

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第5259456号
(P5259456)

(45) 発行日 平成25年8月7日(2013.8.7)

(24) 登録日 平成25年5月2日(2013.5.2)

(51) Int.Cl.

G06T 7/00 (2006.01)

F 1

G06T 7/00 350Z
G06T 7/00 250

請求項の数 13 (全 20 頁)

(21) 出願番号 特願2009-48037 (P2009-48037)
 (22) 出願日 平成21年3月2日 (2009.3.2)
 (65) 公開番号 特開2010-204826 (P2010-204826A)
 (43) 公開日 平成22年9月16日 (2010.9.16)
 審査請求日 平成23年9月15日 (2011.9.15)

(73) 特許権者 000003078
 株式会社東芝
 東京都港区芝浦一丁目1番1号
 (74) 代理人 100059225
 弁理士 菊田 琢子
 (74) 代理人 100076314
 弁理士 菊田 正人
 (74) 代理人 100112612
 弁理士 中村 哲士
 (74) 代理人 100112623
 弁理士 富田 克幸
 (72) 発明者 岡田 隆三
 東京都港区芝浦一丁目1番1号 株式会社
 東芝内

最終頁に続く

(54) 【発明の名称】学習装置及び物体検出装置

(57) 【特許請求の範囲】

【請求項1】

入力画像から検出される特徴点が検出対象物体に属するか否かを第1の識別器で識別し、前記検出対象物体に属すると識別された前記特徴点について、学習画像上の相対位置で構成されるパラメータ空間に投票を行って前記検出対象物体を検出する物体検出装置における前記パラメータ空間内の投票位置及び前記第1の識別器を学習する学習装置であって、

前記学習画像中の検出対象物体の特徴点及び非検出対象物体の特徴点をそれぞれ検出する特徴点検出部と、

前記学習画像から検出された前記各特徴点の周辺画像領域における特徴量を計算し、前記検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記検出対象物体のクラスを表すラベルを付与し、前記非検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記非検出対象物体を表すラベルの付与を行う特徴量計算部と、

前記検出対象物体の前記特徴点の前記学習画像上の前記検出対象物体からの相対位置によって、前記パラメータ空間内での投票位置を算出する投票学習部と、

前記学習画像のラベルが付与された前記特徴量を用いて、前記クラスのクラス分布が偏るよう、かつ、前記パラメータ空間への投票位置が集中するよう、前記第1の識別器を学習する識別器学習部と、

を具備し、

10

20

前記識別器学習部は、

前記第1の識別器として複数のランダム木を用い、

前記クラス分布の偏りと、前記パラメータ空間への投票位置の集中の度合いと、が減少するように、前記複数のランダム木の各々の親ノードから子ノードを生成する、
ことを特徴とする学習装置。

【請求項2】

前記識別器学習部は、前記第1の識別器に加えて第2の識別器を学習するものであり、

前記第1の識別器によって、前記ラベル付き特徴量を前記ランダム木で識別することにより、前記検出対象物体として選択された葉ノードで第1の値をとり、それ以外の葉ノードは前記第1の値と異なる第2の値をとり、かつ、複数の前記ランダム木について前記第1の値と前記第2の値を結合した2値ベクトルを求め、10

前記2値ベクトルを前記第2の識別器に入力して、前記第2の識別器を学習させる、
ことを特徴とする請求項1に記載の学習装置。

【請求項3】

前記識別器学習部は、

前記クラス分布のエントロピーの減少度及び前記パラメータ空間における前記投票位置の分散の減少度の重み付き和を用いて前記親ノードの分割を行い、

前記投票位置の分散の減少度に関する重みは検出対象物体割合の関数であり、前記検出対象物体割合は、前記ランダム木の前記ノードに属する全ての前記特徴量の数に対する、前記検出対象物体に対応する前記特徴量の数の割合である、20

ことを特徴とする請求項1又は2に記載の学習装置。

【請求項4】

前記識別器学習部は、

前記各検出対象物体のそれぞれから抽出された前記特徴量である特徴ベクトルの各集合について、前記特徴ベクトルが類似し、かつ、前記投票位置が前記パラメータ空間内で集中するように前記特徴ベクトルをクラスタリングして前記クラスタを求め、

前記非検出対象物体から抽出された前記特徴ベクトルの各集合について、前記特徴ベクトルが類似しているように前記特徴ベクトルをクラスタリングして前記クラスタを求め、

前記各クラスタに属する前記特徴ベクトルの集合を代表する代表特徴ベクトルを計算する、30

ことを特徴とする請求項1に記載の学習装置。

【請求項5】

入力画像から特徴点を検出する特徴点検出部と、

前記特徴点とその周辺画像領域に関する特徴量を計算する特徴量計算部と、

請求項1記載の前記識別器学習部によって学習された前記第1の識別器を用いて、前記特徴量が前記検出対象物体に属するか否かを識別する特徴量識別部と、

前記検出対象物体と識別された前記特徴量に対応する前記特徴点について、請求項1記載の前記投票学習部で学習した前記パラメータ空間内の投票位置に従って、前記検出対象物体のクラスのクラス分布が偏るように、かつ、前記パラメータ空間への投票位置が集中するように投票を行う投票部と、40

前記投票された投票値が高い投票位置に、前記検出対象物体が検出されたとする物体検出部と、

を具備することを特徴とする物体検出装置。

【請求項6】

前記特徴量識別部は、

前記入力画像から得られる各特徴量について、前記第1の識別器で識別して前記2値ベクトルを算出し、

前記2値ベクトルを、請求項3記載の前記第2の識別器に入力して、前記特徴量が前記各検出対象物体に属するか否かを識別する、

ことを特徴とする請求項5に記載の物体検出装置。50

【請求項 7】

前記投票部は、

前記入力画像から得られる各特徴量を前記ランダム木によって前記検出対象物体として識別された葉ノードの前記検出対象物体割合、前記検出対象物体と識別した前記ランダム木の割合に比例する投票値を前記パラメータ空間に投票する、

ことを特徴とする請求項5に記載の物体検出装置。

【請求項 8】

前記投票部は、

前記入力画像から得られる各特徴量を前記ランダム木によって前記検出対象物体として識別された葉ノードの前記検出対象物体割合、前記検出対象物体と識別した前記ランダム木の割合、又は、前記第2の識別器からの前記検出対象物らしさを表す識別値のいずれか、もしくは、これらの組み合わせに比例する投票値を前記パラメータ空間に投票する、

ことを特徴とする請求項6に記載の物体検出装置。

【請求項 9】

前記特徴量計算部は、

前記特徴量として特徴ベクトルを計算し、

前記特徴量識別部は、

前記特徴ベクトルと、請求項5記載の前記識別器学習部で計算した前記代表特徴ベクトルと照合して、最も類似している前記代表特徴ベクトルを選択し、

この選択した前記代表特徴ベクトルに関する前記クラスタを類似クラスタとして抽出し

、前記類似クラスタの一定割合以上が、特定の検出対象物体であった場合に、前記特徴ベクトルは前記特定の検出対象物体に属すると識別し、

前記投票部は、

前記検出対象物体に属すると識別された特徴ベクトルについて、前記類似クラスタに割り当てられ、かつ、請求項1記載の前記投票学習部の学習時に用いた特徴ベクトルを求め

、この求めた前記特徴ベクトルの前記特徴点に関して、請求項1記載の前記投票学習部で学習した前記パラメータ空間内の投票位置を取得し、

前記パラメータ空間内の前記投票位置に投票値を投票を行う、

ことを特徴とする請求項6に記載の物体検出装置。

【請求項 10】

入力画像から検出される特徴点が検出対象物体に属するか否かを第1の識別器で識別し、前記検出対象物体に属すると識別された前記特徴点について、学習画像上の相対位置で構成されるパラメータ空間に投票を行って前記検出対象物体を検出する物体検出方法における前記パラメータ空間内の投票位置及び前記第1の識別器を学習する学習方法であって

