

(19) 日本国特許庁(JP)

(12) 特 許 公 報(B2)

(11) 特許番号

特許第6017277号
(P6017277)

(45) 発行日 平成28年10月26日 (2016.10.26)

(24) 登録日 平成28年10月7日 (2016.10.7)

(51) Int.Cl. F 1
G 0 6 F 17/30 (2006.01)
 G 0 6 F 17/30 3 5 0 C
 G 0 6 F 17/30 1 7 0 B

請求項の数 12 (全 23 頁)

(21) 出願番号	特願2012-255899 (P2012-255899)	(73) 特許権者	000208891
(22) 出願日	平成24年11月22日 (2012.11.22)		KDDI株式会社
(65) 公開番号	特開2014-102772 (P2014-102772A)		東京都新宿区西新宿二丁目3番2号
(43) 公開日	平成26年6月5日 (2014.6.5)	(74) 代理人	100135068
審査請求日	平成27年8月4日 (2015.8.4)		弁理士 早原 茂樹
		(72) 発明者	内田 祐介
			埼玉県ふじみ野市大原二丁目1番15号
			株式会社KDDI研究所内
		(72) 発明者	酒澤 茂之
			埼玉県ふじみ野市大原二丁目1番15号
			株式会社KDDI研究所内
		審査官	吉田 誠

最終頁に続く

(54) 【発明の名称】 特徴ベクトルの集合で表されるコンテンツ間の類似度を算出するプログラム、装置及び方法

(57) 【特許請求の範囲】

【請求項1】

特徴ベクトルの集合で表されるクエリコンテンツと対象リファレンスコンテンツRとの間の類似度を算出するべく、装置に搭載されたコンピュータを機能させる類似度算出プログラムであって、

多数のリファレンスコンテンツR_jから抽出された各特徴ベクトルを記憶したリファレンス特徴ベクトル蓄積手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、前記リファレンス特徴ベクトル蓄積手段からリファレンス特徴ベクトルの集合を取得し、最も類似するものから順に上位N (> 1) 件のリファレンス特徴ベクトルを検索するリファレンス特徴ベクトル検索手段と

10

クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する対象リファレンス特徴ベクトル検索手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、最も類似する対象リファレンス特徴ベクトルとの間の距離が、上位N件の各リファレンス特徴ベクトルとの間の距離における上位から何位に相当するかの順位に基づいてスコアを算出するスコア算出手段と、

クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする類似度算出手段と

してコンピュータを機能させることを特徴とする類似度算出プログラム。

20

【請求項 2】

前記スコア算出手段は、上位 N 件の各リファレンス特徴ベクトルとの間の距離に対する、最も類似する対象リファレンス特徴ベクトルとの間の距離の前記順位が、上位 N 件以内にある場合、スコア 1 とし、上位 N 件以内でない場合、スコア 0 とするようコンピュータを機能させることを特徴とする請求項 1 に記載の類似度算出プログラム。

【請求項 3】

前記スコア算出手段は、上位 N 件の各リファレンス特徴ベクトルとの間の距離に対する、最も類似する対象リファレンス特徴ベクトルとの間の距離の前記順位が、K 位に相当する場合、スコアを以下の式によって算出する

$$s_i = \log \left\{ \frac{1}{(1 - \alpha)^{|R_{all}|} / (K \cdot |R|) + 1} \right\}$$

α : 調整可能パラメータ

|R| : 対象リファレンスコンテンツの中の特徴ベクトルの数

|R_{all}| : 前記リファレンス特徴ベクトル蓄積手段に蓄積されたリファレンス特徴ベクトルの数

ようコンピュータを機能させることを特徴とする請求項 1 に記載の類似度算出プログラム。

【請求項 4】

前記類似度算出手段は、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似した対象リファレンス特徴ベクトルとの対応関係を求め、その対応関係の集合からクエリコンテンツと対象リファレンスコンテンツとの間の Homography 行列を算出し、その Homography 行列を満たす対応関係を持つクエリコンテンツの特徴ベクトルについてのスコアのみを合計するようコンピュータを機能させることを特徴とする請求項 3 に記載の類似度算出プログラム。

【請求項 5】

前記類似度算出手段は、前記 Homography 行列を、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルとの対応関係のうち、前記スコアが大きい対応関係から順に用いて算出するようコンピュータを機能させることを特徴とする請求項 4 に記載の類似度算出プログラム。

【請求項 6】

請求項 1 から 5 のいずれか 1 項に記載の類似度算出プログラムを用いて、リファレンスコンテンツの集合から、クエリコンテンツに類似したリファレンスコンテンツを検索するよう、装置に搭載されたコンピュータを機能させる検索プログラムであって、

前記リファレンス特徴ベクトル蓄積手段は、複数のリファレンスコンテンツ R_j から抽出された各リファレンス特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶しており、

前記リファレンス特徴ベクトル蓄積手段を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i について、類似したリファレンス特徴ベクトルを M (> 1) 個探索する類似ベクトル探索手段と、

混合パラメータ α を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i が、探索された各リファレンスコンテンツから生成される確率 α · p(q_i | R_j) と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率 (1 - α) · p(q_i) との確率比に基づいて、リファレンスコンテンツ R_j 毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトル q_i について実行し、最終的に、所定閾値以上の上位のスコアを得たリファレンスコンテンツ R_j を、検索結果として出力する投票手段とを有し、

前記類似度算出プログラムが、前記投票手段によって出力された各リファレンスコンテンツ R_j について、前記クエリコンテンツの各クエリ特徴ベクトルとの間の類似度を算出することによって再度順位を並び替える

10

20

30

40

50

ようにコンピュータを機能させることを特徴とする検索プログラム。

【請求項 7】

前記投票手段は、クエリコンテンツの特徴ベクトル q_i に対するリファレンスコンテンツ j のスコア s_j を、以下の式によって算出する

$$s_j = \log \left\{ \frac{1}{(1-\alpha) \cdot |R_{all}| + \alpha \cdot |R_j|} + 1 \right\}$$

α : リファレンスコンテンツ j の特徴ベクトルが上位 M 件の中で初めて出現する番号

$|R_{all}|$: 全リファレンスコンテンツにおける全特徴ベクトルの数

$|R_j|$: 当該リファレンスコンテンツ j における全特徴ベクトルの数

α 、 $1-\alpha$: 混合パラメータ

10

ようにコンピュータを機能させることを特徴とする請求項 6 に記載の検索プログラム。

【請求項 8】

クエリコンテンツ及びリファレンスコンテンツは、画像であって、

リファレンスコンテンツとしての画像には、同一の物体又は同一カテゴリに属する少なくとも 1 つのインスタンス (対象物、オブジェクト) が写っている

ことを特徴とする請求項 1 から 5 のいずれか 1 項に記載の類似度算出プログラム。

【請求項 9】

特徴ベクトルの集合で表されるクエリコンテンツと対象リファレンスコンテンツ R との間の類似度を算出する類似度算出装置であって、

20

多数のリファレンスコンテンツ R_j から抽出された各特徴ベクトルを記憶したリファレンス特徴ベクトル蓄積手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、前記リファレンス特徴ベクトル蓄積手段からリファレンス特徴ベクトルの集合を取得し、最も類似するものから順に上位 N (> 1) 件のリファレンス特徴ベクトルを検索するリファレンス特徴ベクトル検索手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する対象リファレンス特徴ベクトル検索手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、最も類似する対象リファレンス特徴ベクトルとの間の距離が、上位 N 件の各リファレンス特徴ベクトルとの間の距離における上位から何位に相当するかの順位に基づいてスコアを算出するスコア算出手段と、

30

クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする類似度算出手段と

を有することを特徴とする類似度算出装置。

【請求項 10】

請求項 9 に記載の類似度算出装置の全ての機能を含み、リファレンスコンテンツの集合から、前記クエリコンテンツに類似したリファレンスコンテンツを検索する検索装置であって、

前記リファレンス特徴ベクトル蓄積手段は、複数のリファレンスコンテンツ R_j から抽出された各リファレンス特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶しており、

40

前記リファレンス特徴ベクトル蓄積手段を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i について、類似したリファレンス特徴ベクトルの集合 D を、少なくとも 1 つ以上探索する類似ベクトル探索手段と、

混合パラメータ α を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i が、探索された各リファレンスコンテンツから生成される確率 $\alpha \cdot p(q_i | R_j)$ と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率 $(1-\alpha) \cdot p(q_i)$ との確率比に基づいて、リファレンスコンテンツ R_j 毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトル q_i について実行し、最終的に、所定閾値以上の上位のスコアを

50

得たりファレンスコンテンツ R_j を、検索結果として出力する投票手段とを有し、

前記類似度算出プログラムが、前記投票手段によって出力された各リファレンスコンテンツ R_j について、前記クエリコンテンツの各クエリ特徴ベクトルとの間の類似度を算出することによって再度順位を並び替えることを特徴とする検索装置。

