

パーツ選択型 DPM を用いた傘差し歩行者検出手法の検討

新保 祐人[†] 川西 康友[†] 出口 大輔^{††} 井手 一郎[†] 村瀬 洋[†]

[†] 名古屋大学 大学院情報科学研究科 〒464-8601 愛知県名古屋市千種区不老町
^{††} 名古屋大学 情報連携統括本部 情報戦略室 〒464-8601 愛知県名古屋市千種区不老町
E-mail: †shimboy@murase.m.is.nagoya-u.ac.jp, †{kawanishi,ide,murase}@is.nagoya-u.ac.jp,
††ddeguchi@nagoya-u.jp,

あらまし 近年、車載カメラを用いた歩行者検出技術が注目されている。しかし、雨天環境においては傘によって歩行者の頭部が隠蔽されるため、傘差し歩行者の検出精度が低下するという問題がある。本報告では、物体認識の分野で広く用いられている Deformable Part Models (DPM) をベースとし、DPM の本来のパーツフィルタと別途学習したパーツフィルタを選択的に用いて検出を行なうパーツ選択型 DPM を提案する。これにより、傘による頭部の隠蔽に頑健な歩行者検出を実現する。実験の結果、パーツ選択型 DPM による歩行者検出は、通常の DPM による検出と比べて雨天環境において高い精度が得られることを確認し、またパーツフィルタの選択を用いたとしても晴天時の歩行者検出精度には影響を及ぼさないことを確認した。

キーワード 歩行者検出, 雨, DPM, パーツ選択

A study on the detection of a pedestrian holding an umbrella with a Selective DPM

Yuto SHIMBO[†], Yasutomo KAWANISHI[†], Daisuke DEGUCHI^{††},

Ichiro IDE[†], and Hiroshi MURASE[†]

[†] Graduate School of Information Science, Nagoya University
Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8601 Japan

^{††} Information Strategy Office, Nagoya University
Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8601 Japan

E-mail: †shimboy@murase.m.is.nagoya-u.ac.jp, †{kawanishi,ide,murase}@is.nagoya-u.ac.jp,
††ddeguchi@nagoya-u.jp,

Abstract In recent years, pedestrian detection from an in-vehicle camera has been attracting interest. However, in the case of a raining situation, there is a problem that the detection accuracy decreases because the head of a pedestrian tends to be occluded by an umbrella. In this report, as a variation of the deformable part models (DPM) which is widely used in the field of object recognition, we propose “Selective DPM” which selectively chooses the original part filters and additional part filters trained independently. In the detection of a pedestrian holding an umbrella, the selection of head and umbrella parts will make pedestrian detection more robust to the occlusion. We conducted experiments to evaluate the performance of the proposed method. As a result, pedestrian detection with the Selective DPM achieved high detection accuracy in raining situations, compared with the detection by conventional DPM. Moreover, we confirmed that it does not affect the pedestrian detection accuracy in fine weather.

Key words Pedestrian detection, Rain, DPM, Parts selection

1. まえがき

近年、自動車の自動運転に注目が集まっており、その実用化への取り組みが広くなされている。自動運転には、自動車の周囲環境を認識する技術が必要不可欠である。周囲環境の認識の中でも、歩行者の検出は重大な事故の回避のために重要な課題となっている。特に雨天時は、路面が濡れることで自動車の制動距離が増加することや、歩行者自身も傘によって視界が遮られ、雨音により自動車の接近に気がつきにくく危険な状態にある。そのため、晴天時よりも歩行者検出の重要性は高い。しかし、歩行者検出に関する多くの研究は晴天時を前提としており、より危険度の高い雨天時は考慮されていない。晴天時と雨天時の歩行者の見えの違いを図1に示す。雨天時の歩行者は図1(b)のように傘により頭部がしばしば隠蔽されることから、検出精度が低下するという問題がある。そこで本報告では、雨天環境下での歩行者検出の高精度化を目的とし、傘差し歩行者を高精度に検出するための手法について検討した結果を報告する。