、特徴点検出部が、前記学習画像中の検出対象物体の特徴点及び非検出対象物体の特徴点をそれぞれ検出する特徴点検出ステップと、

特徴量計算部が、前記学習画像から検出された前記各特徴点の周辺画像領域における特徴量を計算し、前記検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記検出対象物体のクラスを表すラベルを付与し、前記非検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記非検出対象物体を表すラベルの付与を行う特徴量計算ステップと、

投票学習部が、前記検出対象物体の前記特徴点の前記学習画像上の前記検出対象物体からの相対位置によって、前記パラメータ空間内での投票位置を算出する投票学習ステップと、

識別器学習部が、前記学習画像のラベルが付与された前記特徴量を用いて、前記クラスのクラス分布が偏るよう、かつ、前記パラメータ空間への投票位置が集中するように、前記第1の識別器を学習する識別器学習ステップと、

10

20

30

40

50

を具備し、

前記識別器学習ステップにおいて、

識別器学習部が、前記第1の識別器として複数のランダム木を用い、

前記クラス分布の偏りと、前記パラメータ空間への投票位置の集中の度合いと、が減少するように、前記複数のランダム木の各々の親ノードから子ノードを生成する、

ことを特徴とする学習方法。

【請求項11】

特徴点検出部が、入力画像から特徴点を検出する特徴点検出ステップと、

特徴量計算部が、前記特徴点とその周辺画像領域に関する特徴量を計算する特徴量計算ステップと、

10

特徴量識別部が、請求項10記載の前記識別器学習部によって学習された前記第1の識別器を用いて、前記特徴量が前記検出対象物体に属するか否かを識別する特徴量識別ステップと、

投票部が、前記検出対象物体と識別された前記特徴量に対応する前記特徴点について、請求項1記載の前記投票学習部で学習した前記パラメータ空間内の投票位置に従って、前記検出対象物体のクラスのクラス分布が偏るように、かつ、前記パラメータ空間への投票位置が集中するように投票を行う投票ステップと、

物体検出部が、前記投票された投票値が高い投票位置に、前記検出対象物体が検出されたとする物体検出ステップと、

を具備することを特徴とする物体検出方法。

20

【請求項12】

入力画像から検出される特徴点が検出対象物体に属するか否かを第1の識別器で識別し、前記検出対象物体に属すると識別された前記特徴点について、学習画像上の相対位置で構成されるパラメータ空間に投票を行って前記検出対象物体を検出する物体検出プログラムにおける前記パラメータ空間内の投票位置及び前記第1の識別器を学習する学習プログラムであって、

コンピュータに、

前記学習画像中の検出対象物体の特徴点及び非検出対象物体の特徴点をそれぞれ検出する特徴点検出機能と、

前記学習画像から検出された前記各特徴点の周辺画像領域における特徴量を計算し、前記検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記検出対象物体のクラスを表すラベルを付与し、前記非検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記非検出対象物体を表すラベルの付与を行う特徴量計算機能と、

30

前記検出対象物体の前記特徴点の前記学習画像上の前記検出対象物体からの相対位置によって、前記パラメータ空間内での投票位置を算出する投票学習機能と、

前記学習画像のラベルが付与された前記特徴量を用いて、前記クラスのクラス分布が偏るように、かつ、前記パラメータ空間への投票位置が集中するように、前記第1の識別器を学習する識別器学習機能と、

を実現させ、

40

前記識別器学習機能は、

前記第1の識別器として複数のランダム木を用い、

前記クラス分布の偏りと、前記パラメータ空間への投票位置の集中の度合いと、が減少するように、前記複数のランダム木の各々の親ノードから子ノードを生成する、

学習プログラム。

【請求項13】

コンピュータに、

入力画像から特徴点を検出する特徴点検出機能と、

前記特徴点とその周辺画像領域に関する特徴量を計算する特徴量計算機能と、

請求項12記載の前記識別器学習機能によって学習された前記第1の識別器を用いて、

50

前記特徴量が前記検出対象物体に属するか否かを識別する特徴量識別機能と、

前記検出対象物体と識別された前記特徴量に対応する前記特徴点について、請求項12記載の前記投票学習機能で学習した前記パラメータ空間内の投票位置に従って、前記検出対象物体のクラスのクラス分布が偏るように、かつ、前記パラメータ空間への投票位置が集中するように投票を行う投票機能と、

前記投票された投票値が高い投票位置に、前記検出対象物体が検出されたとする物体検出機能と、

を実現させるための物体検出プログラム。

【発明の詳細な説明】

【技術分野】

10

【0001】

本発明は、画像中に写っている特定の物体を検出し、その位置を推定する物体検出技術とその学習技術に関する。

【背景技術】

【0002】

画像で撮影された特定の検出対象物体を、その姿勢や形状などの画像上の見え方の変化に影響されずに検出するために、検出対象物体が映っている多数の学習サンプル画像から特徴点を検出し、その周辺の画像パターンを検出対象物体の部分パターンとして予め学習しておく方法が提案されている。

【0003】

20

学習サンプル画像の学習時には、この検出対象物体の部分画像パターンから計算した局所特徴量に加えて、局所特徴量に対する検出対象物体の位置、スケール、向き等のパラメータの相対的関係も同時に記憶しておく。

【0004】

検出対象物体の検出時には、入力された画像から学習時と同様の方法で抽出したそれぞれの局所特徴量を、学習時に記憶しておいた各局所特徴量と照合して類似している各局所特徴量を選択し、記憶されている相対パラメータを用いて検出対象物体の種類、位置、スケール、方向等のパラメータ空間に投票を行い、投票値が十分大きい極大点を求ることによって、物体の検出とそのパラメータの推定を行う。

【0005】

30

非特許文献1では、検出対象画像から抽出された局所特徴量と、学習時に記憶しておいた多数の代表的な局所特徴量を照合して類似しているものを選択し、検出対象物体の位置、スケールのパラメータ空間に投票を行って物体を検出している。

【0006】

特許文献1では、KD木によって局所特徴量の照合を高速化している。また、複数の特徴量の組から計算した位置・姿勢パラメータをパラメータ空間に投票し、検出対象物体の位置・姿勢を求めている。

【先行技術文献】

【非特許文献】

【0007】

40

【非特許文献1】B.Leibe,A.Leonardis,B.Schiele,「Robust Object Detection with Interleaved Categorization and Segmentation」,International Journal of Computer Vision, Vol.77, No.1-3, pp.259-289, 2008

