

車載カメラ映像における機械学習を用いた 夜間の視程レベル推定に関する検討

A Study on Estimating for Visibility Level at Nighttime via Machine Learning Using In-vehicle Camera Videos

北海道大学 工学部 ○学生員 佐藤 諒 (Ryo Sato)
 北海道大学大学院 工学研究院 正 員 高橋 翔 (Sho Takahashi)
 北海道大学大学院 工学研究院 正 員 萩原 亨 (Toru Hagiwara)
 北海道開発技術センター 永田 泰浩 (Yasuhiro Nagata)
 北海道開発技術センター 正 員 大橋 一仁 (Kazuhito Ohashi)

1. はじめに

北海道のような積雪寒冷地では、冬期道路において吹雪による吹きだまりや降雪による視界不良が交通事故発生の要因となっており、問題となっている。実際に北海道の一般国道にて発生した冬型事故のうち、視界不良事故はスリップ事故に次いで多い¹⁾。特に吹雪時における視界不良が原因となる事故発生件数は晴天時の2倍となっており、道路交通に多大な影響を及ぼしている²⁾。したがって、安全な道路交通を実現するために、道路の視界不良を把握し、交通障害のリスクを抑えることが求められる。

道路の視界不良を監視するために、視程計が用いられているが、設置地点が少なく、広域的な吹雪の発生状況を把握するには不十分である³⁾。そこで、文献²⁾では、道路情報としてドライバーに広域での吹雪情報や視程情報を提供するために、容易に入手できる気象データから吹雪時の視程値を推定する手法を提案した。文献⁴⁾では、CCTVカメラから得られる画像の周波数から算出したWeighted Intensity of Power Spectra(WIPS)を用いて視程レベルを推定し、さらに文献⁵⁾では、WIPSによる視界不良と上空の気象予報データであるGPVデータを用いた視界不良の検知を行った。文献⁶⁾では、前方の見やすさに関して、車載カメラから取得した映像内におけるWIPSとドライバーの運転感覚は評価に近いことが示された。一方で、文献³⁾の手法では、昼間と比較して、夜間における推定視程値と観測視程値との解離が大きく、1日を通して高い精度を保った視程値の推定が難しい。また、文献⁴⁾⁵⁾の手法では、照明等の設置上、夜間のCCTVカメラから得られる画像を分析することが難しいことから、分析対象とする画像を7:00~16:00の昼間に限定した。そのため、夜間における視程レベルの推定を実現する手法には至っていない。

そこで、本研究ではドライバー目線の映像が取得可能な車載カメラ映像を用いて夜間の視程レベルを推定する手法を提案する。具体的には、映像内における降雪やヘッドライトの反射光を考慮した特徴量を入力とする識別器を構築することにより、視程レベルの推定を行う。それにより、ドライバー目線で視界不良となっている道路を把握することが可能になる。

本稿では2で車載カメラ映像を用いた視程レベルの推

定を行うための特徴量抽出と識別方法について説明する。3では、実際に2で説明した提案手法による実験を行い、その有効性を確認する。

2. 視程レベルの推定

本章では、視程レベルの推定について説明する。提案手法の概要を図-1に示す。提案手法では、車載カメラから得られた映像から視程レベルを推定する。具体的に、まず初めに、周波数、および物体の移動方向のそれぞれに着目した特徴量を算出する。求めた特徴量を用いて、識別器であるExtreme Learning Machine(ELM)⁷⁾を構築する。最後に、構築した識別器を用いて視程レベルを推定する。本研究では、図-3のように視程レベルを3種類設ける。これらはヘッドライトで照らされている範囲内の視程に注目している。晴天時の視界が良好な状態を視程レベル1と定義し、吹雪時の視界が劣悪な状態を視程レベル3と定義した。また、視程レベル2は視程レベル1と視程レベル3の間の状態と定義した。

以降、2.1では視程レベルを推定するための特徴量抽出について説明し、2.2ではELMによる識別について説明する。

2.1 特徴ベクトルの算出

本節では、入力映像からの視程レベルの推定に用いる特徴量について説明する。提案手法では、まず、ピクセル数が $W \times H$ の映像が入力された場合、図-2のように縦方向に c 分割し、ボンネットを含む領域を除外する。これによって残りの $W \times H' (= H - \frac{H}{c})$ の領域に切り出し、特徴量抽出の対象とする。次に、切り出した領域に対して、周波数、および物体の移動方向に着目した特徴量で構成される特徴ベクトル f_i を算出する。ここで、 $i (= 1, 2, \dots, I; I$ は映像の総数)は各入力映像である。