近年、画像からの一般物体検出の研究では大量の学習用画像を用意し、機械学習によって検出器を構築する統計的学習手法[2]~[4]が用いられることが多い。その中でもFelzenszwalbらによって提案されたDeformable Part Models (DPM) [1]は、検出対象の多様な姿勢変化に対応可能であり、歩行者検出の研究においても広く用いられている。しかし、傘差し歩行者は通常の歩行者とは異なり、傘によって頭部にオクルージョンが発生する確率が高くなる。通常の歩行者を学習したDPMによって雨天時の歩行者を検出しようとした場合、そのオクルージョンによって検出できない歩行者が晴天時と比べて増加してしまう。このような問題に関して、オクルージョンを含んだ学習画像を用いて検出対象のモデルを学習する手法が提案されている。Tangらは、人と人の重なりをDPMによりモデル化する手法[5]を提案している。この手法は、人と人が重なってしまうような通常の検出器では難しいとされる混雑状況下において高い検出精度を実現している。またPepikらは、オクルージョンにおける「隠すもの」と「隠されるもの」の関係をモデル化している[8]。Pepikらの手法は、特定状況下において高頻度が発生するオクルージョンを考慮することは、物体の検出精度向上につながることを示している。

上述のような考えは、雨天時の歩行者検出にも適用できると考えられる。すなわち、傘を目印として歩行者を検出することにより検出精度の向上が期待できる。そこで本報告では、通常の歩行者を学習したDPMに対して、別途傘を学習したパーツフィルタを明示的に追加し、検出スコアが最も高くなるように頭部と傘のパーツフィルタを選択する処理を加える。これにより、傘差し歩行者を高精度に検出する手法について検討する。

以降、2節では本研究の関連研究としてDPMについて説明する。3節では、DPMの検出スコアの計算時に最もスコアが高くなるようにパーツ選択を行なうパーツ選択型DPMと、それを用いた傘差し歩行者検出について説明する。つづく4節では提案手法の評価実験について述べ、考察を加える。最後に5節で本報告をまとめる。



(a) 晴天時

(b) 雨天時

図1 晴天時と雨天時の歩行者の見えの違い

2. Deformable Part Models (DPM)

2.1 DPMによる物体検出

DPMは、 M 個の物体モデル m から構成され、複数のモデルによって物体の大きさや姿勢を表現する。通常、学習サンプルのアスペクト比によるクラスタリングを行なった後、得られるクラスタ毎に物体モデルが構成される。各物体モデル m は1個のルートフィルタ p_0 と n 個のパーツフィルタ p_i ($i = 1, \dots, n$)を持ち、 $m = \{p_0, \dots, p_n\}$ と表す。ルートフィルタには、フィルタのサイズ (width, height) で画像から特徴ベクトルを抽出する関数 ϕ_0 、その抽出した特徴ベクトルの各次元に対する重みベクトル \mathbf{F}_0 が設定され、 $p_0 = (\phi_0, \mathbf{F}_0)$ と表すことができる。各パーツフィルタには、ルートフィルタと同様に関数 ϕ_i および重みベクトル \mathbf{F}_i が設定されるほか、ルートフィルタ p_0 との相対的なパーツ位置 \mathbf{v}_i および変形コスト \mathbf{d}_i が設定され、 $p_i = (\phi_i, \mathbf{F}_i, \mathbf{v}_i, \mathbf{d}_i)$ と表すことができる。画像中のルートフィルタの位置 $\mathbf{x}_0 = (x_0, y_0)$ に対して、DPMのモデル m の識別スコアは以下の式で計算される。

$$\alpha(m, \mathbf{x}_0) = \mathbf{F}_0 \cdot \phi_0(\mathbf{x}_0) + \sum_{p_i \in m} \max_{\Delta \mathbf{x}} \{ \mathbf{F}_i \cdot \phi_i(\mathbf{x}_0 + \mathbf{v}_i + \Delta \mathbf{x}) - \mathbf{d}_i \cdot \theta_d(\Delta \mathbf{x}) \} + b \quad (1)$$