【特許文献】

【0008】

【特許文献1】特開2006-65399号公報

【発明の概要】

【発明が解決しようとする課題】

【0009】

上記従来技術では、局所特徴量が検出対象物体の一部なのか、それ以外なのかを識別し

50

てないため、検出対象物体以外の局所特徴量に対しても投票が行われ検出精度が下がるという問題点がある。

【0010】

そこで本発明は、上記問題点を解決するためになされたものであって、検出対象物体を高い検出精度で行える物体検出装置、その方法及びプログラムと、その学習装置、その方法及びそのプログラム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】

【0011】

本発明は、入力画像から検出される特徴点が検出対象物体に属するか否かを第1の識別器で識別し、前記検出対象物体に属すると識別された前記特徴点について、学習画像上の相対位置で構成されるパラメータ空間に投票を行って前記検出対象物体を検出する物体検出装置における前記パラメータ空間内の投票位置及び前記第1の識別器を学習する学習装置であって、前記学習画像中の検出対象物体の特徴点及び非検出対象物体の特徴点をそれぞれ検出する特徴点検出部と、前記学習画像から検出された前記各特徴点の周辺画像領域における特徴量を計算し、前記検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記検出対象物体のクラスを表すラベルを付与し、前記非検出対象物体の前記特徴点の前記周辺画像領域に関する前記特徴量には、前記非検出対象物体を表すラベルの付与を行う特徴量計算部と、前記検出対象物体の前記特徴点の前記学習画像上の前記検出対象物体からの相対位置によって、前記パラメータ空間内での投票位置を算出する投票学習部と、前記学習画像のラベルが付与された前記特徴量を用いて、前記クラスのクラス分布が偏るように、かつ、前記パラメータ空間への投票位置が集中するように、前記第1の識別器を学習する識別器学習部と、を具備し、前記識別器学習部は、前記第1の識別器として複数のランダム木を用い、前記クラス分布の偏りと、前記パラメータ空間への投票位置の集中の度合いと、が減少するように、前記複数のランダム木の各々の親ノードから子ノードを生成する、ことを特徴とする学習装置である。
10

【0012】

本発明は、入力画像から特徴点を検出する特徴点検出部と、前記特徴点とその周辺画像領域に関する特徴量を計算する特徴量計算部と、請求項1記載の前記識別器学習部によつて学習された前記第1の識別器を用いて、前記特徴量が前記検出対象物体に属するか否かを識別する特徴量識別部と、前記検出対象物体と識別された前記特徴量に対応する前記特徴点について、請求項1記載の前記投票学習部で学習した前記パラメータ空間内の投票位置に従つて、前記検出対象物体のクラスのクラス分布が偏るように、かつ、前記パラメータ空間への投票位置が集中するように投票を行う投票部と、前記投票された投票値が高い投票位置に、前記検出対象物体が検出されたとする物体検出部と、を具備することを特徴とする物体検出装置である。
30

【発明の効果】

【0013】

本発明の学習装置によれば、検出対象物体を高い検出精度で行える物体検出装置に用いるパラメータ空間の投票位置及び識別器を学習できる。また、本発明の物体検出装置によれば、検出対象物体を高い検出精度で行える。
40

【図面の簡単な説明】

【0014】

【図1】本発明の第1の実施形態に係る学習装置の構成を示すブロック図である。

【図2】検出対象物体と非検出対象物体に関する特徴点、特徴ベクトル、ラベルの説明図である。

【図3】検出対象物体の画像上の位置、大きさのパラメータに関するパラメータ空間への投票位置の説明図である。

【図4】ランダム木の学習方法を説明する説明図である。

【図5】学習装置のフローチャートである。

【図6】第1の実施形態に係る物体検出装置の構成を示すブロック図である。
50

【図7】物体検出装置の処理の流れを説明する説明図である。

【図8】物体検出装置のフローチャートである。

【図9】第2の実施形態に係る第2の識別器への入力となる二値ベクトルの説明図である。
。

【図10】第3の実施形態におけるパラメータ空間の説明図である。

【発明を実施するための形態】

【0015】

(第1の実施形態)

以下、本発明の第1の実施形態の学習装置と物体検出装置について図面を参照して説明する。

10

【0016】

本実施形態の物体検出装置は、入力画像から検出される特徴点が検出対象物体に属するか否かを識別器で識別する。そして、検出対象物体に属すると識別された各特徴点について、検出対象物体の種類、位置からなるパラメータ空間に投票を行って検出対象物体を検出するものである。

【0017】

一方、本実施形態の学習装置は、前記パラメータ空間の投票位置と、前記物体検出装置において特徴点が検出対象物体に属するか否かを識別するための識別器を、学習画像から学習するものである。

【0018】

20

まず、第1の実施形態の学習装置について図1～図5を参照して説明する。

【0019】

図1は、本実施形態に係わる物体検出装置のための学習装置の構成を示すブロック図である。

【0020】

学習装置は、特徴点検出部1、特徴量計算部2、投票学習部3、識別器学習部4を有する。

【0021】

学習画像は、1つ又は複数の検出対象物体に関する画像群及び検出対象物体以外の物体(以下、「非検出対象物体」という)の画像群で構成される。例えば、図2に示すように、検出対象物体を物体(H)Hと物体(F)Fの2種類とすると、学習画像Aは、物体Hが写っている画像群、物体Fが写っている画像群、物体Hと物体Fが写っていない非検出対象物体の画像群の3クラスで構成される。物体Hと物体Fの検出対象物体の画像群については、各画像について検出対象物体が写っている領域も分かっているものとする。

30

【0022】

学習画像は、記憶装置5に予め記憶しておいてもよく、また、外部から取得してもよい。
。

【0023】

特徴点検出部1は、学習画像のそれぞれから多数の特徴点を検出する。

【0024】

40

特徴点の検出方法としては、一般的な様々な方法を用いることができる。例えば、 Harrisコーナー検出器や、FASTコーナー検出器(E.Rosten and T.Drummond, 'Machine learning for high-speed corner detection,' in Proc. of European Conference on Computer Vision, pp.430-443, 2006参照)等のコーナー検出器を用いる。

【0025】

また、学習画像の解像度を徐々に落としていくことにより生成したピラミッド画像に対して適用することもできる。

【0026】

また、学習画像の拡大縮小のスケール変換に対して不变性を持つ特徴点を用いてもよい。この場合には、Difference of Gaussian(DoG)フィルタ出力の局所極値点を、特徴

50

点として抽出する SIFT 特徴 (D.Lowe, 「Object recognition from local scale-invariant features,」 in Proc.of International Conference on Computer Vision, Vol.2, pp. 1150-1157, 1999 参照、以下、「D. Lowe」という) 等を用いる。

【0027】

特徴量計算部 2 は、図 2 に示すように、特徴点検出部 1 で検出された各特徴点と、その特徴点の周辺画像領域 201 に関する特徴量として特徴ベクトル f を計算する。周辺画像領域 201 の大きさは、例えば縦 24 画素、横 24 画素といった一定の大きさでもよい。

【0028】

また、特徴点検出部 1 において SIFT 特徴のようなスケール不变の特徴量でスケール情報が得られている場合には、このスケール情報に応じた周辺画像領域 201 の大きさを変化させてもよい。周辺画像領域 201 の大きさを変化させる場合は、一定の大きさに正規化してから特徴ベクトル f を計算する。10