まず、周波数に着目した特徴量について説明する。提案手法では、画像内の高周波成分に着目した。視界が劣悪な吹雪時の場合、ヘッドライトが雪粒子に反射し、画面全体が白く霧がかかることにより、画像内の輝度勾配が小さくなり、高周波成分におけるパワースペクトル強度が小さくなる傾向がある。一方で、視界が良好な晴天時には道路上の車線境界線や道路構造物、また積雪時の

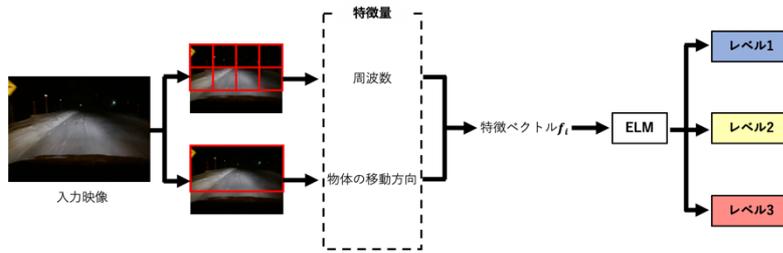


図-1 提案手法の処理の流れ



図-2 入力映像の切り出し



レベル 1



レベル 2



レベル 3

図-3 視程レベルの定義



レベル 1



レベル 2



レベル 3

図-4 キーポイントの追跡結果の可視化

轍や路肩の堆雪により、画像内の輝度勾配が大きくなり、高周波成分におけるパワースペクトル強度が大きくなる傾向がある。したがって、画像内の高周波数成分は視程レベルの推定に有効な特徴量になると考えられる。具体的な算出方法は次のとおりである。

ピクセル数が $W \times H'$ 、フレーム数が J の映像が入力された場合、まず、縦方向に m 分割、横方向に l 分割し、 lm 個のパッチを得る。そしてそれぞれのパッチに対して、グレースケール変換、二次元フーリエ変換の処理を行い、各周波数帯におけるパワースペクトルの平均値 $p_{i,j,n}$ をビン（ただし、ビンの数を b とする）に格納する。

ここで、 $j(= 1, 2, \dots, J)$ は入力した映像の各フレームであり、また、 $n(= 1, 2, \dots, lm)$ はパッチのラベルである。そして、各ビンにおける全フレームの平均値を特徴量 $p_{i,n}$ として下式で算出する。

$$p_{i,n} = \frac{1}{J} \sum_{j=1}^J p_{i,j,n} \quad (1)$$

次に、物体の移動方向に着目した特徴量について説明

する。提案手法では、映像中の物体の動きに注目した。視界が劣悪な吹雪時には雪粒子が暴風により、激しく舞っている特徴が得られると考えられる。一方で、視界が良好な晴天時には、車両の進行に伴い、視認可能な道路構造物が無制限を起点にして、放射状方向に移動する特徴が得られると考えられる。したがって、映像内における視認可能な物体の動きは夜間の視程レベルの推定に有効な特徴量になると考えられる。そこで視認可能な物体の検出、および追跡を行うために Open CV¹ によって提案されている Optical Flow⁸⁾ を用いる。Optical Flow とは、追跡可能な点、すなわちキーポイントの移動ベクトルの分布を表している。図-4 は Optical Flow によって検出された各キーポイントとその追跡結果を視程レベル別に可視化して例示した。具体的な算出方法は次のとおりである。

ピクセル数が $W \times H'$ 、フレーム数が J の映像が入力された場合、まず、 K 個のキーポイント検出、またそれぞれのキーポイントに対して J フレームの間で追跡を行う。そして、 K 個のキーポイントに対して隣接フレーム間のフローのノルム、フローの水平方向に対する角度を $J-1$

¹ <https://opencv.org>

表-1 各手法における評価

視程レベル	レベル1			レベル2			レベル3			正解率
	再現率	適合率	F値	再現率	適合率	F値	再現率	適合率	F値	
提案手法	0.76	0.65	0.70	0.60	0.66	0.63	0.76	0.82	0.79	0.71
比較手法1	0.71	0.75	0.72	0.58	0.56	0.57	0.73	0.73	0.73	0.67
比較手法2	0.41	0.43	0.41	0.43	0.39	0.41	0.47	0.41	0.47	0.44