ここで、右辺の第1項はルートフィルタの応答であり、第2項は全パーツフィルタの応答から変形コストを引いた総和を表す。また、 b はバイアス項であり、式中の \cdot は内積を表す。 $\Delta \mathbf{x}$ は識別時のパーツ位置 \mathbf{x} がパーツフィルタに設定されたパーツ位置 \mathbf{v}_i からどれだけ移動しているかを表す。各パーツフィルタの応答は、 $\Delta \mathbf{x}$ を変化させながら最も高い出力が得られるパーツ位置で計算される。 $\theta_d(\Delta \mathbf{x})$ は、2次元ベクトル $\Delta \mathbf{x} = (\Delta x, \Delta y)$ を以下の式により4次元ベクトルへ写像する。

$$\theta_d(\Delta \mathbf{x}) = (\Delta x, \Delta y, \Delta x^2, \Delta y^2)^T \quad (2)$$

パーツの移動コスト d_i は、 $\theta_d(\Delta \mathbf{x})$ の各要素に対して重みを付与する4次元の重みベクトルである。すなわち、式(1)は全フィルタのスコアの和を求め、各パーツ位置に対するペナルティを与えることで識別スコアを計算する。そして、ルートフィルタの位置 \mathbf{x}_0 に対するDPMの識別スコア $S(\mathbf{x}_0)$ は以下の式で計算される。

$$S(\mathbf{x}_0) = \max_m \alpha(m, \mathbf{x}_0) \quad (3)$$

この式は各モデル m の識別スコアのうち、最高スコアを \mathbf{x}_0 で

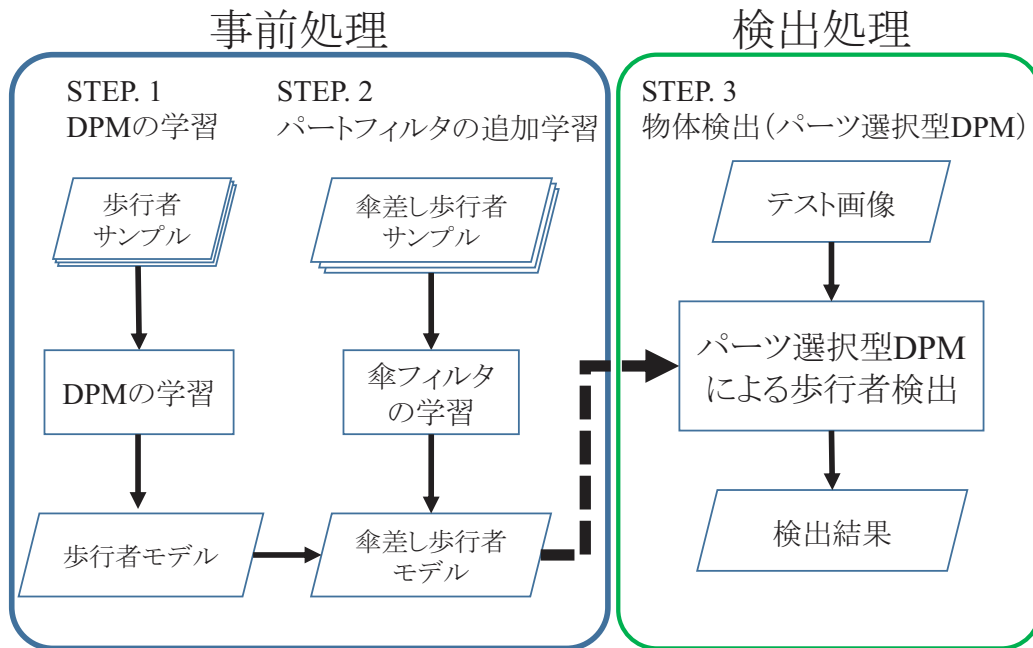


図 2 提案手法の処理手順

の識別スコアとする。

2.2 DPM の学習

DPM の学習では、物体のパーツ位置を隠れ変数として扱い、パーツ位置の割り当てとパーツ形状の学習を同時に行なう。各学習サンプル s_i のパーツ位置を隠れ変数 z_i とすると、識別関数は以下のように表すことができる。