【請求項 1 1】

特徴ベクトルの集合で表されるクエリコンテンツと対象リファレンスコンテンツ R との間の類似度を算出する装置における類似度算出方法であって、

多数のリファレンスコンテンツ R_j から抽出された各特徴ベクトルを記憶したリファレンス特徴ベクトル蓄積部を有し、

クエリコンテンツの各クエリ特徴ベクトルについて、前記リファレンス特徴ベクトル蓄積部からリファレンス特徴ベクトルの集合を取得し、最も類似するものから順に上位 N (> 1) 件のリファレンス特徴ベクトルを検索する第 1 のステップと、

クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する第 2 のステップと、

クエリコンテンツの各クエリ特徴ベクトルについて、最も類似する対象リファレンス特徴ベクトルとの間の距離が、上位 N 件の各リファレンス特徴ベクトルとの間の距離における上位から何位に相当するかの順位に基づいてスコアを算出する第 3 のステップと、

クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする第 4 のステップと

を有することを特徴とする類似度算出方法。

【請求項 1 2】

請求項 1 1 に記載の類似度算出方法の全てのステップを含み、リファレンスコンテンツの集合から、前記クエリコンテンツに類似したリファレンスコンテンツを検索する装置における検索方法であって、

前記リファレンス特徴ベクトル蓄積部は、複数のリファレンスコンテンツ R_j から抽出された各リファレンス特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶しており、

第 1 のステップの前段として、

前記リファレンス特徴ベクトル蓄積部を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i について、類似したリファレンス特徴ベクトルの集合 D を、少なくとも 1 つ以上探索する第 0 1 のステップと、

混合パラメータ α を用いて、前記クエリコンテンツの各クエリ特徴ベクトル q_i が、探索された各リファレンスコンテンツから生成される確率 $\alpha \cdot p(q_i | R_j)$ と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率 $(1 - \alpha) \cdot p(q_i)$ との確率比に基づいて、リファレンスコンテンツ R_j 毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトル q_i について実行し、最終的に、所定閾値以上の上位のスコアを得たりファレンスコンテンツ R_j を、検索結果として出力する第 0 2 のステップとを更に有し、

第 1 から第 4 のステップを実行することによって、第 0 2 のステップによって出力された各リファレンスコンテンツ R_j について、前記クエリコンテンツの各クエリ特徴ベクトルとの間の類似度を算出し、再度順位を並び替えることを特徴とする検索方法。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、特徴ベクトルの集合で表されるコンテンツ間の類似度を算出する技術に関する。また、コンテンツ間の類似度を算出することによって、特徴ベクトルの集合で表されるリファレンスコンテンツ（検索対象のコンテンツ）の集合から、同じく特徴ベクトルの

10

20

30

40

50

集合で表されるクエリコンテンツ（検索キーとなるコンテンツ）に類似したリファレンスコンテンツを高精度に検索する技術に関する。特に、高次元の特徴ベクトルの集合で表されるマルチメディアコンテンツ（例えば画像）の検索に適する。

【背景技術】

【0002】

近年、オンライン/オフラインに限られず、ストレージの大容量化に伴って、大量のコンテンツを蓄積することが可能となっている。また、携帯電話機やスマートフォンに代表される情報端末機器の普及によって、ユーザ自ら取得した写真データのようなデジタルコンテンツも、データベースに大量かつ容易に蓄積することができる。オフラインデータベースとして、HDD(Hard Disk Drive)、DVD(Digital Versatile Disk)、Blu-ray disc等の記憶装置がある。また、オンラインデータベースとしては、Flickr（登録商標）やMySpace（登録商標）のようなソーシャルネットワークサービスがある。これら記憶装置及びサービスによれば、データベースに蓄積された個人の大量且つ多様なマルチメディアコンテンツを検索する技術が重要となる。

10

【0003】

マルチメディアコンテンツを検索するために、これらコンテンツから多数の特徴ベクトルを抽出し、この特徴ベクトルの集合同士の間の類似度が高いコンテンツを検索結果として出力する技術がある。この技術によれば、マルチメディアコンテンツの特徴ベクトルを量子化し、量子化された特徴ベクトルの頻度からヒストグラムを作成する。そのヒストグラム同士の間のL1ノルム又はL2ノルムの距離によって類似度（距離）を算出する。ノルムとは、2つの点の間の距離を表す。L1ノルムとは、2つの点の各次元の値の絶対値の和を意味し、L2ノルムとは、2つの点の各次元の値を二乗した和を意味する。

20

【0004】

また、画像コンテンツから大量の局所特徴ベクトルを抽出し、それらをベクトル量子化し、同一の代表ベクトルにベクトル量子化された局所特徴ベクトルの数で類似度を算出する技術もある（例えば非特許文献1参照）。

【0005】

更に、画像から複数の局所不変特徴量を抽出し、特徴ベクトルの頻度のヒストグラム化し、そのヒストグラムの重なり率によって画像とカテゴリとの間の類似度を算出する技術もある（例えば特許文献1参照）。この技術によれば、ヒストグラムに基づいて被写体のパターン認識に不要となる特徴（例えば背景の特徴）を除くことができる。これによって、画像中から物体と物体以外とを予め分離することなく、当該物体の特徴を抽出することができる。

30

【0006】

従来、局所特徴量を用いた類似画像検索の枠組みは、「Bag-of-Visual Words」（又はBag-of-Features、Bag-of-Keypoints）と称される（例えば非特許文献1参照）。この技術によれば、Bag-of-Wordsモデル及び転置インデックスを用いた文章の検索方法を、類似画像の検索に適用したものである。Bag-of-Wordsは、文章を1つの単語の頻度により定義される特徴ベクトルで表現し、文章集合に基づいて予め導出されたIDF(Inverse Document Frequency)を単語の重みとして文章間の類似度を導出する枠組みである。これに対し、Bag-of-Visual Wordsは、画像の局所特徴量を量子化し、量子化後の局所特徴量を単語と見立て、同様に頻度により定義される1つの特徴ベクトルとして表現し、IDFを用いた重み付けを利用して同一の類推方法を適用することができる。

40

【0007】

これら従来技術に対して、クエリ特徴ベクトルに対して類似度の高い順に並べられたリファレンス特徴ベクトルのリストについて、更なる正確度を高めたい場合もある。また、クエリ画像とリファレンス画像とに、同一の物体が含まれているか否かを、類似度に基づいて閾値で判定したい場合もある。これらの場合に対して、最初の検索結果で得られた上位N件のリファレンス特徴ベクトルについて、更に正確なスコアを計算するリランキング技術がある（例えば特許文献7参照）。

50

【 0 0 0 8 】

図 1 は、従来技術におけるクエリコンテンツと対象リファレンスコンテンツとの間の類似度を算出する画像対応図である。

【 0 0 0 9 】

図 1 によれば、クエリ特徴ベクトルから見て、最も近い対象リファレンス特徴ベクトルまでの距離 d_1 と、2 番目に近い対象リファレンス特徴ベクトルまでの距離 d_2 との比 (d_1 / d_2) に基づいて、再度、マッチング処理を実行する。その距離の比が所定閾値以下となるまで、そのマッチング処理を繰り返す。最終的に、その距離の比が所定閾値以下となった際、類似度を + 1 としてスコアを算出する。

【 先行技術文献 】

10

【 特許文献 】

【 0 0 1 0 】

【 特許文献 1 】 特開 2 0 1 0 - 2 8 2 5 8 1 号公報

【 特許文献 2 】 特開 2 0 0 9 - 0 2 0 7 6 9 号公報

【 非特許文献 】

【 0 0 1 1 】

【 非特許文献 1 】 J. Sivic et al., "Video Google: A Text Retrieval Approach to Object Matching in Videos," in Proc. ICCV, 2003.

【 非特許文献 2 】 H. Jegou, M. Douze, and C. Schmid, "Improving bag-of-features for large scale image search," in IJCV, vol.87, no.3, pp.316-336, 2010.

20

【 非特許文献 3 】 Y. Uchida, M. Agrawal, and S. Sakazawa, "Accurate Content-Based Video Copy Detection with Efficient Feature Indexing," in Proc. of ICMR, 2011.

【 非特許文献 4 】 D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," International Journal of Computer Vision, vol. 60, no. 2, pp.91-110, 2004.

【 非特許文献 5 】 H. Jegou, M. Douze, and C. Schmid, "Product quantization for nearest neighbor search," in IEEE Trans. on PAMI, vol. 33, no. 1, pp.117-128, 2011.

【 非特許文献 6 】 O. Boiman, E. Shechtman, and M. Irani, "In defense of nearest-neighbor based image classification," in Proc. of CVPR, 2008.