【0029】

特徴ベクトル f としては、一般的な様々な特徴量を利用することができる。例えば、画素値を離散化して一次元に並べたものや、又はこれを平均値と分散で正規化したものでも良い。さらに、微小な変化に頑健なヒストグラム特徴として、SIFT 特徴 (D. Lowe 参照) 等を用いてもよい。

【0030】

以下では、このように学習画像から検出された全ての特徴点に関する特徴ベクトル f を「学習特徴ベクトル」と呼び、各検出対象物体の学習画像領域内から検出された特徴点に関する特徴ベクトルを「学習検出物体特徴ベクトル」と呼ぶ。20

【0031】

投票学習部 3 や識別器学習部 4 で使用するため、学習検出物体特徴ベクトルには該当する検出対象物体のクラス (種類) を表すラベル付けを行い、それ以外の特徴ベクトルには非検出対象物体のラベル付けを行う。例えば図 2 の場合、物体 H が写っている画像領域内から抽出された特徴ベクトル f には物体 H のラベル「+1」を付与し、非検出対象物体の画像から検出された特徴ベクトル f には非検出対象物体のラベル「-1」を付与する。

【0032】

投票学習部 3 は、学習検出物体特徴ベクトルに対応する特徴点に関して、投票空間であるパラメータ空間内での投票位置情報を算出して記憶する。30

【0033】

以下では、検出対象物体のクラス (種類) r を表すラベル、画像内の二次元位置 (x, y)、大きさ s の 4 次元のパラメータ空間 (r, x, y, s) を用いて説明する。しかし、その他にも検出対象物体の姿勢、向きなどを加えたより多次元のパラメータ空間を利用してても良い。

【0034】

図 3 (a) は、 x 軸と y 軸の直交二軸で画像位置が決められる画像上に検出対象物体 (掌) H の学習画像領域がある状態を示し、図 3 (b) はパラメータ空間を示している。ただし、4 次元空間を表示できないため、検出対象物体のクラスを示すラベル r を除いた 3 次元のパラメータ空間 (x, y, s) で表している。40

【0035】

検出対象物体のクラス r については、ラベルが特徴空間となり、+1、+2 の 2 つの離散的な投票位置となる。

【0036】

画像内の位置に関する投票位置情報は、図 3 (a) に示すように特徴点から検出対象物体の代表位置への 2 次元の相対ベクトルである。代表位置としては、例えば、検出対象物体の画像領域の重心位置や、外接四角形の中心である。

【0037】

大きさ s は、検出対象画像中の検出対象物体領域の大きさを用いる。例えば、検出対象物体領域を囲む矩形の幅、高さ、もしくはこれらの最大値、対角線の長さ等である。50

【 0 0 3 8 】

なお、位置や大きさについては、特徴ベクトルを計算した局所画像領域の大きさで正規化した相対値を用いても良い。このように、各学習検出物体特徴ベクトルについて、パラメータ空間内の投票位置を割り当てる。

【 0 0 3 9 】

識別器学習部4は、物体検出装置において検出された任意の特徴点が検出対象物体に属するか否かを識別するための識別器を、特徴量計算部2で抽出したラベル付き学習特徴ベクトルを用いて学習する。

【 0 0 4 0 】

識別器として複数のランダム木を用いる。そして、識別器は、各ランダム木の識別性能が高く、すなわち、クラス分布が偏るように、かつ、前記パラメータ空間への投票位置がパラメータ空間内で集中するように構成する。10

【 0 0 4 1 】

任意の特徴量が検出対象物体に属するか否かを識別するためには、各ランダム木の識別性能が高いこと、すなわち、クラス分布が偏ることは必須であるが、これに加えて物体検出装置は検出対象物体の位置や姿勢といったパラメータ空間への投票によって物体検出及びパラメータ推定を行うため、パラメータ空間で投票値が鋭いピークを持つことによって、精度の良い物体検出を行うことが可能となる。このような性質を持ったランダム木の学習は以下のようにして行う。

【 0 0 4 2 】

以下では説明を簡単にするため、検出対象物体が1クラス（1種類）と、非検出対象物体の2クラス（2種類）の問題について図4を参照して説明する。しかし、検出対象物体が2つ以上の多クラスの場合も同様の方法が適用できる。なお、図4では、ランダム木の各ノードの横にクラス分布を示すグラフと、二次元に簡略化したパラメータ空間の図を示す。20

【 0 0 4 3 】

まず、識別器学習部4は、根ノードSに、特徴量計算部2で抽出した全てのラベル付き学習特徴ベクトルfを割り当てる。

【 0 0 4 4 】

識別器学習部4は、この根ノードSを2つに分割して2つの子ノードL、Rを作る際は、次のように行う。まず、図4に示すようにランダムに特徴ベクトルの要素 f_i とその閾値 T_i を生成する。次に、 $f_i < T_i$ を満たすラベル付き学習特徴ベクトルを左の子ノードL（図4のY esの場合）、満たさないラベル付き学習特徴ベクトルは右の子ノードR（図4のN oの場合）に仮に割り当てた場合の分割指標を計算する。分割指標は、分割の良さを表すものであり、後とから説明する。30

【 0 0 4 5 】

識別器学習部4は、この仮割り当ての操作をN回繰り返し、最も良い分割指標を持つ要素 f_i と閾値 T_i の組を選択し、実際にその要素 f_i と閾値 T_i を用いて左右2つの子ノードL、Rを生成する。

【 0 0 4 6 】

識別器学習部4は、以下、再帰的に終了条件を満たすまでこの分割を繰り返す。終了条件としては、次の条件を採用する。第1の条件は、ノードに含まれるラベル付き学習特徴ベクトルの数が予め定めておいた数よりも小さいときである。第2の条件は、木構造の深さが予め定めておいた値よりも大きいときである。第3の条件は、分割の良さを表す指標の減少が予め定めておいた値よりも小さいときである。40

【 0 0 4 7 】

識別器学習部4は、このようなランダム木の生成を行って複数のランダム木を生成する（P.Geurts,D.Ernst, and L. Wehenkel, 「Extremely Randomized Trees,」Machine Learning, No.1, Vol.36, pp.3-42, 2006参照）。

【 0 0 4 8 】1020304050

次に、分割の良さを表す分割指標について説明する。分割指標は、後から説明するクラス分布の偏りとパラメータ空間への投票位置の集中の度合いの2つを統合したものである。

【0049】

まず、クラス分布の偏りについて説明する。

【0050】

分割の良さとして、通常、識別性能が高くなるように上記したクラス分布の偏りを用いる。すなわち、ある分割を行ったことによって、クラス分布の偏りが大きくなつたということは、学習サンプルをうまく識別できたということであり、未知のラベル付き学習特徴ベクトルに関しても識別性能が高いことが期待できる。