$$f_{\beta}(s_i) = \max_{z_i \in Z(s_i)} \beta \cdot \Phi(s_i, z_i) \quad (4)$$

ここで、 β はモデルパラメータであり、 $Z(s_i)$ は s_i に対してとり得る z_i の集合である。 $\max_{z_i \in Z(s_i)}$ は、最もスコアが高くなるようパーツ位置を決定している。学習データは $D = \{(s_i, l_i)\} (i = 1, \dots, N)$ の形で与えられる。 s_i は学習サンプルを表し、 l_i はそのサンプルのクラスラベル $l_i \in \{-1, 1\}$ である。そして、以下の損失関数 $L_D(\beta)$ を最小化することによりモデルパラメータが学習される。

$$L_D(\beta) = \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^N \max(0, 1 - l_i f_{\beta}(s_i)) \quad (5)$$

ここで、 $\max(0, 1 - y_i f_{\beta}(x_i))$ はヒンジ損失であり、 C は学習時のコストパラメータである。この損失関数では $f_{\beta}(s_i)$ を計算する際に、式 (4) を最大にするパーツ位置 z_i を求める必要があり、その最小化は非凸最適化問題となる。そのため、通常の SVM のように最小化ができないため、Latent SVM [1] や Structural SVM [9] などによって最小化される。

3. 提案手法：パーツ選択型 DPM

本節では、パーツ選択型 DPM による物体検出手法について説明する。本手法では、まず初めに通常の DPM と同様に物体の検出モデルを構築する。次に、構築した検出モデルに対して、検出モデルの構築時とは別の学習用データから独立に学習した



図 3 追加パーツ学習用のアノテーション例

パーツを追加する処理を行なう。さらに、使用するパーツフィルタの選択処理を加えて物体検出を行なう。以上の提案手法を傘差し歩行者の検出に適用する際の処理手順を図 2 に示す。

3.1 DPM へのパーツの追加

検出対象と共に現れる確率が高い別の物体を検出モデルに組み込むことにより、検出精度が向上することが報告されている [8]。これは、物体を探すときに他物体を目印にすると考えれば直感的に理解することができる。そこで提案手法では、既に学習済みの DPM に対して、別途学習したパーツフィルタ p_a を追加し、モデル m を拡張する。パーツフィルタを追加した場合のモデルは $m' = \{p_0, \dots, p_n, p_a\}$ と表現できる。よって、このパーツフィルタすべてを検出に利用した場合の式 (1) の識別スコアは、 $\alpha(m', x_0)$ となる。

パーツフィルタの追加時に学習すべきパラメータは、フィルタサイズ (width, height) とパラメータ F_a, v_a, d_a である。本手法では追加パーツの形状を明確に学習するため、パーツ位置に関するアノテーションを学習データに加える。学習サンプルの例を図 3 に示す。図 3 中の実線矩形は検出対象 (歩行者) を表し、破線矩形は追加パーツ (傘) を表す。パーツのアノテーションは外接矩形で与えられ、追加パーツのフィルタサイズ (width,

height) はつけられた外接矩形の全サンプルにおける平均をとる。また、各サンプルにおいて矩形内の局所画像をフィルタサイズに拡張し、通常の線形 SVM によりフィルタの値 F_a を学習する。パーツ位置 v_a は、検出対象からのパーツの相対位置 (x, y) の平均 $v_a = (\bar{x}, \bar{y})$ とする。変形コスト d_a としては、検出対象からのパーツの相対位置 (x, y) の分散 σ_x, σ_y を求め、その x 軸および y 軸方向の正規分布の積 $N(\mu_x, \sigma_x)N(\mu_y, \sigma_y)$ を $d_a \cdot \theta_d(\Delta \mathbf{x})$ の代わりに用いる。