【 非特許文献 7 】 J. Philbin, O. Chum, M. Isard, J. Sivic, and A. Zisserman, "Object Retrieval with Large Vocabularies and Fast Spatial Matching," in Proc of CVPR, 2007.

30

【 非特許文献 8 】 O. Chum and J. Matas, "Matching with PROSAC - Progressive Sample Consensus," in Proc. of CVPR, 2005.

【 発明の概要 】

【 発明が解決しようとする課題 】

【 0 0 1 2 】

しかしながら、既存の Bag-of-Visual Words の技術によれば、特徴ベクトルに基づいてコンテンツ間の類似度のスコアを算出する際に、文章検索における IDF を用いている。IDF とは、テキストマイニングの用途について、文章中に出現した特定の単語がどのくらい特徴的であるかを識別するための指標を表す。IDF の場合、例えば固有名詞のような、「各文章は、当該文章内に含まれる少数の単語によって検索される」という前提で設計されている。言い換えれば、「各文章は、当該文章内に含まれない単語によっては検索されない」という前提である。IDF は、具体的には、当該文章の中で特定の単語が出現した回数と、コーパス全体の中でその文章を含む文章数の自然対数とから、そのコーパス中におけるその単語の特徴度として算出される。

40

【 0 0 1 3 】

一方、画像検索の場合、局所不変特徴領域から、高次元の特徴ベクトルを抽出する必要がある。例えば、物体認識に用いる特徴ベクトルを抽出するために代表的な SIFT (Scale-Invariant Feature Transform) によれば、特徴領域を複数のブロックに分割し、各ブ

50

ロックから輝度勾配の方向を重み付きヒストグラムとして抽出する。

【0014】

ここで、クエリコンテンツには、リファレンスコンテンツに描写される対象物とは無関係な特徴ベクトルが多く含まれる場合がある。具体的には、対象物をカメラで撮影した画像を、クエリコンテンツとした場合である。リファレンスコンテンツには、例えば背景が白で、検索対象物のみが写っているのに対し、クエリコンテンツには、当該対象物だけでなく、その背景に様々な物が写り込む。即ち、クエリコンテンツの背景には、当該対象物とは無関係の様々な特徴ベクトルが検出される。これが、検索精度を低下させる原因となっている。

【0015】

また、リランキング技術を用いて上位N件について正確な類似度を算出しようとしても、リファレンス画像中に、ほぼ同一の特徴部分が複数存在する場合、距離の比(d_1/d_2)が1となる。即ち、正しい対応点(特徴ベクトル)であっても、マッチングしたと判定されない場合があり、マッチングの精度が、リファレンス画像の内容に依存してしまうという問題がある。また、リファレンス画像の中のリファレンス特徴ベクトルの数の影響を、正規化できないという問題もある。

【0016】

そこで、本発明によれば、クエリ特徴ベクトルから見て、複数のリファレンス特徴ベクトルとの間の距離の分布に基づいて、クエリコンテンツと対象リファレンスコンテンツとの間の類似度を正確に算出することができるプログラム、装置及び方法を提供することを目的とする。

【課題を解決するための手段】

【0017】

本発明によれば、特徴ベクトルの集合で表されるクエリコンテンツと対象リファレンスコンテンツRとの間の類似度を算出するべく、装置に搭載されたコンピュータを機能させる類似度算出プログラムであって、

多数のリファレンスコンテンツ R_j から抽出された各特徴ベクトルを記憶したリファレンス特徴ベクトル蓄積手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、リファレンス特徴ベクトル蓄積手段からリファレンス特徴ベクトルの集合を取得し、最も類似するものから順に上位N(> 1)件のリファレンス特徴ベクトルを検索するリファレンス特徴ベクトル検索手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する対象リファレンス特徴ベクトル検索手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、最も類似する対象リファレンス特徴ベクトルとの間の距離が、上位N件の各リファレンス特徴ベクトルとの間の距離における上位から何位に相当するかの順位に基づいてスコアを算出するスコア算出手段と、

クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする類似度算出手段と

してコンピュータを機能させることを特徴とする。

【0018】

本発明の類似度算出プログラムにおける他の実施形態によれば、

スコア算出手段は、上位N件の各リファレンス特徴ベクトルとの間の距離に対する、最も類似する対象リファレンス特徴ベクトルとの間の距離の順位が、

上位N件以内にある場合、スコア1とし、

上位N件以内でない場合、スコア0とする

ようにコンピュータを機能させることも好ましい。

【0019】

本発明の類似度算出プログラムにおける他の実施形態によれば、

スコア算出手段は、上位N件の各リファレンス特徴ベクトルとの間の距離に対する、最

10

20

30

40

50

も類似する対象リファレンス特徴ベクトルとの間の距離の順位が、K位に相当する場合、スコアを以下の式によって算出する

$$s_i = \log \{ \frac{1}{(1-\alpha)} \cdot |R_{all}| / (K \cdot |R_i|) + 1 \}$$

α : 調整可能パラメータ

|R_i| : 対象リファレンスコンテンツの中の特徴ベクトルの数

|R_{all}| : リファレンス特徴ベクトル蓄積手段に蓄積された
リファレンス特徴ベクトルの数

ようにコンピュータを機能させることも好ましい。

【0020】

本発明の類似度算出プログラムにおける他の実施形態によれば、

類似度算出手段は、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似した対象リファレンス特徴ベクトルとの対応関係を求め、その対応関係の集合からクエリコンテンツと対象リファレンスコンテンツとの間のHomography行列を算出し、そのHomography行列を満たす対応関係を持つクエリコンテンツの特徴ベクトルについてのスコアのみを合計するようにコンピュータを機能させることも好ましい。

10

【0021】

本発明の類似度算出プログラムにおける他の実施形態によれば、

類似度算出手段は、Homography行列を、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルとの対応関係のうち、スコアが大きい対応関係から順に用いて算出するようにコンピュータを機能させることも好ましい。

20

【0022】

本発明によれば、前述した類似度算出プログラムを用いて、リファレンスコンテンツの集合から、クエリコンテンツに類似したリファレンスコンテンツを検索するように、装置に搭載されたコンピュータを機能させる検索プログラムであって、

リファレンス特徴ベクトル蓄積手段は、複数のリファレンスコンテンツR_jから抽出された各リファレンス特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶しており、

リファレンス特徴ベクトル蓄積手段を用いて、クエリコンテンツの各クエリ特徴ベクトルq_iについて、類似したリファレンス特徴ベクトルをM (> 1) 個探索する類似ベクトル探索手段と、

30

混合パラメータαを用いて、クエリコンテンツの各クエリ特徴ベクトルq_iが、探索された各リファレンスコンテンツから生成される確率α・p(q_i|R_j)と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率(1-α)・p(q_i)との確率比に基づいて、リファレンスコンテンツR_j毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトルq_iについて実行し、最終的に、所定閾値以上の上位のスコアを得たリファレンスコンテンツR_jを、検索結果として出力する投票手段とを有し、

類似度算出プログラムが、投票手段によって出力された各リファレンスコンテンツR_jについて、クエリコンテンツの各クエリ特徴ベクトルとの間の類似度を算出することによって再度順位を並び替える

40

ようにコンピュータを機能させることを特徴とする。

【0023】

本発明の検索プログラムにおける他の実施形態によれば、

投票手段は、クエリコンテンツの特徴ベクトルq_iに対するリファレンスコンテンツjのスコアs_jを、以下の式によって算出する

$$s_j = \log \{ \frac{1}{(1-\alpha)} \cdot |R_{all}| / (a \cdot |R_j|) + 1 \}$$

a : リファレンスコンテンツjの特徴ベクトルが上位M件の中で初めて出現する番号

50

$|R_{all}|$: 全リファレンスコンテンツにおける全特徴ベクトルの数
 $|R_j|$: 当該リファレンスコンテンツ j における全特徴ベクトルの数
 α : 混合パラメータ

ようにコンピュータを機能させることも好ましい。

【0024】

本発明の検索プログラムにおける他の実施形態によれば、
 クエリコンテンツ及びリファレンスコンテンツは、画像であって、
 リファレンスコンテンツとしての画像には、同一の物体又は同一カテゴリに属する少なくとも1つのインスタンス(対象物、オブジェクト)が写っている
 ことも好ましい。

10

【0025】

本発明によれば、特徴ベクトルの集合で表されるクエリコンテンツと対象リファレンス
 コンテンツ R との間の類似度を算出する類似度算出装置であって、

多数のリファレンスコンテンツ R_j から抽出された各特徴ベクトルを記憶したリファレンス特徴ベクトル蓄積手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、リファレンス特徴ベクトル蓄積手段からリファレンス特徴ベクトルの集合を取得し、最も類似するものから順に上位 $N (> 1)$ 件のリファレンス特徴ベクトルを検索するリファレンス特徴ベクトル検索手段と、

クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する対象リファレンス特徴ベクトル検索手段と、

20

クエリコンテンツの各クエリ特徴ベクトルについて、最も類似する対象リファレンス特徴ベクトルとの間の距離が、上位 N 件の各リファレンス特徴ベクトルとの間の距離における上位から何位に相当するかの順位に基づいてスコアを算出するスコア算出手段と、

クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする類似度算出手段と

を有することを特徴とする。

【0026】

本発明によれば、前述の類似度算出装置の全ての機能を含み、リファレンスコンテンツの集合から、クエリコンテンツに類似したリファレンスコンテンツを検索する検索装置であって、

30

リファレンス特徴ベクトル蓄積手段は、複数のリファレンスコンテンツ R_j から抽出された各リファレンス特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶しており、

リファレンス特徴ベクトル蓄積手段を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i について、類似したリファレンス特徴ベクトルの集合 D を、少なくとも1つ以上探索する類似ベクトル探索手段と、

混合パラメータ α を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i が、探索された各リファレンスコンテンツから生成される確率 $\alpha \cdot p(q_i | R_j)$ と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率 $(1-\alpha) \cdot p(q_i)$ との確率比に基づいて、リファレンスコンテンツ R_j 毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトル q_i について実行し、最終的に、所定閾値以上の上位のスコアを得たリファレンスコンテンツ R_j を、検索結果として出力する投票手段と

40

を有し、

類似度算出プログラムが、投票手段によって出力された各リファレンスコンテンツ R_j について、クエリコンテンツの各クエリ特徴ベクトルとの間の類似度を算出することによって再度順位を並び替える

ことを特徴とする。

【0027】

本発明によれば、特徴ベクトルの集合で表されるクエリコンテンツと対象リファレンス

50

コンテンツ R との間の類似度を算出する装置における類似度算出方法であって、

多数のリファレンスコンテンツ R_j から抽出された各特徴ベクトルを記憶したリファレンス特徴ベクトル蓄積部を有し、

クエリコンテンツの各クエリ特徴ベクトルについて、リファレンス特徴ベクトル蓄積部からリファレンス特徴ベクトルの集合を取得し、最も類似するものから順に上位 $N (> 1)$ 件のリファレンス特徴ベクトルを検索する第 1 のステップと、

クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する第 2 のステップと、

クエリコンテンツの各クエリ特徴ベクトルについて、最も類似する対象リファレンス特徴ベクトルとの間の距離が、上位 N 件の各リファレンス特徴ベクトルとの間の距離における上位から何位に相当するかの順位に基づいてスコアを算出する第 3 のステップと、

クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする第 4 のステップと

を有することを特徴とする。

【 0 0 2 8 】

本発明によれば、前述の類似度算出方法の全てのステップを含み、リファレンスコンテンツの集合から、クエリコンテンツに類似したリファレンスコンテンツを検索する装置における検索方法であって、

リファレンス特徴ベクトル蓄積部は、複数のリファレンスコンテンツ R_j から抽出された各リファレンス特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶しており、

第 1 のステップの前段として、

リファレンス特徴ベクトル蓄積手段を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i について、類似したリファレンス特徴ベクトルの集合 D を、少なくとも 1 つ以上探索する第 0 1 のステップと、

混合パラメータ α を用いて、クエリコンテンツの各クエリ特徴ベクトル q_i が、探索された各リファレンスコンテンツから生成される確率 $\alpha \cdot p(q_i | R_j)$ と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率 $(1 - \alpha) \cdot p(q_i)$ との確率比に基づいて、リファレンスコンテンツ R_j 毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトル q_i について実行し、最終的に、所定閾値以上の上位のスコアを得たリファレンスコンテンツ R_j を、検索結果として出力する第 0 2 のステップとを更に有し、

第 1 から第 4 のステップを実行することによって、第 0 2 のステップによって出力された各リファレンスコンテンツ R_j について、クエリコンテンツの各クエリ特徴ベクトルとの間の類似度を算出し、再度順位を並び替える

ことを特徴とする。

【発明の効果】

【 0 0 2 9 】

本発明のプログラム、装置及び方法によれば、クエリ特徴ベクトルから見て、複数のリファレンス特徴ベクトルとの間の距離の分布に基づいて、クエリコンテンツと対象リファレンスコンテンツとの間の類似度を正確に算出することができる。

【図面の簡単な説明】

【 0 0 3 0 】

【図 1】従来技術におけるクエリコンテンツと対象リファレンスコンテンツとの間の類似度を算出する画像対応図である。

【図 2】本発明における類似度算出装置の機能構成図である。

【図 3】本発明におけるスコアの算出を表す第 1 の画像対応図である。

【図 4】本発明におけるスコアの算出を表す第 2 の画像対応図である。

【図 5】本発明におけるスコアの算出を表す第 3 の画像対応図である。

【図 6】クエリコンテンツのスコアとして加算される、クエリ特徴ベクトルと対象リファ

10

20

30

40

50

レンス特徴ベクトルとの間のマッチングを表す画像対応図である。

【図 7】 Homography 行列に基づく inlier 及び outlier を表す画像対応図である。

【図 8】 本発明における検索装置の機能構成図である。

【図 9】 複数のリファレンスコンテンツの複数の特徴ベクトルから投票する説明図である。

【発明を実施するための形態】

【0031】

以下では、本発明の実施の形態について、図面を用いて詳細に説明する。特に、以下のよう
に 2 つの実施の形態に区分して説明する。

<クエリコンテンツと対象リファレンスコンテンツとの間の類似度の算出>

10

<クエリコンテンツに類似するリファレンスコンテンツの検索>

【0032】

<クエリコンテンツと対象リファレンスコンテンツとの間の類似度の算出>

本発明は、基本的に、特徴ベクトルの集合で表されるクエリコンテンツと対象リファレン
スコンテンツとの間の類似度を算出するプログラム、装置及び方法に関する。

【0033】

図 2 は、本発明における類似度算出装置の機能構成図である。

【0034】

図 2 によれば、類似度算出装置 1 は、クエリコンテンツと、対象リファレンスコンテン
ツとを入力し、2 つのコンテンツ間の類似度を算出する。クエリコンテンツ及びリファレン
スコンテンツは、例えば画像である。この場合、リファレンスコンテンツとしての画像
には、同一の物体又は同一カテゴリに属する少なくとも 1 つのインスタンス（対象物、オ
ブジェクト）が写っている。

20

【0035】

類似度算出装置 1 は、リファレンス特徴ベクトル蓄積部 10 と、特徴ベクトル集合抽出
部 11 と、リファレンス特徴ベクトル検索部 12 と、対象リファレンス特徴ベクトル検索
部 13 と、スコア算出部 14 と、類似度算出部 15 とを有する。これら機能構成部は、装
置に搭載されたコンピュータを機能させるプログラムを実行することによって実現される
。また、これら機能の処理順序は、類似度算出方法としても理解できる。

【0036】

30

[リファレンス特徴ベクトル蓄積部 10]

リファレンス特徴ベクトル蓄積部 10 は、多数のリファレンスコンテンツから抽出され
た各特徴ベクトルを記憶する。

【0037】

[特徴ベクトル集合抽出部 11]

特徴ベクトル集合抽出部 11 は、1 つのマルチメディアコンテンツから、特徴ベクトル
の集合を抽出する。例えばマルチメディアコンテンツが画像である場合、その特徴ベクト
ルは、画像の局所特徴領域から抽出された局所特徴ベクトルである。

【0038】

特徴ベクトル集合抽出部 11 は、具体的には、クエリコンテンツからクエリ特徴ベクト
ルの集合 $Q (= \{q_j\})$ を抽出し、それらクエリ特徴ベクトルの集合 Q は、リファレンス
特徴ベクトル検索部 12 及び対象リファレンス特徴ベクトル検索部 13 へ出力される。

40

また、特徴ベクトル集合抽出部 11 は、対象リファレンスコンテンツから対象リファレン
ス特徴ベクトルの集合 $R (= \{R_j\})$ を抽出し、それらリファレンス特徴ベクトルの集
合 R は、対象リファレンス特徴ベクトル検索部 13 へ出力される。尚、クエリコンテン
ツのクエリ特徴ベクトルと、対象リファレンスコンテンツの対象リファレンス特徴ベクトル
とは、同じ次元数である。

【0039】

物体認識に用いる特徴ベクトルの抽出アルゴリズムとしては、例えば SIFT や SURF
(Speeded Up Robust Features) が用いられる。例えば、SIFT の場合、1 枚の画像が

50

らは128次元の特徴ベクトルの集合が抽出される(例えば非特許文献4参照)。SIFTとは、スケール空間を用いて特徴的な局所領域を解析し、そのスケール変化及び回転に不変となる特徴ベクトルを記述する技術である。一方で、SURFの場合、SIFTよりも高速処理が可能であって、1枚の画像から64次元の特徴ベクトルの集合が抽出される。