10

【0051】

クラス分布の偏りは、エントロピーを用いて評価することができるので、識別性能の高いランダム木を構成するには分割前後のエントロピーをクラス分布の偏りとし、このクラス分布のエントロピーの減少度をG1とすればよい。分割前の親ノードのクラス分布のエントロピーをHc、分割後の左右の子ノードのクラス分布エントロピーをそれぞれHl、Hrとすると、

$$G1 = 2(Hc - Hs) / (Hc + Hs) \quad \dots (1)$$

$$Hs = (nL/n)Hl + (nR/n)Hr \quad \dots (2)$$

20

となる。但し、n、nL、nRはそれぞれ親ノード、左子ノード、右子ノードに含まれる特徴ベクトル数、Hsは分割後のエントロピーである。

【0052】

エントロピー以外の分布の偏りを評価する指標を用いてもよく、例えば、変動係数やジニ係数といった集中度の指標（芳鐘、「計量書誌学的分布における集中度：集中度の概念と指標の特徴」、日本図書館情報学会誌 Vol. 46, No. 1, 2000. p. 18-32参照）を用いても良い。

【0053】

検出対象物体が2つ以上の場合は、3クラス以上の多クラス識別を行う必要があるが、エントロピー等の分布の偏りを評価する指標は多クラスになつても同様に計算することができる。

30

【0054】

次に、パラメータ空間への投票位置の集中の度合いについて説明する。

【0055】

物体検出装置では、検出された特徴量を識別器学習部4で学習した各ランダム木で識別し、選択された葉ノードに含まれている学習特徴ベクトルに割り当てられているパラメータ空間の投票位置に投票を行う。したがつて、各葉ノードから行われる投票位置が、投票空間であるパラメータ空間で集中しているほど、最終的な投票結果もパラメータ空間で鋭いピークを持ち、物体検出性能が向上する。

40

【0056】

投票位置の集中の度合い、言い換えれば、投票位置のばらつきは、分散で評価することができる。そのため、集中した投票を行うランダム木を構成するには、分割前後の各検出対象物体oに関する分散をパラメータ空間への投票位置の集中の度合いとし、この分散の減少度をG2oとすればよい。分割前の検出対象物体oに関する親ノードの投票位置の分散を c_o^2 、分割後の左右の子ノードの投票位置の分散をそれぞれ l_o^2 , r_o^2 とすると、

$$G2o = 2(c_o^2 - s_o^2) / (c_o^2 + s_o^2) \quad \dots (3)$$

50

$$s_o^2 = (n_{Lo} / n_{To}) l_o^2 + (n_{Ro} / n_{To}) r_o^2 \\ \dots (4)$$

となる。但し、 n_{To} 、 n_{Lo} 、 n_{Ro} は、それぞれ親ノード、左の子ノード、右の子ノードに含まれる検出対象物体 o に関する学習検出物体特徴ベクトル数である。

【0057】

パラメータ空間への投票位置の集中の度合いについても、分散だけでなく、標準偏差や平均偏差など別の指標を用いても良い。

【0058】

検出対象物体が2つ以上の場合には、各検出対象物体 o について、パラメータ空間への投票位置の集中の度合い G_{2o} を計算する。 10

【0059】

これらクラス分布の偏りとパラメータ空間への投票位置の集中の度合いを統合した分割指標 G は、下記の式(5)に示すようにクラス分布の偏りの減少度 G_1 とパラメータ空間への投票位置の集中の度合いの減少度 G_2 の重み付き和とする。

【0060】

$$G = G_1 + o(w(o) * G_{2o}) \dots (5)$$

但し、パラメータ空間への投票位置の集中の度合いの減少度 G_{2o} に関する重みは、検出対象物体割合 $o = n_{To} / n$ に関する関数 $w(o)$ を用いる。検出対象物体割合 $o = n_{To} / n$ は、ランダム木の親ノードに属する全学習特徴ベクトル数 n に対する、各検出対象物体 o に関する学習検出物体特徴ベクトル数 n_{To} の割合である。関数 $w(o)$ としては、 $w(o) = o$ 、 $w(o) = a * o$ 、 $w(o) = \max(o - b, 0)$ 等を用いる。ここで、 a と b は予め定められた定数である。 20

【0061】

この分割指標 G を用いることにより、識別性能の高さと投票位置の集中が両立したランダム木を構成することができる。

【0062】

木構造の根ノード S に近いノードでは、検出対象物体割合 o は比較的小さく、識別性能を優先した分割が行われる。木構造の深い部分のノードでは、検出対象物体割合 o が大きいノードと小さいノードができる。しかし、検出対象物体割合 o が大きいノードでは、識別性能の向上（クラス分布の偏り G_1 の増加）が小さくなても、投票位置が散らばっている間はノードの分割が行われ、投票位置を集中させるような分割が続けられる。 30

【0063】

学習装置の処理について、図5のフローチャートを参照して説明する。

【0064】

ステップ1では、特徴点検出部1は、1つ又は複数の検出対象物体に関する画像及び非検出対象物体の画像からなる学習画像が入力され、各学習画像について多数の特徴点を検出する。 40

【0065】

ステップ2では、特徴量計算部2は、図2に示すように特徴点とその周辺画像領域201に関する特徴量を計算すると共に、各検出対象物体の学習画像領域内から検出された特徴点に関する特徴量に該当する検出対象物体のクラスを表すラベル、それ以外の特徴量には非検出対象物体のラベル付けを行う。

【0066】

ステップ3では、投票学習部3は、検出対象物体のラベルが付与されている各特徴点に関して、パラメータ空間内での投票位置を算出して記憶する。

【0067】

ステップ4では、識別器学習部4は、物体検出装置において特徴点が特定の検出対象物 50

体に属するか否かを識別するための識別器を、特徴量計算部2で抽出したラベル付き特徴量を用いて学習する。

【0068】

第1の実施形態の物体検出装置について図6～図8を参照して説明する。

【0069】

図6は、本発明の第1の実施形態に係わる物体検出装置の構成を示すブロック図である。

【0070】

物体検出装置は、画像入力部10、特徴点検出部11、特徴量計算部12、特徴量識別部13、投票部14、検出部15を有する。

10

【0071】

画像入力部10には、カメラ等から画像が入力される。

【0072】

特徴点検出部11と特徴量計算部12は、それぞれ前記学習装置の特徴点検出部1と特徴量計算部2と同様の方法で、図7に示すように入力画像から特徴点を検出し、その周辺の画像領域に関する特徴ベクトル計算する。特徴点検出部11と特徴量計算部12については、前記学習装置と同じ処理を行うので詳細の説明は省略する。

10

【0073】

特徴量識別部13は、前記識別器学習部4によって生成された複数のランダム木を用いて、各特徴量が前記各検出対象物体に属するか否かを識別する。

20

【0074】

投票部14は、特徴量識別部13において検出対象物体と識別された特徴量に対応する特徴点について、投票学習部3で学習したパラメータ空間内の投票位置に従って投票を行う。

【0075】

物体検出部15では、投票結果に基づいて物体検出を行う。

【0076】

特徴量識別部13では、識別器学習部4で学習した複数のランダム木の各ランダム木で、特徴量計算部12で計算した各特徴ベクトルを識別する。

【0077】

30

すなわち、各ノードの分割テスト（例えば $f_i < T_i$ ）で特徴ベクトルを識別し、分割テストを満たせば左のノードに進むといったように、識別結果に応じて木構造を葉ノードに到達するまで下っていく。

【0078】

到達した葉ノードに属する学習特徴ベクトルのラベルをカウントし、最大のラベル数を持つクラスが検出対象物体oであれば、このランダム木による識別結果は検出対象物体oであるとする。