3.2 パーツ選択型 DPM による物体検出

式 (1) のように、DPM のすべてのパーツフィルタを検出時に使用した場合、検出対象の一部にオクルージョンが発生すると、その部分に対応したパーツフィルタの応答値が低くなってしまふ。このようなオクルージョンの影響を低減させるには、応答の悪いパーツフィルタは検出に利用せず、応答の良いものだけを利用することが有効であると考えられる。そこで提案手法では、DPM にパーツフィルタの選択を行なう機構を持たせるために、モデル m' を以下のように分割する。

$$m'_f = \{p_0, p_{f_1}, \dots, p_{f_k}\} \quad (6)$$

$$m'_s = \{p_{s_1}, \dots, p_{s_l}\} \quad (7)$$

ここで、 m'_f は検出時に必ず使用するパーツフィルタの集合であり、 m'_s は検出時に選択的に使用するパーツフィルタの集合である。ただし、モデル m' のルートフィルタ p_0 は必ず m'_f に含まれるものとする。また、 $k+l = |m'|$ である。このときパーツフィルタの分割はユーザがパラメータとして指定する。この分割したパーツフィルタの集合のうち、 m'_s に含まれるパーツフィルタに対して選択処理を行なうよう、式 (1) を以下のように変更する。

$$\alpha'(m', \mathbf{x}_0) = \alpha(m'_f, \mathbf{x}_0) + \max_{c \in \mathcal{P}(m'_s)} \gamma(c, \mathbf{x}_0) \quad (8)$$

ここで、

$$\gamma(c, \mathbf{x}_0) = \sum_{p_i \in c} \max_{\Delta \mathbf{x}} \{F_i \cdot \phi_i(\mathbf{x}_0 + \mathbf{v}_i + \Delta \mathbf{x}) - d_i \cdot \theta_d(\Delta \mathbf{x})\} \quad (9)$$

である。ただし、 $\mathcal{P}(m'_s)$ は m'_s の冪集合から空集合を除いた集合であり、 $\mathcal{P}(m'_s) = \{c : \text{a set} \mid c \subseteq m'_s\} - \emptyset$ である。例えば、 m'_s に含まれるパーツ数が 3 であるとき、

$$\mathcal{P}(m'_s) = \{\{p_{s_1}\}, \{p_{s_2}\}, \{p_{s_3}\}, \{p_{s_1}, p_{s_2}\}, \{p_{s_1}, p_{s_3}\}, \{p_{s_2}, p_{s_3}\}, \{p_{s_1}, p_{s_2}, p_{s_3}\}\}$$

のようなパーツの組み合わせを表す集合となる。

$\max_{c \in \mathcal{P}(m'_s)} \gamma(c, \mathbf{x}_0)$ は、 $\mathcal{P}(m'_s)$ から識別スコアが最も高くなるパーツフィルタの組み合わせ c を選択する項である。

3.3 パーツ選択型 DPM による傘差し歩行者検出

本節では、前節において説明したパーツ選択型 DPM によって傘差し歩行者を検出する手法について説明する。以下では、パーツの追加処理およびパーツフィルタの選択処理について順に説明する。

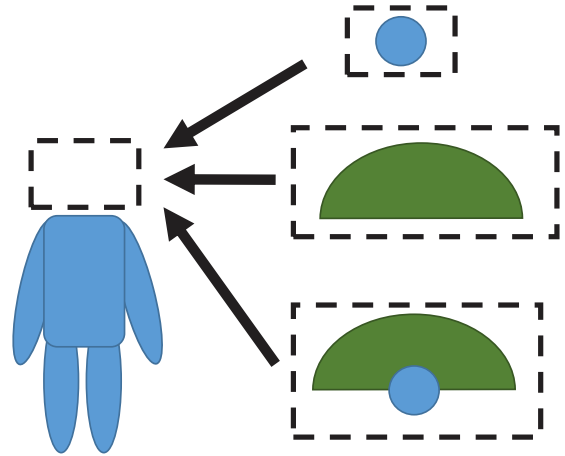


図 4 パーツ選択型の歩行者モデルの概念図

3.3.1 パーツの追加

雨天時の自動車の走行環境では、多くの歩行者が傘を差しているため、傘を検出モデルに組み込むことによって歩行者の検出精度が向上できると考えられる。そこで提案手法では、歩行者のみを学習した DPM に対して、傘を表現するパーツフィルタ p_u を追加し、 $p_a = p_u$ として歩行者モデルを拡張する。傘フィルタを追加した場合の歩行者モデルは $m' = \{p_0, \dots, p_n, p_u\}$ と表現できる。

