

I-11 見えにくい交通映像シーンからの状況変化の自動アノテーション

Automatic Annotation of Changes from Obscure Traffic Video Scenes

境野 英朋[†]
Hidetomo Sakaino[†]

1. まえがき

映像を通じたシーン状況理解が自動的にできるようになれば、画像によらないさまざまなセンサとの情報統合や遠隔の膨大なシーンの自動分類や検索など、生活や監視情報として有効なDBを構築することができるであろう。その際、映像情報を用いた場合に遭遇する自然環境の変化を考慮しないと誤検出が多く生じてしまう。そこで本稿では、交通シーンでの状況変化をカメラ視線上を横切る降雪パターンなどにより、見えにくい状況下でも安定に走行車両数を計数する方法と、その経時変化について自動的にアノテーションづけする方法について提案している。

2. 悪天候下の交通シーン

映像を通じた降雪下の走行車両シーンを図1aに示す。本稿では降雪シーン300フレームの時系列画像を用いるが、画面左上から下に向かって、車両数が増減したものである。その中の連続する16フレームの差分値を累積した画像を図1bに示すように、左斜め下方向に雪が激しく降りながらシーン全体を覆っていることがわかる。従来より交通シーンからの車両検出・追従の研究は多いが晴天シーンである場合がほとんどであった。従って、降雪パターンが車両検出を行う際にどのように影響を及ぼすかについて予備実験を行った。

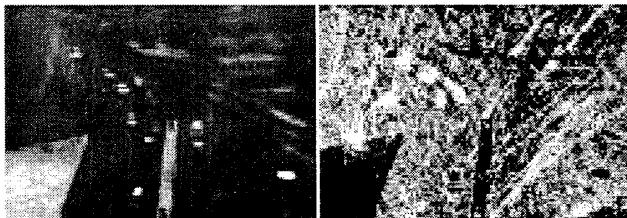


図1 降雪シーン(a)と差分値累積画像(b)の例

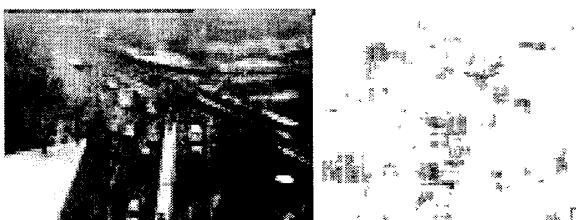


図2 降雪シーンの差分累積画像(a)とLK法での速度検出(b)

前処理としてヒストグラム平坦化を施した。前者により、図1aは図2aのように車両がくっきりと見える。車両速度検出にはLucas-Kanade(LK)法を用いた。LK法はサブブロック毎に目的関数を最小二乗法で計算する。Anandan法、Nagel法ではほとんど車両域を検出できなかった[1][2][3]。降雪も逆に強調されてしまい、車両速度と降雪速度が混在したまま検出される問題が残った(図2b)。さらに、ローパスフィルタ等を用いた場合でも降雪と車両の融合が生じてしまい車両

速度の精度は改善されなかった。このことから、前処理を用いて降雪パターンと走行車両域を分離検出できる方法が必要である。

3. 輝度・コントラスト変動モデル

速度検出の際、時系列フレーム間での点対応ではLK法で仮定されている画像強度保存則モデルが適当ではない。これは図3aに示すように、降雪が車両上を移動しながらオクルージョンを呈するためである。時間tとt+1での強度の変化について、LK法(図3b)と降雪等による車両上の強度変化(図3c)の2つのモデルを考えることができる。ここでは、後者については、輝度とコントラストの2つの要因とする。

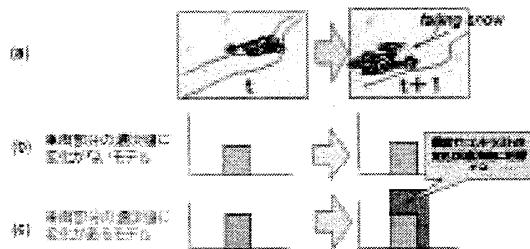


図3 画像強度変化モデル

図3cを条件式で表す。 $I(x,t)$ を2次元位置 \mathbf{x} 、速度 $\mathbf{u}(x)$ 、時間 t での画像強度とすると、連続フレーム間で式(1)となる。

$$I(\mathbf{x}, t) = br(\mathbf{x}, t)I(\mathbf{x} - \mathbf{u}(\mathbf{x}), t + 1) + ct(\mathbf{x}, t) \quad (1)$$