【0079】

このようなランダム木の識別を識別器学習部4で学習した複数のランダム木について行い、検出対象物体oであると識別したランダム木の割合が閾値以上であれば、最終的にその特徴ベクトルを検出対象物体oの一部であると判別する。

40

【0080】

特徴量識別部13において、ある検出対象物体oの一部であると識別された特徴ベクトルについて、特徴ベクトルをランダム木で識別したときに到達した葉ノードが分かれている。

【0081】

投票部14では、到達した葉ノードに割り当てられている検出対象物体oに関する学習検出物体特徴ベクトルについて、投票学習部3で学習しておいた検出対象物体oのパラメータ空間内の投票位置を取得する。

【0082】

50

特に、画像内の位置に関する投票位置情報について説明する。図3に示すように位置に関する投票位置情報は、特徴点から検出対象物体の代表位置への2次元相対ベクトルなので、検出対象物体であると識別された特徴ベクトルに対応する特徴点の画像上の位置にこの相対ベクトルを足した位置に投票を行う。

【0083】

投票値は、各学習検出物体特徴ベクトルについて一定の値でもよいし、到達した葉ノードの検出対象物体割合 α 、特徴量識別部13で検出対象物体 α であると識別したランダム木の割合、これらの積、又はこれらを到達した葉ノードに属する検出対象物体 α に関する学習検出物体特徴ベクトルの数で割って正規化した値等を用いる。

【0084】

特徴量計算部12で検出された特徴ベクトルのうち、特徴量識別部13でいずれかの検出対象物体の一部であると識別された全ての特徴ベクトルについて、各検出対象物体に対応するパラメータ空間に対して以上の投票処理を行う。非特徴物体であると識別された特徴ベクトルについては投票を行わない。

【0085】

物体検出部15では、パラメータ空間の投票値を用いて検出対象物体の検出を行う。

【0086】

単純には、投票値が閾値以上である極大点を検出する。

【0087】

特徴量計算部12で検出された特徴ベクトルの数が画像によって大きくばらつく場合には、前記極大点位置に投票を行った特徴ベクトルの数で極大値を割って投票値の正規化を行ってもよい。

【0088】

物体検出装置の処理について、図8のフローチャートを参照して説明する。

【0089】

ステップ11では、特徴点検出部11は、入力画像から特徴点を検出する。

【0090】

ステップ12では、特徴量計算部12は、特徴点の周辺画像領域201に関する特徴ベクトルを計算する。

【0091】

ステップ13では、特徴量識別部13は、識別器学習部4で学習した識別器である複数のランダム木で、特徴量計算部12で計算した各特徴ベクトルを識別する。

【0092】

ステップ14では、投票部14は、到達した葉ノードに割り当てられている検出対象物体 α に関する学習検出物体特徴ベクトルについて、投票学習部3で学習しておいた検出対象物体 α のパラメータ空間内の投票位置を取得する。

【0093】

ステップ15では、物体検出部15は、パラメータ空間の投票値を用いて検出対象物体の検出を行う。

【0094】

(第2の実施形態)

第2の実施形態に係わる物体検出装置及び学習装置について図9を参照して説明する。

【0095】

第2の実施形態の学習装置について図9を参照して説明する。

【0096】

本実施形態に係わる学習装置では、第1の実施形態において識別器学習部3で学習した複数のランダム木からなる識別器（以下、「第1の識別器」という）に加えて、第2の識別器を学習する。

【0097】

まず、図9に示すように、学習特徴ベクトルを前記第1の識別器の各ランダム木で識別

10

20

30

40

50

した結果、検出対象物体として選択された葉ノードで + 1 の値をとり、それ以外の葉ノードは 0 の値をとり、複数のランダム木についてこれらを結合した 2 値ベクトル g を求める。次に、第 2 の識別器は、この 2 値ベクトル g を入力して学習する。

【 0 0 9 8 】

すなわち、第 2 の識別器の学習には、全てのラベル付き学習特微量ベクトルから計算される 2 値ベクトル g を用いる。第 2 の識別器としては、一般的な識別器を用いることができる。例えば、サポートベクトルマシン、ニューラルネットワーク、AdaBoost 等を用いる。

【 0 0 9 9 】

検出対象物体が 2 つ以上の場合には、第 2 の識別器は 3 クラス以上の多クラス識別を行う必要がある。識別器として 2 クラス識別器を用いる場合には、複数の 2 クラス識別器を組み合わせることによって、多クラス識別を行うことができる。すなわち、あるクラスとそれ以外のクラスを識別する 2 クラス識別器を、各クラス毎に学習しておく方法や、あるクラスと別のあるクラスを識別する 2 クラス識別器を組み合わせの数だけ学習しておく方法などがある。

【 0 1 0 0 】

第 2 の実施形態の物体検出装置について説明する。

【 0 1 0 1 】

第 2 の実施形態に係わる物体検出装置では、特微量識別部 13 において識別器学習部 3 で学習した複数のランダム木である第 1 の識別器と第 2 の識別器によって、特微量計算部 12 で抽出した各特微量ベクトルを識別する。

【 0 1 0 2 】

第 1 の識別器は、第 1 の実施形態と同様の識別を行う。

【 0 1 0 3 】

第 2 の識別器は、検出対象物体らしさを表す識別値を出力するので、この識別値が閾値よりも大きい場合に、特微量ベクトルを検出物体の一部であると識別する。

【 0 1 0 4 】

また、投票部 14 において投票値を計算するとき、第 2 の識別器の識別値をさらに用いてもよい。

【 0 1 0 5 】

(第 3 の実施形態)

第 3 の実施形態に係わる物体検出装置及び学習装置について図 10 を参照して説明する。

【 0 1 0 6 】

第 1 の実施形態で示したように、特微量の識別器として複数のランダム木を用いる以外にも、他の識別器を用いることもできる。第 3 の実施形態では、最近傍識別器を用いる場合について述べる。

【 0 1 0 7 】

第 3 の実施形態の学習装置について図 10 を参照して説明する。

【 0 1 0 8 】

本実施形態に係わる学習装置では、識別器学習部 4 において、全ての学習特微量を k 平均法などのベクトル量子化方法によって k 個のクラスタに分割する。

【 0 1 0 9 】

k 平均法は、任意のベクトルデータに対してランダムにクラスタを割り当てる、この割り当てで各クラスタの平均を計算する。各ベクトルと各クラスタ平均との距離を求め、各ベクトルを最も近い平均値をもつクラスタに割り当てる。上記の処理で全てのベクトルのクラスタへの割り当てるが変化しなかった場合は処理を終了する。それ以外の場合は処理を繰り返す。

【 0 1 1 0 】

識別器学習部 4 では、学習検出物体特微量ベクトルと、非検出対象物体の特微量ベクトルに

10

20

30

40

50

対して別々に k 平均法を適用し、検出対象物体のクラスタと、非検出対象物体のクラスタをそれぞれ K 個、K' 個生成する。

【0111】

学習検出物体特徴ベクトルについて k 平均法を適用するとき、通常の k 平均法では、クラスタに割り当てられた特徴ベクトルの各要素の平均値と、ユークリッド距離が使用されるが、各クラスタに分類された学習検出物体特徴ベクトルの投票位置が集中するように、クラスタ平均値やデータ間の距離を定義する。

