spectral Mismatch Distance between the best Gaussian frame match  $\mu(k)$  of the hypothesis and the spectral vectors in the state  $S_2$  unit sw is

$$SMD = \frac{1}{W_{sw}} \sum_{n=b_{sw}}^{e_{sw}} \left( \sum_{k=1}^{N_{ref}} (F_n(k) - \mu(k))^2 \right)^{1/2}. \quad (3)$$

Using the average Mahalanobis Distance, the SMD between the best Gaussian frame match of the hypothesis and the spectral vectors in the state  $S_2$  unit sw will become:

$$SMD = \frac{1}{W_{sw}} \sum_{n=b_{sw}}^{e_{sw}} \left( \sum_{k=1}^{N_{ref}} \frac{(F_n(k) - \mu(k))^2}{\sigma(k)} \right)^{1/2}, \quad (4)$$

which corresponds to a weighted Euclidian distance variance.

Like mentioned before with reference to the Average Spectral Variation meter, other spectral vectors such as an MFCC can be used for the spectral representation.

The State Length One Ratio is given by the number of best frame matches in a state  $S_2$  which last for only one frame 6 divided by the number of frames N within said state  $S_2$ . In the example of Figure 1 only the sixth (with an identification number 7 of '20') and the seventh frame (with an identification number 7 of '21') of state  $S_2$  occur just once. Therefore two frames fulfil the condition, and with the total number of frames N within state  $S_2$  being 8, the State Length One Ratio amounts to 0.25.

All signal variation meters described up to now may be combined to derive a confidence measure for the speech input signal 2 to be recognised. The confidence metering may either be based on a state  $S_2$ -level or on a higher level. Particularly, when an utterance consist of more than one state  $S_2$ , the confidence measures obtained for subsequent states  $S_2$  may be advantageously combined to form a higher level confidence measure. The higher level may be a phoneme, a series of phonemes, a word or a complete utterance. The combination may be based on an arithmetic or geometric mean of a series of confidence measures calculated on a state  $S_2$ -level, but also on a maximum or minimum determination or a dispersion measure as e.g. a range, standard deviation, relative dispersion or the like. The dispersion measures are used to extract the statistical distribution of a state  $S_2$  unit signal variation measure in a word and/or utterance hypothesis.

A confidence score may be derived directly from one of the above described signal variation meters or a combination thereof, or by combining one or more signal variation meters with a state-of-the art classifier like a multilayer perceptron.

The application of a signal variation meter according to the present invention is described with reference to Figure 2. The flowchart 20 illustrates the individual steps of a speech recognition process yielding a confidence score or measure, respectively, according to the present invention. Beginning with step S1, a speech input signal 2 is received. Step S2 retrieves the spectral features from the speech input signal 2. This may be an amplitude spectrum or any other spectral vector such as for instance a Mel Frequency Cepstrum Coefficient. The spectral features derived in step S2 form the base for producing a recogniser hypothesis in step S3. The speech recogniser evaluating the hypothesis is based on a Hidden markov Model (HMM) 21. A phoneme alignment applied in step S4 provides the best match information based on an identification of at least framewise matching recorded signal forms for a state  $S_2$ . In step S5, the results from the spectral feature analysis of step S2 to S4, the recogniser hypothesis of step S3, and the phone alignment of step S4 are merged by one or more of the above described signal variation meters to perform a signal variation feature extraction. Using results obtained in step S2 to S4, the confidence Meter CM transforms in step S6 the result of step S5 into a confidence measure delivered as a confidence score in step S7. Although the usage of the results from S2, S3, and S4 in step S6 is not mandatory, it is preferred, since it improves the speech recognition significantly.

**List of Reference Signs**

1	diagram
2	speech input signal
3, 3', 3''	phoneme
4, 4'	phoneme boundary
5, 5 <sub>1</sub> , 5 <sub>2</sub> , 5 <sub>3</sub>	state
6, 6'	frame
7	identification number of recorded signal form
20	flowchart
21	HMM
S1	receiving speech input
S2	retrieve spectral features
S3	produce a recogniser hypothesis
S4	provide best match information
S5	merging results
S6	transform results in confidence measure
S7	deliver confidence score

**Claims**

1. A method for predicting a misrecognition in a speech recognition system, the method comprising the following steps:
  - receiving a speech input signal,
  - extracting at least one signal variation feature of the speech input signal, and
  - applying a signal variation meter to the speech input signal for deriving a signal variation measure.
2. A method according to claim 1,  
characterised in  
that the signal variation meter is applied to a sub-word of the speech input signal.
3. A method according to claim 2,  
characterised in  
that the signal variation measures derived for two or more sub-words of the speech input signal are combined to form a confidence measure.
4. A method according to claim 3,  
characterised in  
that said combination of the signal variation measures derived for two or more sub-words of a speech input signal is based on an arithmetic mean, geometric mean , maximum value, minimum value or on a dispersion measure.
5. A method according to claim 4,  
characterised in  
that said dispersion measure is the range, standard deviation or relative dispersion.
6. A method according to one of the claims 1 to 5,  
characterised in  
that the signal variation meter is based on a Unique State Ratio evaluation.
7. A method according to one of the claims 1 to 6,

characterised in

that the signal variation meter is based on a Same State Ratio evaluation.

8. A method according to one of the claims 1 to 7,

characterised in

that the signal variation meter is based on a Unique State Entropy evaluation.

9. A method according to one of the claims 1 to 8,

characterised in

that the signal variation meter is based on an Average Spectral Variation evaluation.

10. A method according to one of the claims 1 to 9,

characterised in

that the signal variation meter is based on a Spectral Mismatch Distance evaluation.

11. A method according to one of the claims 1 to 10,

characterised in

that the signal variation meter is based on a State Length One Ratio evaluation.

12. A method according to one of the claims 1 to 11,

characterised in

that the extraction of the signal variation is based on a spectral feature derived from the speech input signal.

13. A method according to claim 12,

characterised in

that the extraction of the signal variation is further based on a phoneme alignment of a Hidden Markov Model based speech recognition hypothesis.

14. A Computer-software-product for defining a confidence measure for a recognition hypothesis concerning a speech input signal 2 in a speech recognition system, the computer-software-product comprising a series of state elements which are

adapted to be processed by a data processing means such, that a method according to one of the claims 1 to 13 may be executed thereon.

### Abstract

Based on the insight that variations in a speech input signal (2) are different depending on the origin of the signal (2) being a speech or a non-speech event, the present invention proposes method for predicting a misrecognition in a speech recognition system (2) with steps for receiving a speech input signal (S1), extracting at least one signal variation feature (S2) of the speech input signal (2), and applying a signal variation meter to the speech input signal for deriving a signal variation measure (S5).

(Figure 2)

【図1】




Figure 1

【図2】




Figure 2