3.3.2 パーツ選択

傘差し歩行者を検出する場合、傘によって歩行者の頭部が隠蔽される状況がしばしば発生する。よって頭部付近に配置されたパーツフィルタの応答が悪くなってしまふ。そこで傘差し歩行者の検出においては、頭部と傘に相当するパーツフィルタのみをパーツ選択の対象とする。ただし、頭部と傘以外のパーツは常に使用するものとする。すなわち、頭部に相当するパーツを p_h とすると、 $m'_s = \{p_h, p_u\}$ であり、 $m'_f = m' - m'_s$ となる。このとき、 $\mathcal{P} = \{\{p_h\}, \{p_u\}, \{p_h, p_u\}\}$ である。このパーツ選択による歩行者モデルの概念図を図 4 に示す。提案手法は、このような 3 パターンのパーツの組み合わせから識別スコアが最も高いものを選択する手法となる。


4. 評価実験

4.1 実験内容

提案手法の雨天時の歩行者検出における有効性を確認するため、雨天時車載カメラ画像を用いた歩行者検出実験を行なった。また、提案手法の晴天時における歩行者検出精度を調査するため、晴天時の車載カメラ画像に対しても同様に実験を行なった。DPM の実装には Felzenszwalb らによって公開されている実装 [7] を用いた。

4.2 使用した歩行者モデル

本実験では DPM のモデル構造として、Person grammar model [6] を用いた。そのモデルの構造を図 5 に示す。これは歩行者のルートフィルタを輪切り状のパーツに分割したモデルである。また、オクルージョンフィルタを備えており、下半身に



(a)Parts (b)Sub-parts (c)Deformation costs

図5 Person grammar model

表1 データセットの比較

データ名	天候	画像枚数	歩行者のべ数	傘差し歩行者
学習データ	雨	1,673	1,857	1,763 (95%)
テストデータ A	雨	1,669	1,397	1,276 (91%)
テストデータ B	雨	950	1,280	845 (66%)
Daimler	晴れ	7,656	2,452	0 (0%)

オクルージョンが発生した際には、検出に使用する輪切りパーツの数を変化させることにより歩行者のアスペクト比の変化に頑健な検出を可能としている。また分割したルートフィルタのうち上から2番目のフィルタまではサブパーツを持っており、頭部から肩にかけての詳細な形状を評価する。実験では文献[7]において公開されている学習済みのモデルを用いた。このモデルをベースラインとし、傘パーツの追加学習および傘パーツと頭部パーツの選択機能を追加した。

4.3 データセット

本実験では、雨天時の単眼車載カメラ画像系列3本を用意した。このうち一つは傘パーツの追加学習用の学習データとし、残る2つの画像系列をテストデータA、Bとした。また晴天時の車載カメラ画像系列として、Daimler Mono Pedestrian Detection Benchmark Dataset [10]を使用した。ただし、学習データとテストデータAはカラー画像であり、テストデータBとDaimlerデータセットはグレースケール画像である。これらのデータセットの内容を表1にまとめる。

4.4 実験結果および考察

検出精度の評価にはFROC曲線を用いた。これは横軸に画像一枚当たりの誤検出数(False Positives Per Image)を、縦軸に検出率(Detection Rate)をとったグラフである。グラフはDPMの検出スコアのしきい値を変化させながら描画した。このグラフでは、曲線が左上に位置するほど検出精度が高いことを表す。

雨天時のテストデータA、Bに対して歩行者検出を行なった結果を図6に示す。図6より、テストデータA、Bのどちらにおいても提案手法の検出精度が高いことが分かる。よって、提案手法は雨天時の歩行者検出精度の改善に有効であることが確認できた。テストデータA、Bに対する歩行者検出結果の例を