ここでは、輝度 br とコントラスト ct とする。各画素毎に速度2成分と br, ct の4つの未知数を推定すればよい。解法として、サブブロック内で目的関数の最小二乗法を考える。しかしながら、通常、外れ値の影響により、当てはめ誤差が生じることから、非線形なロバスト関数によるM推定法を適用する[2][3]。ロバスト関数はローレンツ関数を用いる。なお、式(1)をティラー展開近似表現すると、式(3)を得る。 u, v は未知の速度成分。一定画像領域内で目的関数、式(2)を最小化するために、式(4)に示す最急降下法を適用し、速度2成分と br, ct の4つの値を推定する。本手法をNRBC(Nonlinear Robust estimator with Brightness and Contrast model)法と呼ぶことにする。サブブロックは1画素ずつずらし全面にわたって計算した。収束は反復誤差が各未知数で0.001未満になるまで、ローレンツ関数内の分散値を100から段階的に小さくして行った。

$$E = \sum_{\mathbf{x}} \rho(u, v, \sigma) \quad (2)$$

$$\epsilon = \left| I^{n+1}(\mathbf{x}, t) - br(\mathbf{x}, t)I^n(\mathbf{x}, t) + I_x u + I_y v - ct(\mathbf{x}, t) \right| \quad (3)$$

$$w^{n+1} = w^n - \mu \frac{\partial E^n}{\partial w^n} \quad (4)$$

ただし、 I_x, I_y は水平、垂直空間1次微分。 I^n はnフレーム目化の必要条件。 $\mu = 10^{-3}$ 。 $\rho(z, \sigma) = \log(1 + \frac{1}{2} + \frac{z^2}{\sigma^2}) + \frac{z^2}{\sigma^2} - \frac{z^2}{\sigma^2 + 2\sigma^2}$ 。

$$E_x = \sum_{uv} \Psi(uv), E_y = \sum_{uv} \Psi(v), E_u = \sum_{uv} \Psi(br), E_v = \sum_{uv} \Psi(ct)$$

[†]日本電信電話(株), NTT コミュニケーション科学基礎研究所

4. 速度・輝度・コントラスト検出実験

NRBC 法を降雪シーンに適用した結果を図 4 に示す。走行車両の速度ベクトルだけが検出できた。速度域に対応する画像も示す。降雪パターンは、図 5 に示すように、輝度画像とコントラスト画像に分離された。図中、斜めに横切る降雪パターンが存在する。

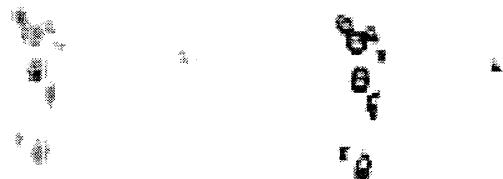


図 4 速度ベクトル場と対応する画像抽出

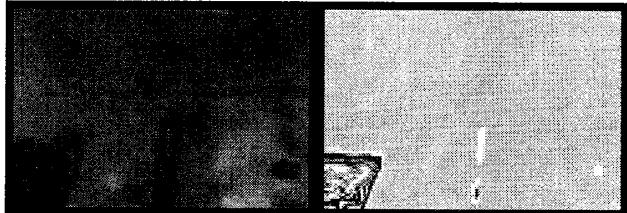


図 5 輝度画像とコントラスト画像

次に、自動的に走行車両の数を計数するために、速度場に対して、クラスタリング手法の一つである LBG 法を適用する。ここでは併合されたセントロイドの数を走行車両数と見なすものとする。セントロイドの初期数はシーン中、十分に大きい車両数 40 台を想定して 40 個とした。図 6a に、図 4 の速度点列からクラスタ群が形成できた。さらに、隣接するセントロイドが一定距離内にある点をマージング処理により併合し(円)，これを最終的な車両数とした。その結果、走行車両と一致した(図 6b)。