【0040】

[リファレンス特徴ベクトル検索部12]

リファレンス特徴ベクトル検索部12は、クエリコンテンツの各クエリ特徴ベクトルについて、リファレンス特徴ベクトル蓄積部10を参照し、最も類似するものから順に上位N(>1)件のリファレンス特徴ベクトルを検索する。検索されたN件のリファレンス特徴ベクトルは、スコア算出部14へ出力される。

10

【0041】

図3は、本発明におけるスコアの算出を表す第1の画像対応図である。

【0042】

図3によれば、クエリ特徴ベクトル q_i に類似する上位N=8件のリファレンス特徴ベクトルが、破線の円によって囲まれている。即ち、破線の円によって囲まれた上位N=8件のリファレンス特徴ベクトルが検索される。

【0043】

[対象リファレンス特徴ベクトル検索部13]

対象リファレンス特徴ベクトル検索部13は、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルを検索する。図3によれば、クエリ特徴ベクトル q_i に最も類似する対象リファレンス特徴ベクトル r_j が、xによって表されている。検索された最も類似する対象リファレンス特徴ベクトルは、スコア算出部14へ出力される。

20

【0044】

[スコア算出部14]

スコア算出部14は、クエリコンテンツの各クエリ特徴ベクトル q_i について、最も類似する対象リファレンス特徴ベクトル r_j との間の距離dが、上位N件の各リファレンス特徴ベクトルとの間の距離 $d_1 \sim d_N$ における上位から何位(=K)に相当するかの順位に基づいてスコア s_i を算出する。

30

【0045】

スコア算出部14は、最も簡単な第1の方法として、上位N件の各リファレンス特徴ベクトルとの間の距離に対する、最も類似する対象リファレンス特徴ベクトルとの間の距離dの順位が、上位N件以内にあるか否かによって、スコア s_i を付与する。例えば以下のようである。

上位N件以内にある場合($d_1 \leq d \leq d_N$) ->スコア $s_i = 1$

上位N件以内でない場合($d_N < d$) ->スコア $s_i = 0$

【0046】

スコア算出部14は、他の第2の方法として、上位N件の各リファレンス特徴ベクトルとの間の距離に対する、最も類似する対象リファレンス特徴ベクトルとの間の距離の順位が、K位に相当する場合、スコアを以下の式によって算出するものであってもよい。

40

$$s_i = \log \left\{ \frac{1}{(1 - \alpha) \cdot |R_{all}| / (K \cdot |R|) + 1} \right\}$$

α: 調整可能パラメータ

|R|: 対象リファレンスコンテンツの中の特徴ベクトルの数

|R_{all}|: リファレンス特徴ベクトル蓄積部に蓄積された
リファレンス特徴ベクトルの数

但し、 $d_N < d$ である場合、スコア $s_i = 0$ とする。

【0047】

図3によれば、クエリ特徴ベクトル q_i について、最も類似する対象リファレンス特徴ベクトル r_j との間の距離dが、上位N=8件の各リファレンス特徴ベクトルとの間の距

50

離 $d_1 \sim d_8$ における最上位 ($K = 1$) に相当している。クエリ特徴ベクトルと各リファレンス特徴ベクトルとの間の距離は、 $d < d_1$ のような関係となる。この順位に基づいて、以下の式によって、スコアが算出される。

第 1 の方法： $s_i = 1$

第 2 の方法： $s_i = \log \{ \frac{1}{(1 - \frac{1}{|R|}) \cdot |R|} / (1 \cdot |R| + 1) \}$

【0048】

図 4 は、本発明におけるスコアの算出を表す第 2 の画像対応図である。

【0049】

図 4 によれば、クエリ特徴ベクトル q_i について、最も類似する対象リファレンス特徴ベクトル r_j との間の距離 d が、上位 $N = 8$ 件の各リファレンス特徴ベクトルとの間の距離 $d_1 \sim d_8$ における上から 4 位 ($K = 4$) に相当している。クエリ特徴ベクトルと各リファレンス特徴ベクトルとの間の距離は、 $d_3 < d < d_4$ のような関係となる。この順位に基づいて、以下の式によって、スコアが算出される。

第 1 の方法： $s_i = 1$

第 2 の方法： $s_i = \log \{ \frac{1}{(1 - \frac{1}{|R|}) \cdot |R|} / (4 \cdot |R| + 1) \}$

【0050】

図 5 は、本発明におけるスコアの算出を表す第 3 の画像対応図である。

【0051】

図 5 によれば、クエリ特徴ベクトル q_i について、最も類似する対象リファレンス特徴ベクトル r_j との間の距離 d が、上位 $N = 8$ 件の各リファレンス特徴ベクトルとの間の距離 $d_1 \sim d_8$ における上から 9 位以降に相当している。クエリ特徴ベクトルと各リファレンス特徴ベクトルとの間の距離は、 $d_8 < d$ のような関係となる。このように、上位 $N = 8$ 件以内でない場合 ($d_N < d$)、スコア s_i は、以下のようになる。

第 1 の方法： $s_i = 0$

第 2 の方法： $s_i = 0$

【0052】

[類似度算出部 15]

類似度算出部 15 は、クエリコンテンツにおける全てのクエリ特徴ベクトルのスコアの合計を、類似度とする。

【0053】

図 6 は、クエリコンテンツのスコアとして加算される、クエリ特徴ベクトルと対象リファレンス特徴ベクトルとの間のマッチングを表す画像対応図である。

【0054】

ここで、他の実施形態として、単に全てのクエリ特徴ベクトルのスコアの合計を、類似度とすることなく、特定のスコアのみを加算することも好ましい。具体的には、クエリコンテンツとリファレンスコンテンツとの間で Homography 行列を算出し、その行列を満たすマッチングのみを、スコアに加算する。

【0055】

最初に、類似度算出部 15 は、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似した対象リファレンス特徴ベクトルとの対応関係を求める。これは、スコア算出部 14 におけるクエリ特徴ベクトルと対象リファレンス特徴ベクトルとのマッチング結果から得られる。

【0056】

次に、類似度算出部 15 は、その対応関係の集合からクエリコンテンツと対象リファレンスコンテンツとの間の Homography 行列を算出する。クエリコンテンツと対象リファレンスコンテンツとは、類似度が高いほど、特徴ベクトル同士は、射影幾何学的に線形となる。従って、平面射影変換行列である Homography 行列 H によって、座標を置き換えることができる。Homography 行列 H は、以下のよう表される。

10

20

30

40

【数 1】

$$\begin{bmatrix} x_2 \\ y_2 \\ 1 \end{bmatrix} = \begin{bmatrix} h_0 & h_1 & h_2 \\ h_3 & h_4 & h_5 \\ h_6 & h_7 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \\ 1 \end{bmatrix}$$

$$x_2 = \frac{h_0 x_1 + h_1 y_1 + h_2}{h_6 x_1 + h_7 y_1 + 1}$$

$$y_2 = \frac{h_3 x_1 + h_4 y_1 + h_5}{h_6 x_1 + h_7 y_1 + 1}$$

$$H = \begin{bmatrix} h_0 & h_1 & h_2 \\ h_3 & h_4 & h_5 \\ h_6 & h_7 & h_8 \end{bmatrix}$$

10

【0057】

Homography行列Hの未知パラメータ数は、8個($h_0 \sim h_7$)であり、一組の対応点は2個の式を与える。従って、4組以上の対応点があれば、最小二乗法によってこの行列を計算することができる。即ち、マッチング結果の中で、ランダムに4組を選択し、その4組からHomography行列を算出する。

20

【0058】

類似度算出部15は、そのHomography行列を用いて、クエリコンテンツの各点を射影した際に、以下のように判定する。

(1) マッチング結果となるリファレンス特徴ベクトルに対して所定閾値以下の近くに射影されれば、inlierと判定する。

(2) 逆に、所定閾値よりも遠くに射影されれば、outlierと判定する。

この処理を複数回実行した後、inlierの数が最も多かったHomography行列のみを採用する。

【0059】

図7は、Homography行列に基づくinlier及びoutlierを表す画像対応図である。outlierは、破線で表されている。

30

【0060】

尚、従来技術として、Homographyを算出する際に、一度に全てのマッチングを利用するのではなく、信頼度の高いマッチングを優先的に利用する技術が提案されている(例えば非参考文献8参照)。この技術によれば、信頼度として、クエリ特徴ベクトルとリファレンス特徴ベクトル間の距離を利用している。しかしながら、特徴ベクトルの密度が均一ではないために、単純な距離は信頼度の指標としては適切ではない。これに対し、本発明によれば、スコア s_i を信頼度として利用し、 s_i の高いマッチングから優先的に利用してHomography行列を算出することによって高精度化を実現する。