図6 各手法の検出精度の比較



(a) 比較手法

(b) 提案手法

図7 歩行者検出の結果例(テストデータA)

図7、8に示す。

左右の画像では検出スコアのしきい値に同じ値を用いている。比較手法では検出できなかった傘差し歩行者が提案手法では検出できていることが分かる。

また、晴天時のテストデータであるDaimlerデータセットに対して歩行者検出を行なった結果を図9に示す。この図を見ると2つの曲線はほとんど一致している。これは、提案手法では頭部と傘のパーツを選択して用いるため、傘パーツが選択されることなく、ベースラインとなる比較手法と同じパーツを使用して検出が行なわれたためであると考えられる。つまり提案手法は晴天時の歩行者検出精度を低下させず、雨天時の歩行者検出精度を向上させることに成功している。



(a) 比較手法 (b) 提案手法

図 8 歩行者検出の結果例 (テストデータ B)




図 9 Daimler データセットでの歩行者検出精度の比較

5. むすび

本報告では、パーツ選択型 DPM を用いて傘差し歩行者を高精度に検出する手法について検討した。DPM の歩行者モデルに傘パーツを追加し、頭部パーツと傘パーツを検出スコアが高くなるように選択する手法を提案した。評価実験により、頭が傘により隠れてしまっているような歩行者でも従来手法と比べて高精度に検出が可能であることを確認した。

今後の課題として、パーツ検出のマルチスケール化が挙げられる。図 10 に示すように歩行者と傘の相対的な大きさは多様で




図 10 傘と歩行者の相対的な大きさの違い

あるのに対し、DPM のパーツフィルタの大きさはルートフィルタに対して固有である。本手法のように既存のモデルにパーツを追加する場合、本来のパーツよりも追加パーツの拡張性が高いことが利点といえる。ルートフィルタに対するパーツフィルタの相対的な大きさに幅を持たせることで、検出率の向上が望める。

謝辞 本研究の一部は、科学研究費補助金による。

文 献

- [1] P. F. Felzenszwalb, R. B. Girshick, D. McAllester, and D. Ramanan, "Object detection with discriminatively trained part-based models," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 32, no.9, pp. 1627–1645, Sep. 2010.
- [2] 山内悠嗣, 山下隆義, 藤吉弘亘, "[サーベイ論文] 統計的学習手法による人検出," 電子情報通信学会技術研究報告, PRMU2012-43, Sep. 2012.
- [3] R. Benenson, M. Omran, J. Hosang, and B. Schiele, "Ten years of pedestrian detection, what have we learned?" In *computer Vision—ECCV 2014 Workshops, Lecture Notes in Computer Science*, vol.8626, pp.613–627, Springer, Mar. 2015.
- [4] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," In *Proc. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol.1, pp.886–893, June 2005.
- [5] S. Tang, M. Andriluka, and B. Schiele, "Detection and tracking of occluded people," *Int. J. of Computer Vision*, vol.110, no.1, pp. 58–69, Oct. 2014.
- [6] R. B. Girshick, P. Felzenszwalb and D. McAllester, "Object detection with grammar models," In *Proc. Neural Information Processing Systems Conference, Advances in Neural Information Processing Systems 24*, pp. 442–450, 2011.
- [7] R. B. Girshick, P. Felzenszwalb and D. McAllester, "Discriminatively Trained Deformable Part Models, release 5," <<http://www.cs.berkeley.edu/~rbg/latent/>>, Sep. 2012.
- [8] B. Pepik, M. Stark, P. Gehler, and B. Schiele, "Occlusion patterns for object class detection," *Proc. IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, pp. 3286–3293, Jun. 2013.
- [9] C. N. J. Yu and T. Joachims, "Learning structural SVMs with latent variables," In *Proc. 26th Annual ACM Int. Conf. on Machine Learning*, pp.1169–1176, Sep. 2009.
- [10] M. Enzweiler and D. M. Gavrila, "Monocular pedestrian detection: Survey and experiments," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.31, no.12, pp.2179–2195, Dec. 2009.