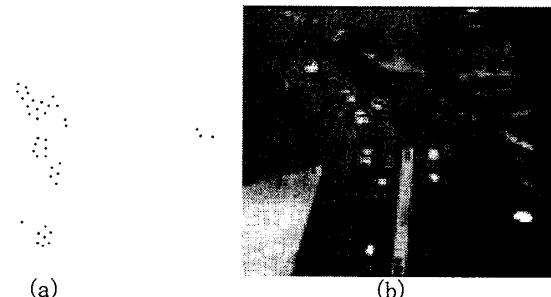


図 6 速度域のクラスタリングと併合されたセントロイド

5. 走行車両数と自動アノテーション

図 6 に示す円近傍領域を拡大表示した結果を図 7 に示す。8 台の走行車両と路面電車 1 台が見えにくい降雪シーンから自動抽出できた。走行車両数を 300 フレームすべてで検出した(図 8)。2 台から 10 台までの時系列変化をモニタリングできた。図中、太線は low-pass フィルタで変化見えやすくしている。さらに、LK 法と走行車両数の推定精度を主観評価し、NRBC 法を検証した。2 つの評価指標として、 C, F, M をそれぞれ正解数、空振り数、見逃し数として、空振り率($C/(C+F) \times 100$)と見

逃し率($C/(C+F) \times 100$)を計算し、100%から引いた率で高い数値を良いとした。ここでは路面電車については除外して評価した。30 フレーム毎で評価した。その結果、図 9 の横軸の数値 $\times 30$ で実フレーム番号(#30, #60...#270)とすると、NRBC 法は LK 法よりも全般的に的中しており、100%にも達した。このことから、NRBC 法の有効性が示唆された。走行車両数と図 8 の太線の変化から、信頼できるシーン状況理解として、"フレーム番号 285:走行車両数 2 台:少し減少傾向"といったアノテーションを自動的に付与させることを実現できた。

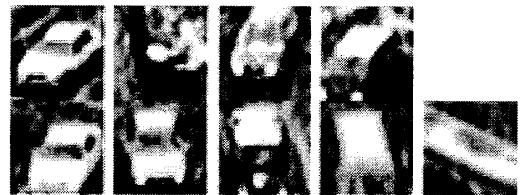


図 7 降雪シーンから検出された走行車両画像

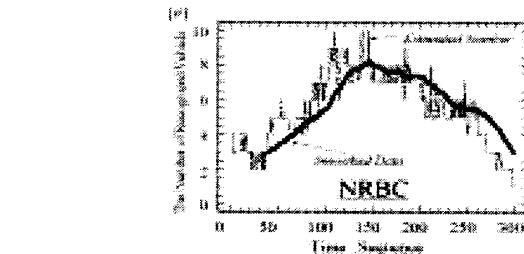


図 8 300 フレームの走行車両数の自動計数した変化

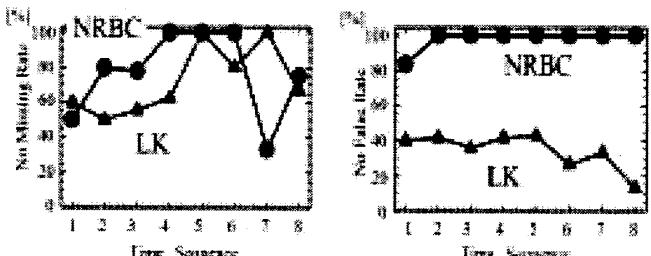


図 9 300 フレーム中の 30 フレーム毎の的中率評価

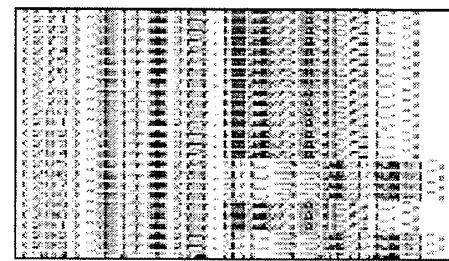


図 10 シーン状況理解と自動アノテーション

6. まとめ

今後、事故、渋滞、歩行者や自転車などシーン状況理解の細分化を図っていく予定である。

参考文献 [1] 境野, "降雪シーン..." 信学会総合大会 02, D-12-154. [2] H. Sakaino, "Nonlinear..." ICPR02. [3] H. Sakaino, "Moving vehicle...", ICIP02.