【0061】

最後に、類似度算出部15は、そのHomogprahy行列を満たす対応関係を持つクエリコンテンツの特徴ベクトルについてのスコアのみを合計する。

40

【0062】

また、類似度算出部15が、outlierのマッチングをスコアに加算しないようにすることによって、精度の高いマッチングを得ることができる。図6からも明らかとおり、Homography行列と整合性のとれる(=inlierとなる)マッチング結果に対応するスコアのみを、合計する。

【0063】

通常、従来技術によれば、inlierとなるマッチング数をスコアとするのに対し、本発明では、更に、inlierとなるマッチングそれぞれにもスコア s_i を導入することによって、

50

信頼性の高いスコアを算出することができる。即ち、本発明によれば、それらのマッチングのスコア s_i の合計を利用する。

【0064】

また、他の実施形態として、類似度算出部15は、Homography行列を、クエリコンテンツの各クエリ特徴ベクトルについて、対象リファレンスコンテンツにおける最も類似する対象リファレンス特徴ベクトルとの対応関係のうち、スコアが大きい対応関係から順に用いて算出するものであってもよい。

【0065】

<クエリコンテンツに類似するリファレンスコンテンツの検索>

本発明は、前述した類似度算出機能を用いて、大量のリファレンスコンテンツの中から、クエリコンテンツに類似するリファレンスコンテンツを検索するプログラム、装置及び方法を実現することもできる。

【0066】

図8は、本発明における検索装置の機能構成図である。

【0067】

検索装置2は、多数のリファレンスコンテンツを予め入力し、リファレンス特徴ベクトル蓄積部10に、リファレンスコンテンツに関する情報を記憶する。また、検索装置2は、検索の際に、検索キーとなるクエリコンテンツを入力し、リファレンス特徴ベクトル蓄積部10を用いて、クエリコンテンツに最も類似するリファレンスコンテンツを検索する。

【0068】

図8によれば、検索装置2は、図2の類似度算出装置の全ての機能を含んでおり、類似ベクトル探索部21と、投票部22とを更に有する。これら機能構成部は、装置に搭載されたコンピュータを機能させるプログラムを実行することによって実現される。また、これら機能の処理順序は、検索方法としても理解できる。

【0069】

[特徴ベクトル集合抽出部11]

特徴ベクトル集合抽出部11は、リファレンスコンテンツ毎に特徴ベクトルの集合を抽出し、それら特徴ベクトルの集合をリファレンス特徴ベクトル蓄積部10へ出力する。また、特徴ベクトル集合抽出部11は、クエリコンテンツから特徴ベクトルの集合 $Q (= \{q_i\})$ を抽出し、それら特徴ベクトルの集合を類似ベクトル探索部21へ出力する。尚、リファレンスコンテンツの特徴ベクトルと、クエリコンテンツの特徴ベクトルとは、同じ次元数である。

【0070】

[リファレンス特徴ベクトル蓄積部10]

リファレンス特徴ベクトル蓄積部10は、複数のリファレンスコンテンツ R_j から抽出された各特徴ベクトルに対応付けて、リファレンスコンテンツ識別子を記憶する。

【0071】

尚、以下の実施形態によれば、複数のリファレンスコンテンツ j から特徴ベクトルの集合 R_j を抽出した場合について詳述している。一方で、例えば非特許文献6のように、特徴ベクトルの集合 R_j を、特定のカテゴリに基づく特徴ベクトルの集合とすることによって、クエリコンテンツを、カテゴリに分類することもできる。この場合、後述するように、クエリコンテンツに対して、各カテゴリに対するスコアを算出し、最もスコアの高い上位複数件のカテゴリに分類するか、スコアが一定以上のカテゴリのタグを付加することができる。

【0072】

[類似ベクトル探索部21]

類似ベクトル探索部21は、リファレンス特徴ベクトル蓄積部10を用いて、クエリコンテンツの各特徴ベクトル q_i について、類似した特徴ベクトルを持つリファレンスコンテンツの特徴ベクトルの上位 $A (\quad 1)$ 件を探索する。クエリコンテンツの特徴ベクトル

q_i と、リファレンスコンテンツの特徴ベクトルとの間の距離が短いほど、類似度が高いことを意味する。具体的には、最近傍探索(Approximate Nearest Neighbor)アルゴリズムの1つである直積量子化を用いた方法(例えば非特許文献5参照)やHamming Embeddingを用いた方法(例えば非特許文献2参照)、LSH(Locality-Sensitive Hashing)を用いることも好ましい。探索された1つ以上の特徴ベクトルの集合Dに基づくリファレンスコンテンツIDは、投票部22へ出力される。

【0073】

[投票部22]

投票部22は、リファレンスコンテンツ R_j 毎にスコアを加算することを、当該クエリコンテンツの全ての特徴ベクトル q_i について実行し、最終的に、所定閾値以上の上位のスコアを得たリファレンスコンテンツ R_j を、検索結果として出力する。投票部22は、従来技術によればIDFによって投票していたのに対し、本発明によれば、以下に詳述する算出式によって投票される。

10

【0074】

本発明によれば、クエリコンテンツを生成したであろう可能性の最も高いリファレンスコンテンツ j' を導出する。以下の式は、事後確率を意味し、クエリコンテンツが、 j 番目のリファレンスコンテンツから生成されたであろう確率 p を表す。

$$j' = \operatorname{argmax}_j p(R_j | Q)$$

Q : クエリコンテンツの特徴ベクトルの集合

R_j : j 番目のリファレンスコンテンツの特徴ベクトルの集合

$p(R_j | Q)$: クエリコンテンツの特徴ベクトルの集合 Q から、

リファレンスコンテンツの特徴ベクトルの集合 R_j が生成される事後確率

argmax_j : 右項の事後確率を最大とする j を導出することを意味する

20

【0075】

前述の事後確率の式は、一般的に、ベイズの定理を用いて以下の式が成立する。これは、事前確率に尤度確率を乗算することによって、事後確率を算出するものである。

$$j' = \operatorname{argmax}_j p(R_j | Q) = \operatorname{argmax}_j p(Q | R_j) p(R_j)$$

$p(Q | R_j)$: リファレンスコンテンツの特徴ベクトルの集合 R_j から、クエリコンテンツの特徴ベクトルの集合 Q が生成される尤度確率

$p(R_j)$: リファレンスコンテンツの特徴ベクトルの集合 R_j が検索される事前確率

30

($p(R_j)$ が高いほど、検索される確率が高いことを意味する)

【0076】

尚、ここで、検索されるリファレンスコンテンツには偏りがなく、 $p(R_j)$ は、いずれの j であっても一定であると仮定する。そうすると、 $p(R_j)$ を削除することができ、単に以下のように表される。

$$j' = \operatorname{argmax}_j p(Q | R_j)$$

【0077】

ここで、クエリコンテンツの特徴ベクトルの集合 Q は、独立に生成されたものであると仮定する。「独立に生成」とは、ある特徴が出た場合、次に必ず特定の特徴が出るような影響が無い、即ち、以前の結果に影響しないことを意味する。この場合、クエリコンテンツの特徴ベクトルの集合 Q の各特徴ベクトル $q_1, q_2, q_3, \dots, q_n$ の個々に基づく確率の積となる。この場合、以下の式によって表される。

40

$$j' = \operatorname{argmax}_j \prod_{i=1}^n p(q_i | R_j)$$

【0078】

更に、確率の積は、一般に、 \log の和によって表すことができる。単調増加関数であるために、確率の大小関係は維持されるためである。この場合、以下の式によって表される。

$$j' = \operatorname{argmax}_j \prod_{i=1}^n p(q_i | R_j) = \operatorname{argmax}_j \sum_{i=1}^n \log p(q_i | R_j)$$

