



# 岐阜大学機関リポジトリ

## Gifu University Institutional Repository

Title	PLS回帰分析を用いた一般化Hough変換の研究(若葉研究者の集い16,サマーセミナー2013～画像処理の理論と実際～)(本文(Fulltext))
Author(s)	竹内, 錬磨; 加藤, 邦人; HARWOOD, David; DAVIS, Larry, S.; 鈴木, 孝昌
Citation	[映像情報メディア学会技術報告] vol.[37] no.[36] p.[87]-[90]
Issue Date	2013-08-12
Rights	The Institute of Image Information and Television Engineers (一般社団法人映像情報メディア学会)
Version	出版社版 (publisher version) postprint
URL	<a href="http://hdl.handle.net/20.500.12099/53429">http://hdl.handle.net/20.500.12099/53429</a>

この資料の著作権は、各資料の著者・学協会・出版社等に帰属します。

# PLS 回帰分析を用いた一般化 Hough 変換の研究

竹内 錬磨<sup>†</sup> 加藤 邦人<sup>†</sup> David Harwood<sup>‡</sup> Larry S. Davis<sup>‡</sup> 鈴木 孝昌<sup>†</sup>

<sup>†</sup> 岐阜大学工学部 〒501-1193 岐阜県岐阜市柳戸 1-1

<sup>‡</sup> University of Maryland, A.V. Williams Building, College Park, MD 20742

E-mail: <sup>†</sup> takeuchi@cv.info.gifu-u.ac.jp

**あらまし** 一般的なパターンマッチング手法では、画像内に検出対象物体全体が存在する場合は高い精度で認識することができるが、ノイズや他の物体による隠蔽などにより認識が困難になってしまう。本研究では、ノイズや隠蔽などによる画素の欠落に対して頑健である一般化 Hough 変換に、PLS 回帰分析を組み合わせることで学習機能を付加した。これにより、Hough 変換の枠組みを持ちながら、形状変化に対応した一般物体検出が可能とした。本稿では、衛星写真からの車両検出を例として、新たな物体検出手法を提案するとともに、実験を通して提案手法の有効性について考察する。

**キーワード** 一般化 Hough 変換, PLS 回帰分析, 物体検出

## 1. はじめに

一般化 Hough 変換は、投票処理による大域的な演算を行うため、隠蔽やノイズ等による画素の欠落に対して頑強であるという利点を持つ<sup>[1]</sup>。しかし、形状の変化に弱く、一般的に定形の物体でないとは検出できないという問題点がある。

本稿ではこの解決策として、一般化 Hough 変換に PLS 回帰分析<sup>[2]</sup>を組み合わせることで学習機能を付加し、ノイズや隠蔽に頑強な物体検出を可能にする。また、衛星写真からの車両検出を例として、提案手法の有効性について考察する。

## 2. 提案手法

### 2.1. PLS Hough 変換

提案手法では、自動車の形状を表すモデルデータと学習画像のマッチングと PLS 回帰分析によって回帰係数を求め、それを重みとして投票をする。図 1 に提案手法の処理の流れを示す。

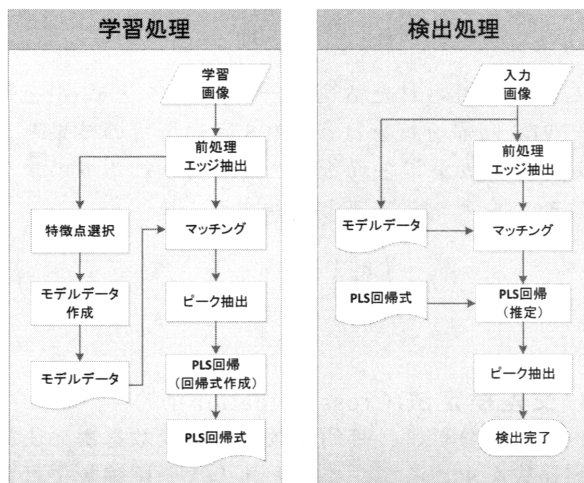


図 1 提案手法の処理

### 2.2. PLS 回帰分析

回帰分析は、入力された特徴量を説明変数、その出力、すなわちクラスを目的変数とすることでパターン認識に応用することができる。

提案手法で用いる PLS 回帰分析は、目的変数と説明変数間のスコアの相関が最大となるように両変数を次元圧縮し、それぞれのスコアを用いて回帰式を推定する。そのため、PLS 回帰分析によって推定された推定値は、目的変数のデータの広がりをよく表すものとなり、クラス分類に適した出力を得ることができる。また、PLS 回帰分析は多重共線性に強いというメリットを持つ。PLS 回帰分析によって得られる回帰式は、入力される特徴量を  $x$ 、推定値を  $y$ 、回帰係数を  $b$  とすると以下ようになる。