【0112】

図 10 に示すように、特徴ベクトルの要素 f_1, f_2 と投票位置 v をつなげた結合ベクトルを定義し、この結合ベクトルの平均とユークリッド距離によって k 平均法を行う。 10

【0113】

これにより、各クラスタは特徴ベクトルが類似しており、投票位置も近い特徴ベクトルの集合となる。各クラスタではクラスタに割り当てられた特徴ベクトルの平均値を計算し、代表特徴ベクトルとする。

【0114】

第 3 の実施形態の物体検出装置について説明する。

【0115】

本実施形態に係わる物体検出装置では、特徴量計算部 12 で抽出した各特徴ベクトルについて、特徴量識別部 13 において識別器学習部 4 で生成した代表特徴ベクトルと照合を最近傍識別器によって行い、距離の近い（複数の）代表特徴ベクトルを選択する。 20

【0116】

選択された代表特徴ベクトルが、非検出対象物体のクラスタである場合には、その特徴ベクトルは非検出対象物体であると識別し、投票を行わない。

【0117】

選択された代表特徴ベクトルが、検出対象物体のクラスタである場合には、その特徴ベクトルは検出対象物体の一部であると識別する。

【0118】

投票部 14 は、検出対象物体の一部であると識別された特徴ベクトルについて、距離の近い代表特徴ベクトルを求める。投票部 14 は、この代表特徴ベクトルに対応するクラスタに割り当てられた学習検出物体特徴ベクトルを求める。そして、投票部 14 は、この学習検出物体特徴ベクトルに関して、投票学習部 3 で学習したパラメータ空間内の投票位置を取得する。投票部 14 は、パラメータ空間内の前記投票位置に投票値を投票を行う。 30

【0119】

投票値は、各学習検出物体特徴ベクトルについて一定の値、代表特徴ベクトルとの類似度、これらをクラスタ内に含まれる学習検出物体特徴ベクトルの数で割って正規化したものの等とする。

【0120】

（変更例）

本発明は上記各実施形態に限らず、その主旨を逸脱しない限り種々に変更することができる。 40

【0121】

なお、上記各実施形態の学習装置と物体検出装置は、例えば、汎用のコンピュータを基本ハードウェアとして用いることでも実現することが可能である。すなわち、学習装置の特徴点検出部 1、特徴量計算部 2、投票学習部 3、識別器学習部 4 及び物体検出装置の画像入力部 10、特徴点検出部 11、特徴量計算部 12、特徴量識別部 13、投票部 14、検出部 15 は、上記のコンピュータに搭載されたプロセッサにプログラムを実行させることにより実現することができる。このとき、学習装置と物体検出装置は、上記のプログラムをコンピュータに予めインストールすることで実現してもよいし、CD-ROMなどの記憶媒体に記憶して、又はネットワークを介して上記のプログラムを配布して、このプログラムをコンピュータに適宜インストールすることで実現してもよい。 50

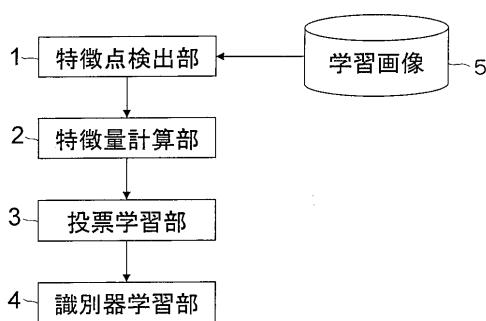
【符号の説明】

【0 1 2 2】

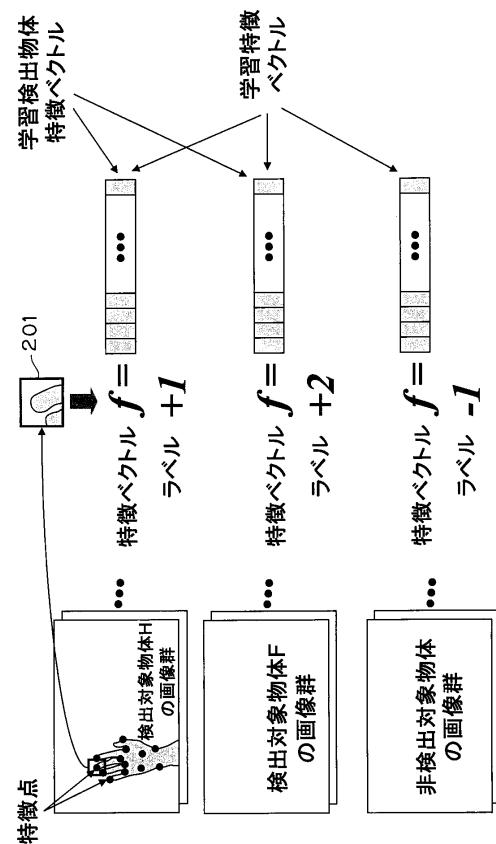
- 1 . . . 特徴点検出部
- 2 . . . 特徴量計算部
- 3 . . . 投票学習部
- 4 . . . 識別器学習部
- 1 0 . . . 画像入力部
- 1 1 . . . 特徴点検出部
- 1 2 . . . 特徴量計算部
- 1 3 . . . 特徴量識別部
- 1 4 . . . 投票部
- 1 5 . . . 検出部