表-2 データセット

視程レベル	学習データ(本)			テストデータ(本)			合計(本)
	レベル1	レベル2	レベル3	レベル1	レベル2	レベル3	
本数	120	120	120	30	30	30	450

表-3 識別に用いる特徴量

特徴量	提案手法	比較手法1	比較手法2
周波数	✓	✓	
Optical Flow	✓		✓

個算出し、それらの分散をそれぞれ特徴量 $a_i^{variance}$, $r_i^{variance}$ とし、それらの平均値を特徴量 a_i^{mean} , r_i^{mean} とする。さらに、ビンの数を b' としたヒストグラムを特徴量 a_i^{hist} , r_i^{hist} として算出する。また、 K 個のキーポイントに対して各フレームの x 座標, y 座標を J ずつ算出し、それらの分散を特徴量 $x_i^{variance}$, $y_i^{variance}$ とし、ビンの数を b' としたヒストグラムを特徴量 x_i^{hist} , y_i^{hist} として算出する。特徴量 q_i は、 J フレームの全てで検出されたキーポイントの総数である。

これらから、特徴ベクトル f_i が下式で算出される。

$$f_i = [s_{i,1}, s_{i,2}, \dots, s_{i,lm}, t_i] \in \mathbb{R}^{btm+4b'+7}, \quad (2)$$

ただし、

$$s_{i,n} = [p_{i,n}] \in \mathbb{R}^b, \quad (3)$$

$$t_i = [a_i, r_i, x_i, y_i, q_i] \in \mathbb{R}^{4b'+7}, \quad (4)$$

$$a_i = [a_i^{variance}, a_i^{mean}, a_i^{hist}] \in \mathbb{R}^{b'+2}, \quad (5)$$

$$r_i = [r_i^{variance}, r_i^{mean}, r_i^{hist}] \in \mathbb{R}^{b'+2}, \quad (6)$$

$$x_i = [x_i^{variance}, x_i^{hist}] \in \mathbb{R}^{b'+1}, \quad (7)$$

$$y_i = [y_i^{variance}, y_i^{hist}] \in \mathbb{R}^{b'+1}. \quad (8)$$

算出された特徴ベクトルに基づいて映像が3種類の視程レベルに分類される。

2.2 ELM

本節では、視程レベルを推定するための識別手法について説明する。識別器は3層のニューラルネットワークからなる ELM を用いる。ELM は Single hidden layer feedforward neural networks (SLFNs) の一種であり、速い学習速度や少ない学習データによる普遍的な近似を可能としている。提案手法では、まず、学習データにおける周波数, Optical Flow から算出された特徴量を合わせた特徴ベクトル f_i , および視程レベルを $z_i = [z_i^{level1}, z_i^{level2}, z_i^{level3}]^T$ (ただし、 z_i の属する視程レベルが1の場合、 $z_i^{level1} = 1$, $z_i^{level2} = 0$, $z_i^{level3} = 0$ となる。) とする。また、出力層への重み β を求める。具体的には、シグモイド関数 G を用いて特徴変換を行うことで、

$$d(f_i) = [G(u_1, v_1, f_i), \dots, G(u_K, v_K, f_i)]^T \quad (9)$$

を算出する。ただし、 $u_k (k = 1, 2, \dots, K)$, および $v_k (k = 1, 2, \dots, K)$ はシグモイド関数 G のパラメータであり、 K は隠れ層のノード数を表す。次に、

$$\beta = (D^T D)^{-1} D^T Z \quad (10)$$

により、最終層の重み β を求める。ただし、 $Z = [z_1, z_2, \dots, z_M]^T$, $D = [d(f_1), d(f_2), \dots, d(f_M)]^T$, M は学習データの数である。最後に、テストデータにおいて、特徴ベクトル f を ELM に入力したとき、出力値は $g = d(f)^T \beta$ であり、クラスラベルは g の内、最も大きな値を出力したノードに対応するクラスラベルとする。