$$y = \mathbf{x}b$$

$$y = x_1b_1 + x_2b_2 + \dots + x_nb_n \quad (1)$$

### 2.3. 学習処理

提案手法では、クラス分類に適した PLS 回帰分析を用いて、検出物体のクラス（ポジティブクラス）とその他のクラス（ネガティブクラス）を作成し、学習を行う。



図 2 学習画像

ポジティブクラスを車画像、ネガティブクラスを車両以外のランダムに選択した背景画像とした。図2は学習に使用した車画像と背景画像の一部である。

まず、モデルデータを作成する。モデルデータは、検出物体の形状を表現するデータで、一般化 Hough 変換における R テーブルと同様に、エッジ方向をキーに基準点までのベクトルを登録する。総モデル点数(モデル数×モデル点数)を  $P$  とすると、 $p$  番目のモデル点  $M_p$  は、表1の情報を持つ。

表1 モデルデータの情報

エッジ方向	$\theta_p$
基準点までのベクトル	$(\Delta x_p, \Delta y_p)$

今回は、1枚のモデル画像から、車の特徴をよく表すと考えられる15点を選択し、モデルデータを作成した。図3にモデルデータの作成の様子を示す。




図3 モデルデータの作成

次にモデルデータと学習画像を用いてマッチングを行う。マッチングでは、学習画像中のすべての点に対して、どのモデル点 matches したかを記録し、PLS 回帰分析を行うためのデータを作成する。学習画像中の任意の点  $(i, j)$  についてのマッチング情報を記録する特徴ベクトル  $\mathbf{x}_{(i,j)}$  を以下のように定義する。また、 $\mathbf{x}_{(i,j)}$  のすべての要素を 0 で初期化しておく。

$$\mathbf{x}_{(i,j)} = \begin{pmatrix} x_{1(i,j)} \\ x_{2(i,j)} \\ \vdots \\ x_{P(i,j)} \end{pmatrix} \quad x_{p(i,j)} = \begin{cases} 1 \\ 0 \end{cases} \quad (2)$$

ここで、 $N$  枚の学習画像から学習を行い、 $n$  枚目の学習画像を  $T^n$  とする。まず、マッチングの前処理として  $T^n$  にエッジ抽出処理を行う。 $T^n$  中のエッジ点  $(i, j)$  のエッジ方向が  $\varphi$  のとき、モデルデータから  $\theta_p = \varphi$  となるモデル点  $M_p$  を探索する。マッチするモデル点があったら、投票点  $(i + \Delta x_p, j + \Delta y_p)$  を中心に、誤差を考慮し円領域内の座標群について、特徴ベクトルの  $p$  番目の要素を 1 にする。

$T^n$  のマッチング処理が完了すると、ベクトル  $\mathbf{x}_{(i,j)}$  は、 $x_{p(i,j)}$  が 1 の場合、座標  $(i, j)$  に対して、 $p$  番目のモデル点  $M_p$  から投票が行われたことを表す。

また、特徴ベクトルの各要素の合計値は、対応する座標に対して行われた投票の総数  $v_{(i,j)}$  となる。

$$v_{(i,j)} = \sum_{p=1}^P x_{p(i,j)} \quad (3)$$

このように、すべての座標について投票数を求め、投票値パラメータ空間を生成する。

作成した投票パラメータ空間から学習画像を代表する1点を選択し、対応する特徴ベクトル  $\mathbf{x}_{(i,j)}$  を抽出する。ポジティブデータの場合は、図4のように非極大点抑制を行った後、値を持つ点の中から最も車の中心座標に近いピークを選択する。ネガティブデータの場合は、画像の中心点を選択する。