【0079】

50

ここで、各クエリ特徴ベクトルが、リファレンスコンテンツの特徴ベクトル集合から生成された確率と、リファレンスコンテンツとは無関係な背景モデルから生成された確率の線形結合としてモデル化を行う。

$$j' = \operatorname{argmax}_j \sum_{i=1}^n \log p(q_i | R_j) \\ = \operatorname{argmax}_j \sum_{i=1}^n \log(p(q_i | R_j) + (1 - \alpha) \cdot p(q_i)) \\ = \operatorname{argmax}_j \sum_{i=1}^n (\log(p(q_i | R_j) + (1 - \alpha) \cdot p(q_i)) - \log(1 - \alpha) \cdot p(q_i)))$$

$$= \operatorname{argmax}_j \sum_{i=1}^n \log\{ \alpha / (1 - \alpha) \cdot p(q_i | R_j) / p(q_i) + 1 \}$$

i : クエリコンテンツの特徴ベクトルの ID

α : 線形結合の混合パラメータ

$p(q_i)$: リファレンスコンテンツとは無関係な背景モデルから生成された確率
(クエリコンテンツにおける対象物と無関係な背景画像に基づく)

$$p(q_i | R_j) + (1 - \alpha) \cdot p(q_i) :$$

における $p(q_i | R_j)$ の確率と、 $(1 - \alpha)$ における $p(q_i)$ の確率との和は、全体の確率を意味する

$$- \log(1 - \alpha) \cdot p(q_i) :$$

変形のため全体的なペナルティを引いても、順番は変わらない。

後述する式の変形のためのもの。

$$\alpha / (1 - \alpha) \cdot p(q_i | R_j) / p(q_i) + 1 :$$

" $\log a - \log b = \log a / b$ " に基づいて、式を変形したもの

【0080】

本発明によれば、混合パラメータ α を用いて、クエリコンテンツの各特徴ベクトル q_i が、探索された各リファレンスコンテンツから生成される確率 $\alpha \cdot p(q_i | R_j)$ と、当該リファレンスコンテンツと無関係な背景モデルから生成される確率 $(1 - \alpha) \cdot p(q_i)$ との確率比を用いる。

【0081】

ここで、以下の式のように置く。

$$s_{ij} = \log\{ \alpha / (1 - \alpha) \cdot p(q_i | R_j) / p(q_i) + 1 \}$$

i : クエリコンテンツの特徴ベクトルの ID

j : リファレンスコンテンツの ID

q_i : クエリコンテンツの特徴ベクトル

R_j : リファレンスコンテンツ

s_{ij} とは、クエリコンテンツ特徴ベクトル q_i が観測された際に、 q_i それぞれが、リファレンスコンテンツ j が得られるスコアを意味する。即ち、 q_i が観測された時点で、それぞれが、リファレンスコンテンツ j から生成された尤もらしさを意味する。

【0082】

そして、クエリコンテンツの特徴ベクトル i 及びリファレンスコンテンツ j の全てについて、「 s_{ij} 」を算出する。そして、スコア $\sum_{i=1}^n s_{ij}$ が最大となるリファレンスコンテンツ R_j を検索結果として選択する。

【0083】

しかしながら、 s_{ij} は、各 i について全ての j について算出しなければならないために、大規模データベースを対象とした場合、その計算量が膨大なものとなる。

【0084】

そこで、本発明によれば、近似法を適用し、クエリコンテンツの特徴ベクトル q_i について、リファレンスコンテンツの特徴ベクトル集合の中から、 q_i に類似した特徴ベクトルの上位 A ($A \geq 1$) 件を抽出する。そして、以下のように s_{ij} の算出を近似する。上位 A 件に対応する特徴ベクトルが含まれるリファレンスコンテンツ R_j のみについて「 s_{ij} 」を算出する

それ以外の R_j については、 $p(q_i | R_j) = 0$ とする

このとき、 $s_{ij} = \log(1) = 0$ となるために、上位 A 件に対応する特徴ベクトルが含まれ

10

20

30

40

50

ないリファレンスコンテンツのスコアは増減しない。

【0085】

そして、上記の上位 A 件の特徴ベクトルを利用して、 $p(q_i | R_j)$ 及び $p(q_i)$ が、k 近傍密度推定法によって算出される。

$$p(q_i | R_j) = 1 / (|R_j| \cdot V_a)$$

$$p(q_i) = a / (|R_{all}| \cdot V_a)$$

R_{all} : リファレンスコンテンツ全ての特徴ベクトル集合

a : リファレンスコンテンツ j の特徴ベクトルが上位 A 件の中で初めて出現する番号

V_a : q_i と a 番目の特徴ベクトルとの距離を半径とする超球 (3 次元以上) の体積 (尚、2 次元であれば面積、1 次元であれば長さを表す)

10

ここで、 $p(q_i)$ は、 $|R_{all}|$ 個 (k 近傍密度推定法における N) のうち、 a 個 (k 近傍密度推定法における k) が落ちる確率を、体積 V_a で割ったものであることを表す。

【0086】

ここで、 V_a を算出する場合、多大な計算量が必要となる。そこで、本発明によれば、 s_{ij} の式に代入することによって、 V_a の項を削除し、以下の式によって算出する。

$$s_{ij} = \log \{ 1 / (1 - \alpha) \cdot (|R_{all}| / a \cdot |R_j|) + 1 \}$$

【0087】

即ち、本発明の投票部 22 は、上位から A 番目までの特徴ベクトルについて、クエリコンテンツの特徴ベクトル q_i に対するリファレンスコンテンツ j のスコア s_j は、以下の式によって算出される。

20

$$s_j = \log \{ 1 / (1 - \alpha) \cdot (|R_{all}| / a \cdot |R_j|) + 1 \}$$

a : リファレンスコンテンツ j の特徴ベクトルが上位 A 件の中で初めて出現する番号

$|R_{all}|$: 全リファレンスコンテンツにおける全特徴ベクトルの数

$|R_j|$: 当該リファレンスコンテンツ j における全特徴ベクトルの数

α : 混合パラメータ

【0088】

[類似ベクトル探索部 21 及び投票部 22 における具体的な処理内容]

以下では、本発明における類似ベクトル探索部 21 及び投票部 22 における具体的な処理内容について詳述する。

30

【0089】

検索の際、クエリコンテンツから特徴ベクトルの集合 Q が抽出され、各特徴ベクトル q_i 毎に、類似したリファレンスコンテンツの特徴ベクトルの上位 A 件が検索される。そして、対応するリファレンスコンテンツ ID に投票する。クエリコンテンツの全ての特徴ベクトル q_i について投票した後、スコアの上位のリファレンスコンテンツ ID を検索結果とする。

【0090】

図 9 は、複数のリファレンスコンテンツの複数の特徴ベクトルから投票する説明図である。

40

【0091】

図 9 によれば、クエリコンテンツの各特徴ベクトルから、直積量子化を用いた方法や Hamming Embedding を用いた方法 (例えば非特許文献 2 参照)、LSH 等のアルゴリズムを用いて、リファレンスコンテンツの上位 A 近傍特徴ベクトルが探索されたものである。

【0092】

(第 1 の特徴ベクトル、 $a = 1$ 番目)

リファレンスコンテンツ ID = 1 :

$$\text{score}_1 = \text{score}_1 + \log \{ 1 / (1 - \alpha) \cdot (|R_{all}| / 1 \cdot |R_1|) + 1 \}$$

(第 2 の特徴ベクトル、 $a = 2$ 番目)

リファレンスコンテンツ ID = 4 :

50

$score_4 = score_4 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 2 |R_1|) + 1 \}$
 (第3の特徴ベクトル、 a = 3 番目)
 リファレンスコンテンツ ID = 1 :
 $\times score_1 = score_1 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 3 |R_1|) + 1 \}$
 リファレンスコンテンツ ID = 1 について、最初に出現した特徴ベクトルではない
 ために、スコアに採用しない。
 (第4の特徴ベクトル、 a = 4 番目)
 リファレンスコンテンツ ID = 5 :
 $score_5 = score_5 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 4 |R_1|) + 1 \}$
 (第5の特徴ベクトル、 a = 5 番目) 10
 リファレンスコンテンツ ID = 4 :
 $score_4 = score_4 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 5 |R_1|) + 1 \}$
 リファレンスコンテンツ ID = 4 について、最初に出現した特徴ベクトルではない
 ために、スコアに採用しない。
 (第6の特徴ベクトル、 a = 6 番目)
 リファレンスコンテンツ ID = 1 :
 $score_1 = score_1 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 6 |R_1|) + 1 \}$
 リファレンスコンテンツ ID = 1 について、最初に出現した特徴ベクトルではない
 ために、スコアに採用しない。
 (第7の特徴ベクトル、 a = 7 番目) 20
 リファレンスコンテンツ ID = 6 :
 $score_6 = score_6 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 7 |R_1|) + 1 \}$
 (第8の特徴ベクトル、 a = 8 番目)
 リファレンスコンテンツ ID = 6 :
 $score_6 = score_6 + \log \{ \frac{1}{(1-)} \cdot (|R_{all}| / 8 |R_1|) + 1 \}$
 リファレンスコンテンツ ID = 6 について、最初に出現した特徴ベクトルではない
 ために、スコアに採用しない。

【0093】

図8によれば、投票部22によって算出された投票結果となるリファレンスIDのリストは、本発明の類似度算出プログラムへ入力される。そして、類似度算出プログラムは、クエリコンテンツと各リファレンスコンテンツとの間の類似度を算出し、最も類似度が高いリファレンスコンテンツを検索結果として出力することができる。 30