3. 実験

本章では、提案手法の有効性を確認するために実験を行う。本実験では、北海道標津郡中標津町国道 272 号線を走行した車に搭載されたカメラ映像を用いる。本実験では、表-2 のように合計 450 本の映像 (30fps) からなるデータセットを用いた。入力する映像の各フレームにおけるピクセル数は 640×480 であり、 $c = 3$ としてボンネットを除いた領域 640×320 に切り出す。また、画像の分割数は $l = 8, m = 4$, ヒストグラムのビンの数を $b = 16$, $b' = 8$, キーポイントの検出個数を $K = 10$ とし、合計 551 次元の特徴ベクトル f_i を取得する。また、ELM の隠れ層のノード数は実験的に $K = 800$ とする。本実験では、5 分割交差検証を行い、次の評価指標によって定量的に評価する。

本実験では、評価指標として、式(11)~(14)に示す再現率, 適合率, F 値, 正解率を用いる。

$$\text{再現率} = \frac{\text{視程レベル}N\text{に正しく識別された映像数}}{\text{視程レベル}N\text{である映像数}}, \quad (11)$$

$$\text{適合率} = \frac{\text{視程レベル}N\text{に正しく識別された映像数}}{\text{視程レベル}N\text{と識別した映像数}}, \quad (12)$$

$$F \text{ 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}}, \quad (13)$$

$$\text{正解率} = \frac{\text{正しく識別された映像数}}{\text{識別器に入力した映像数}}. \quad (14)$$

また、比較検証として表-3 に示すように周波数と Optical Flow のそれぞれの特徴量のみを用いた実験も行

った。

表-1より、レベル2, レベル3におけるF値において、提案手法が比較手法を上回っている。また、レベル1では提案手法が、比較手法を下回っているながらも約7割の精度が確認された。全体の正解率を見ても、提案手法が比較手法を上回っている。さらに、レベル3に対する精度が最も良いことから、視界不良の検知という目的では、一定の効果が期待できる。以上のことから提案手法の有効性が確認された。しかしながら、Optical Flowのみを用いている手法の精度が4割程度のため、提案手法の精度向上も含めて、特徴量の扱いは今後の課題である。

4. まとめ

本稿では、車載カメラ映像から夜間の視程レベルの推定を行うための識別手法を提案した。また、実験によってその有効性が確認された。

ただし、夜間の視程レベルを推定する課題として、正解ラベルの基準の具体化が挙げられる。夜間に対する視程レベルの定義付けを行っている文献が少なかったため、本研究では、視程レベルの定義を主観的な判断で行った。本来は、気象条件や視程計の計測値を考慮し、定量的に評価する必要がある。また、現段階において、全体の正解率が71%であり、3割近くが誤った識別結果となっているため、推定精度の向上が求められる。具体的には、有効な特徴量の選択、その特徴量の算出方法、識別器の改良等が挙げられる。さらに、本研究と昼間の映像を用いた既往研究との比較も必要である。今後はこれらの課題について改良を図ることで、より精度の高い夜間の視程レベルの推定の実現が期待できる。

謝辞：本研究の一部は、JSPS 科研費 JP17K00148, JP19H02254 の助成を受けて行われた。

参考文献

- 1) 竹内政夫：冬の視界不良事故について、北海道の雪氷, No.33, 2014
- 2) 松澤勝：吹雪時の視程推定手法とその活用に関する研究, 寒地土木研究所報告, 題 126 号, 寒地土木研究所, 2006
- 3) 松澤勝, 竹内政夫：気象条件から視程を推定する手法の研究, 雪氷, 64.1, pp. 77-85, 2002
- 4) Nagata, Y., Hagiwara, T., Kaneda, Y., Araki, K. and Murakami, K.: Simple way to use closed-circuit television road images for poor-visibility information, Transportation Research Record, Vol. 1980, pp. 105-116, 2006.
- 5) 中村裕貴, 萩原享, 永田泰浩：CCTV カメラの画像処理を用いた暴風雪時の視程障害検知に関する研究, 土木計画学研究・講演集, No.35, 2018
- 6) 中村裕貴, 萩原享, 永田泰浩：固定カメラと車載カメラによる冬期道路管理向け視界情報評価に関する研究, 土木学会論文集 D3(土木計画学), 6, No.75, pp. 599-604, 2020

- 7) G. Bin Huang, Q. Y. Zhu, and C. K. Siew.: Extreme learning machine: A new learning scheme of feedforward neural networks, IEEE Int. Conf. Neural Networks-Conf. Proc., vol. 2, no. February 2014, pp. 985-990, 2004.
- 8) Horn, Berthold KP, and Brian G. Schunck.: Determining optical flow. In: Techniques and Applications of Image Understanding, International Society for Optics and Photonics. pp. 319-331, 1981.