選択された点の特徴ベクトルには、投票されたモデルデータの番号が 1 で示されている。以上のマッチング処理をすべての学習画像について行う。




図4 二次元パラメータ空間とピーク抽出

全学習画像から得られた特徴ベクトルを行ベクトルとして行列に結合し、PLS 回帰分析の説明変数の入力とする。作成されるデータは  $N \times P$  の行列として表現される。

$$\mathbf{X} = \begin{pmatrix} x_{1,1} & \cdots & x_{1,P} \\ \vdots & \ddots & \vdots \\ x_{N,1} & \cdots & x_{N,P} \end{pmatrix} \quad x_{n,p} = \begin{cases} 1 \\ 0 \end{cases} \quad (5)$$

また、回帰分析を行うためには、各説明変数と対になる目的変数を入力する必要がある。学習処理では、ポジティブクラスとネガティブクラスを分離することが目的であるので、ポジティブデータと対になる説明変数には +1、ネガティブデータと対になる説明変数には -1 を設定する。

$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{pmatrix} \quad y_n = \begin{cases} +1 \\ -1 \end{cases} \quad (6)$$

このよう得られた入力データを式(5)と式(6)を用いて PLS 回帰分析を行う。PLS 回帰分析の結果として回帰係数  $\mathbf{b}$  が得られる。ここで得られる  $\mathbf{b}$  の次元数はモデルデータ数  $P$  と一致する。

$$\mathbf{b} = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_P \end{pmatrix} \quad (7)$$

#### 2.4. 交差検定法(CrossValidation)

PLS 回帰分析は、目的変数と説明変数を次元圧縮し回帰式を求めるが、このときの次元圧縮数には最適な値が存在する。提案手法では、説明変数がモデ

ルデータ数だけの特徴次元数を持つため、それ以下の次元数に圧縮することができる。このときの圧縮次元数は交差検定法を用いて決定した。また、得られた回帰式の評価には二乗平均誤差を用いた。

図5は、交差検定法によって圧縮次元数を決定した際の様子である。図5から圧縮次元数が2次元のときに真値との誤差が最少になっていることが確認でき、最適圧縮数を決定することができる。




図5 交差検定法の様子

## 2.5. 検出処理

検出処理では、入力画像中から検出物体の位置と向いている方向の角度を特定する。

まず、入力画像に対してエッジを抽出し、学習処理と同様にモデルデータを用いてマッチングを行う。マッチングを行うと学習処理と同様、すべての座標について特徴ベクトル  $\mathbf{x}_{(i,j)}$  が得られる。この特徴ベクトル  $\mathbf{x}_{(i,j)}$  と学習処理で作成した回帰係数  $\mathbf{b}$  から、PLS 回帰分析の推定値  $y_{(i,j)}$  を計算する。

$$y_{(i,j)} = \mathbf{x}_{(i,j)} \cdot \mathbf{b} \quad (8)$$

画像中のすべての点について推定値を求め、推定値パラメータ空間とする。このパラメータ空間に対して、非極大点抑制処理、しきい値処理、車の重なり判定を行い、入力画像中の検出物体の位置と角度を特定する。検出処理の全体の様子を図6に示す。

学習処理では  $0^\circ$  方向の車画像のみを学習したため、 $360^\circ$  を任意の分割数で分割し、分割数の回数だけ回転角度を考慮してマッチングを行う。

分割数を  $r$  とすると、回転角度  $\alpha$  は

$$\alpha = 360^\circ \div r \quad (9)$$

となる。このとき、入力画像のエッジ方向  $\varphi$  とモデルデータのエッジ方向  $\theta$  のマッチの判定は式(10)、投票する基準点までのベクトル  $(\Delta x', \Delta y')$  は式(11)のようになる。

$$\theta = \varphi + \alpha \quad (10)$$

$$\begin{pmatrix} \Delta x' \\ \Delta y' \end{pmatrix} = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} \Delta x \\ \Delta y \end{pmatrix} \quad (11)$$