10

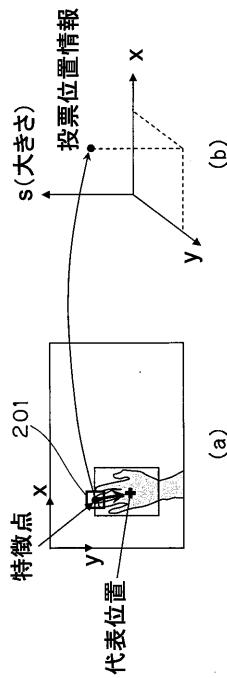
【図1】



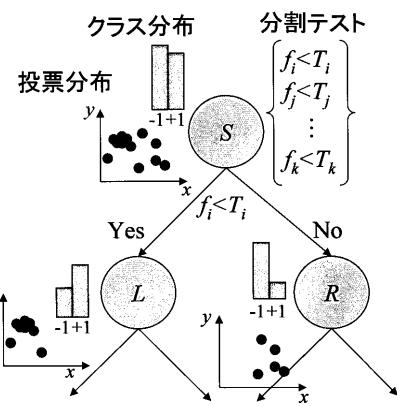
【図2】



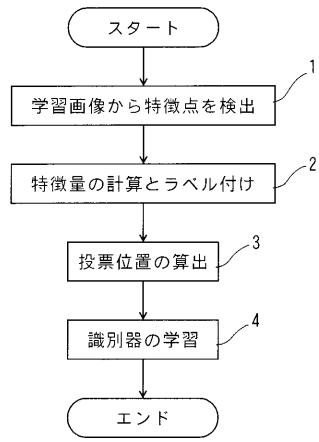
【図3】



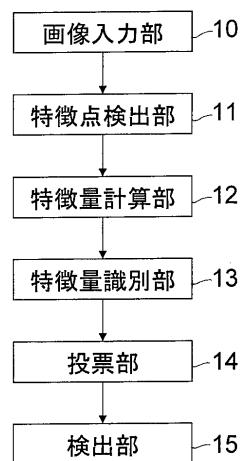
【図4】



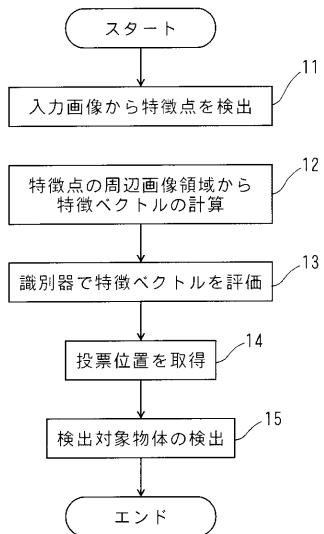
【図5】



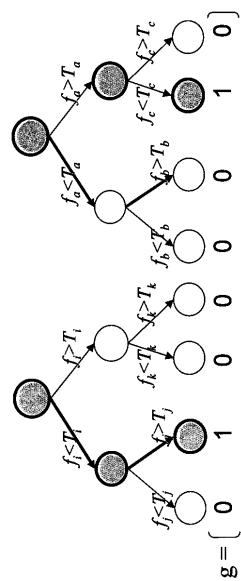
【図6】



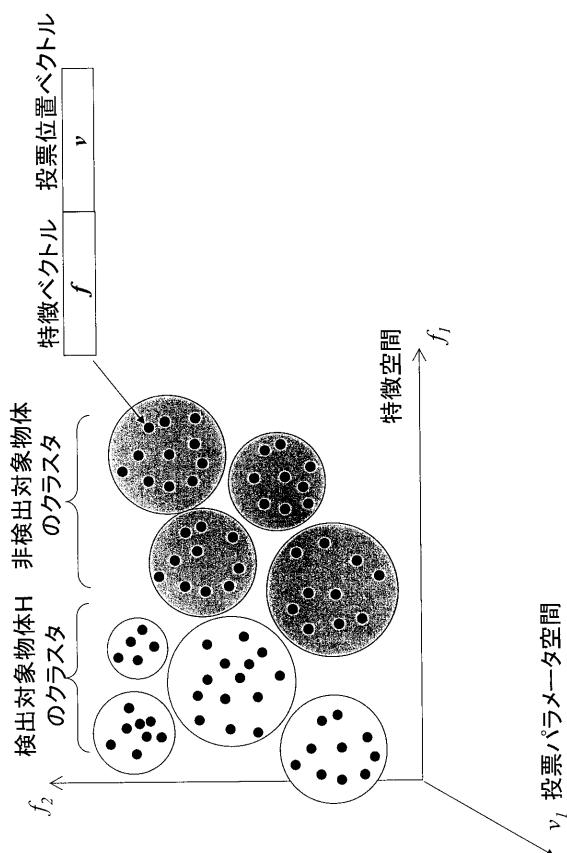
【図 8】



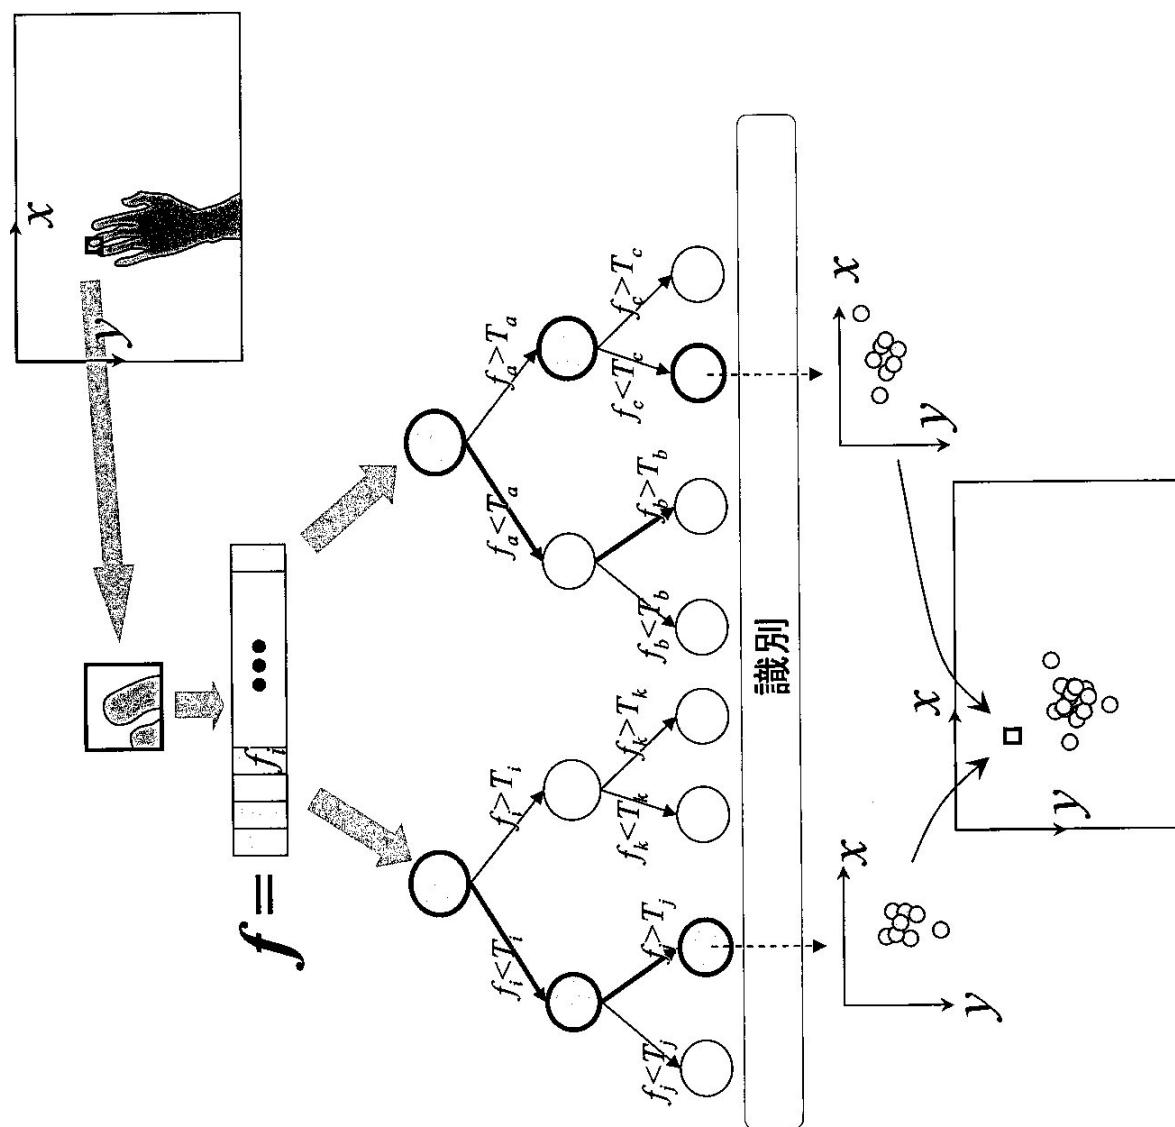
【図 9】



【図 10】



【図7】



フロントページの続き

審査官 板垣 有紀

(56)参考文献 特開平04-175885(JP,A)
特開2008-112211(JP,A)

(58)調査した分野(Int.Cl., DB名)
G06T 7/00