【0094】

以上、詳細に説明したように、本発明のプログラム、装置及び方法によれば、クエリ特徴ベクトルから見て、複数のリファレンス特徴ベクトルとの間の距離の分布に基づいて、クエリコンテンツと対象リファレンスコンテンツとの間の類似度を正確に算出することができる。

【0095】

前述した本発明の種々の実施形態について、本発明の技術思想及び見地の範囲の種々の変更、修正及び省略は、当業者によれば容易に行うことができる。前述の説明はあくまで例であって、何ら制約しようとするものではない。本発明は、特許請求の範囲及びその均等物として限定するもののみ制約される。 40


【符号の説明】

【0096】

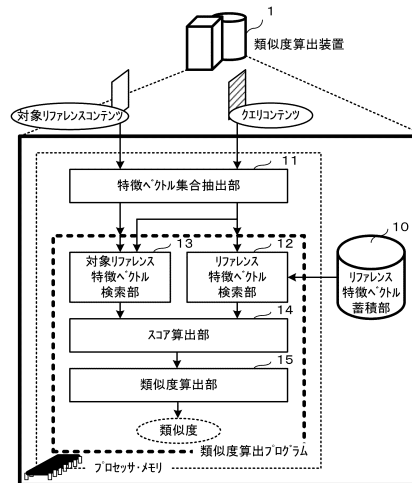
- 1 類似度算出装置
- 10 リファレンス特徴ベクトル蓄積部
- 11 特徴ベクトル集合抽出部
- 12 リファレンス特徴ベクトル検索部
- 13 対象リファレンス特徴ベクトル検索部
- 14 スコア算出部

- 1 5 類似度算出部
- 2 検索装置
- 2 1 類似ベクトル探索部
- 2 2 投票部

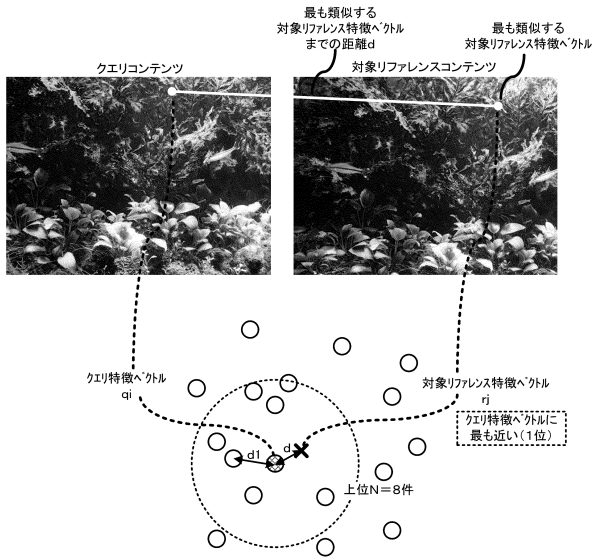
【図 1】



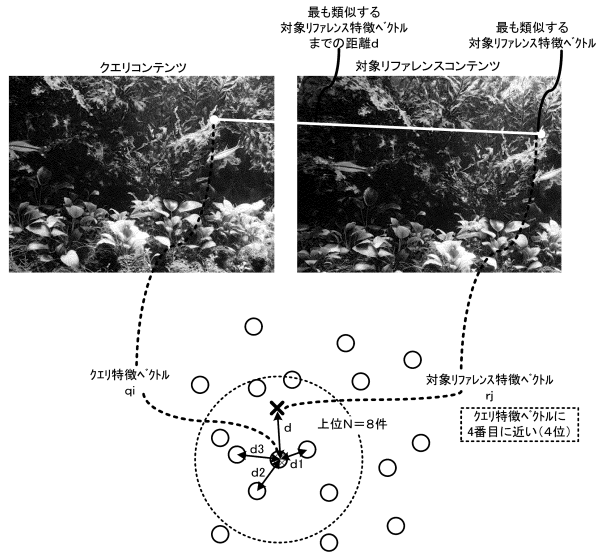
【図 2】



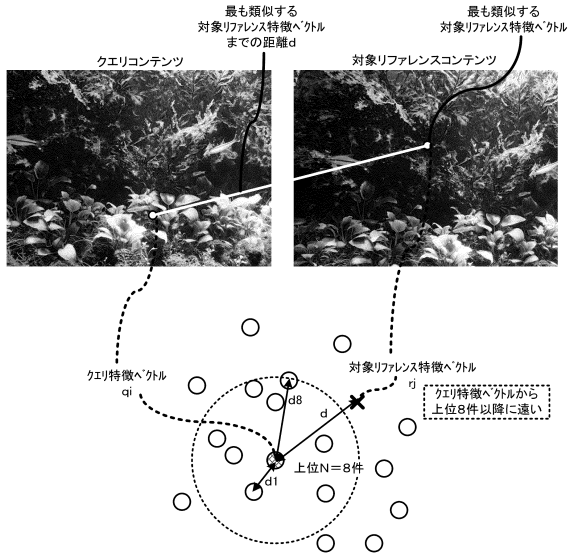
【 図 3 】




【 図 4 】



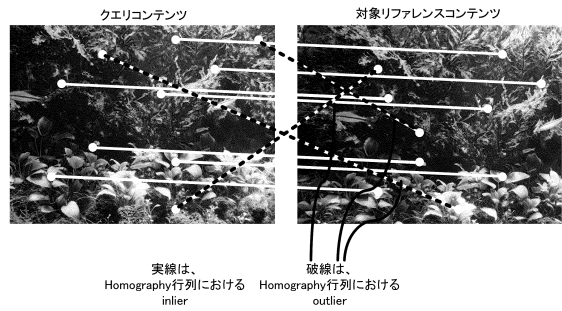
【 図 5 】



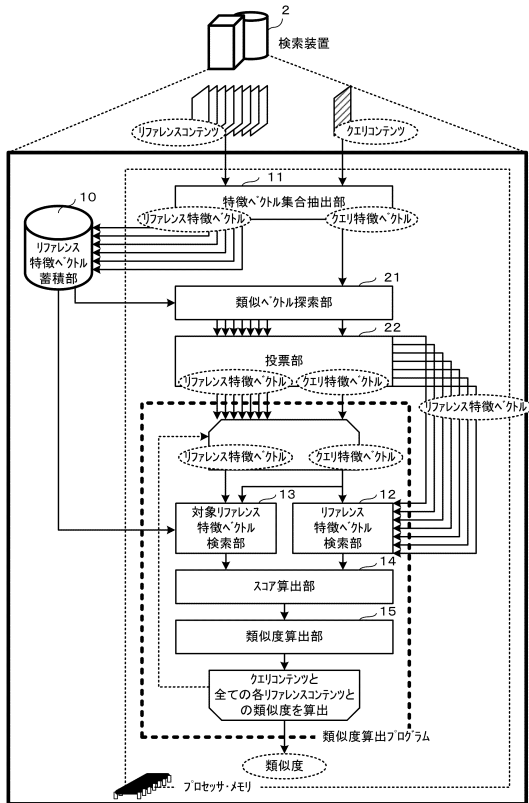
【 図 6 】



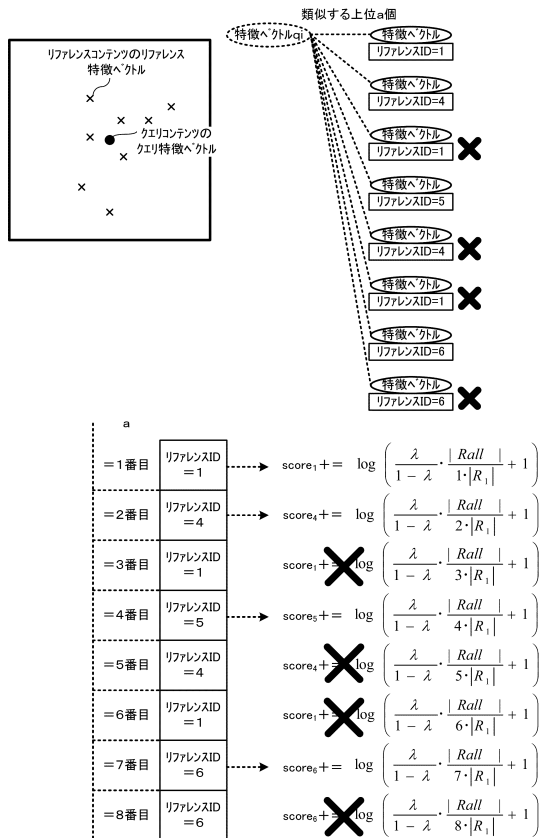
【 図 7 】



【図8】



【図9】



フロントページの続き

(56)参考文献 特開2010-204908(JP,A)
特開2011-113197(JP,A)
特開2004-192555(JP,A)
特開2012-133516(JP,A)

(58)調査した分野(Int.Cl., DB名)
G06F 17/30
G06T 7/00