以上のようにして、 $r$  枚のパラメータ平面についてマッチングを行うことで検出を行う。




図6 検出処理

## 3. 実験

### 3.1. 学習処理の検証

学習処理が正しく行われているかを検証する。実験には Google Earth San Francisco Data Set を使用した<sup>[3]</sup>。衛星写真の画像サイズは  $2048 \times 2048$  で、車のサイズは約  $25 \times 50$  である。また、画像枚数は 23 枚である。

このデータベースより、モデル画像を 10 枚、ポジティブデータとして車画像をセダン車のみ 100 枚と、各車画像を左右反転させた画像の計 200 枚、ネガティブデータとしてランダムに選択した背景画像を 50 枚と上下左右の反転画像の計 200 枚を使用して学習を行った。

マッチングで作成した各学習画像の特徴ベクトルを入力とし、PLS 回帰分析を行った。最適次元数は 2 次元となった。また、求めた回帰式を学習画像に適用し、推定値の分布を観察することで、推定値が各クラスごとに分離できているかを確認した。

図7は、推定値を横軸、推定値の累積数縦軸とし、各クラスごとに示したものである。2つのクラスの推定値が完全に分離できていることが確認できた。




図7 学習処理の検証

### 3.2. 検出処理実験

先で求めた学習データを用いて検出処理を行った。このとき回転の分割数を 36、つまり 10 度刻みで検出処理を行った。検出結果の一例を図 8 に示す。



図 8 検出結果

図 8 から、多くの車を検出できていることがわかる。これは、提案手法がノイズや隠ぺいに頑健である Hough 変換の強みを活かしつつ、不定形の物体に対して検出が可能となったことを示している。

また、図 9 はしきい値を 0 に設定したときの正解検出点、検出漏れが起きた点、誤検出点それぞれの推定値によるヒストグラムである。この図から、車の正解点は+1 側に多く分布していることが確認できる。しかし、誤検出点も推定値 0.5 以下から多く分布している。





図 9 推定値ヒストグラム

そこで、しきい値を 0.5 に設定し、全ての画像に対して検出処理を行った。検出結果の正解検出率が最も良かったデータと最も悪かったデータを表 2 に、このときの検出結果画像を図 10 に示す。

表 2 検出結果

	(a) 100.jpg	(b) 3623.jpg
画像中の車数	17	199
総検出数	57	126
正解検出率	94.18%	36.68%
見落とし率	5.82%	63.32%
誤検出数	41	53



(a) 100.jpg (b) 3632.jpg

図 10 検出処理実験

表 2 から(a)は、正解検出率が 94.18%と高く、画像中のほとんどの車を検出することができたことがわかる。これに対して(b)は正解検出率が 36.68%と低くなっている。図 10 より、これらの画像を比較すると、入力 1 は背景のほとんどが砂漠であるのに対して、入力 2 は街の衛星写真である。人工物が多く存在する街の衛星写真では、直線のエッジが抽出されやすく、車と誤認識しやすい。これは、学習が不十分であることが原因として考えられる。

このような理由から、2 枚の入力画像に大きな正解検出率の差が出たのだと考えられる。

また、全データでの結果は表 3 のようになった。

表 3 全画像での検出結果

全画像中の車数	1743
総検出数	2035
正解検出率	56.68%
見落とし率	43.32%
誤検出数	1047

### 4. まとめ

本研究では一般的に隠ぺいやノイズに強いとされている Hough 変換の原理を用いて、物体検出を実現するため、学習困難であるという一般化 Hough 変換の問題点に対し、PLS 回帰分析を導入し学習機能を付加した。これにより、Hough 変化の枠組みを持ちながら、形状変化に対応した物体検出を可能とした。また、実験を通して、提案手法が物体検出の問題に対して有効であることを示した。

### 文 献

- [1] Ballard, D.H.: "Generalizing the Hough Transform to Detect Arbitrary Shapes", Pattern Recognition, Vol. 13, No. 2, pp.111-122 (1981)
- [2] Roman Rosipal, Nicole Krämer: "Overview and Recent Advances in Partial Least Squares", SLSFS 2005, LNCS 3940, pp. 34-51 (2006)
- [3] Aniruddha Kembhavi, Larry S. Davis, David Harwood: " Vehicle Detection Using Partial Least Squares", IEEE Trans of PAMI, Vol. 33, No. 6, pp1250-1265 (2011)