

人間の行動特性を加味した小型船舶向け衝突検知アルゴリズムの開発

生産システム工学専攻 山本 龍也, 指導教員 中井 一文

Development of Collision Detection Algorithm with Human Behavioral Characteristics for Small Boats

Ryuya YAMAMOTO, Kazufumi NAKAI

Advanced Course of Production System Engineering, National Institute of Technology, Toba College

1. はじめに

日本では年間 2000 隻以上の船舶が事故を起こしている。また、船舶の事故種別の約 3 割が衝突によるものである[1]。事故を防ぐために必要な情報は他船の位置、速度、距離である。これらの情報収集を目的とした自動船舶識別装置 (AIS) があるが、小型船舶にとって AIS は高価であり、普及しきっていないのが現状である。また、AIS は操作にも慣れが必要である。そこで、国土交通省が主催となって小型船舶向けスマートフォンアプリケーションを普及させ、船舶事故を未然に防ぐ取り組みが行われている。しかし、現在の衝突予防装置は最接近距離(CPA)を計算して警告を出す。小型船舶は速度が大型船舶に比べて速いため、適用が難しい。また、幅員地域において CPA では衝突予防の警告が頻繁に起こるため、有事の際に使用者が警告を無視してしまう恐れがある。そこで、本研究では人間の行動特性を加味した小型船舶向け衝突検知アルゴリズムの開発を行う。

2. 衝突検知アルゴリズムの概要と構成

歩行者同士の衝突の恐れがある場合、歩行者は環境要因や外部要因、他の歩行者が作り出す状況によって刺激を受け、情報の認知を行う。その後、危険発生の予測や他の歩行者の行動の判断を行い、加速制御や位置制御を行うと考えられる。また、人間の回避特性と小型船舶の回避特性に相関関係が存在する可能性がある[2]。歩行者と船舶の衝突模式図を図 1 に示す。乗物を運転しているときも歩行者同士の衝突と同様の判断が必要であるため、人間の回避行動の特性を一般化できれば小型船舶用の衝突検知アルゴリズムを作成できる可能性がある。本研究では、人間の歩行動作と自転車の乗車動作を対象として回避行動を分析し、お互いを学習モデルとして交差検証を行うことで、衝突検知アルゴリズムの一般化を検討する。




図 1 歩行者と船舶の衝突模式図

3. 関連研究

歩行者の行動特性、回避行動については、障害物による歩行行動への影響を歩行軌跡データの統計的分析から明らかにする研究[2]がある。

また、歩行者が障害物を避ける行動の動画撮影を行い、画像処理技術を応用してその歩行軌跡の解析を試みる研究[3]などもある。この研究は、回避行動を開始する時点における歩行者と障害物との距離は身体の向きが影響しており、前向きが一番大きい。画像処理技術を応用して回避地点を数理的に判断できたというものである。

しかし、本研究で必要な要因である歩行者同士のすれちがい時における速度、歩行者同士の距離と相対角度の関係を明示したものは少ない。既往の歩行研究を概観すると、歩行者の行動をビデオにより撮影し、画像処理技術を応用してその歩行軌跡を解析し、パラメータを抽出する手法が一般的である[2,3,4]。

そこで、本研究においても同様の手法を用いて、歩行者同士、自転車同士の衝突回避動画を撮影し、画像処理技術を用いてそれぞれの回避行動モデル作成を行う。

4. 学習・比較用データセットの作成

4.1. 衝突回避動作の撮影

歩行者同士、自転車同士が衝突を回避する際の動作を記録し、解析を行うことでデータセットを作成する。作成したデータセットを用いて機械学習を行い、人間の行動特性を加味した小型船舶向け衝突検知アルゴリズムの検討を行う。図2に示すように、歩行者、自転車の動作は12mの高さから撮影を行った。撮影可能範囲は20m×25mである。撮影動画のピクセル数は1920×1080である。マーカーには赤色と青色の風船を用いた。歩行者は帽子の上に風船を固定し、自転車は自転車カゴに風船を固定する。撮影可能な範囲内に設定した目印に向かって歩行し、衝突を回避した。被験者の数は8人で、同時に移動する人数は2人である。また、移動速度、角度、回避方向の指定はしていない。撮影した動画中の衝突の恐れがあると判断した地点から5フレームを衝突地点として指定した。前年度の本研究では、これらの衝突地点の指定は撮影した動画を第三者が確認し、目測にて行っていた。しかし、この方法では被験者との衝突判断地点の不一致が起こる可能性がある。そこで、この衝突地点の指定方法を変更した。今年度の研究では歩行者同士、自転車同士のすれ違いの動画を撮影後に第三者ではなく、被験者に動画を閲覧してもらい、衝突地点の指定をしてもらう事で、第三者との判断地点の不一致をなくすことができた。




図2 すれ違い動作の撮影環境

4.2. 座標の抽出

撮影した動画を元に、OpenCV[5]を用いて赤色マーカーと青色マーカーの座標を1フレームずつ取得した。キャプチャした画像にはノイズが含まれているため、ノイズを除去する必要がある。そこで、膨張と収縮操作を組み合わせることにより、ノイズを取り除く処理を加えた。その後、取得したいマーカーの色に合わせてHSVの色相チャンネルを設定し閾値を作成した。閾

値の作成後は、色相チャンネルの値を用いて一定の色相の領域内に納まる部分を抽出し、マスク画像を作成した。その後、マスク画像をグレースケールへ変換し、画像の画素値を2値化した。2値化した画像を元に、赤色と青色の座標をそれぞれ抽出した。抽出した赤色座標を図3に示す。




図3 赤色マーカーの二値化画像例

4.3. ホモグラフィ行列を用いた座標変換

ホモグラフィ変換を用いてカメラの画角に対する補正を行った。ホモグラフィ変換は3x3の行列の各要素を自由に設定して表現する変換である。パラメータは9つ設定する。ただし、行列を定数倍しても同じ変換になるため、潜在的にはパラメータは8つで表現できる。アフィン変換と比べると、部位毎のスケールの違いを調整できるため、立体感のある変換が可能となる。ホモグラフィ行列を図4に示す。

$$s \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} H_{11} & H_{12} & H_{13} \\ H_{21} & H_{22} & H_{23} \\ H_{31} & H_{32} & H_{33} \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}$$

図4 ホモグラフィ行列

また、左辺のSは図5の通りに式を展開する事で消去することができる。

$$x' = \frac{H_{11}x + H_{12}y + H_{13}}{H_{31}x + H_{32}y + H_{33}}$$

$$y' = \frac{H_{21}x + H_{22}y + H_{23}}{H_{31}x + H_{32}y + H_{33}}$$

図 5 ホモグラフィ変換の展開図

すれ違い動作の撮影を行い，撮影画像から4つの特徴点を選択し，俯瞰図に変換した．変換した際に推定されたホモグラフィ行列を用いることで，座標変換が可能となる．




図 6 俯瞰図への変換

4.4. 特徴量の作成

推定したホモグラフィ行列を用いて，座標変換を行った．座標変換を行った座標データを基にデータセットを作成した．歩行者，自転車の1フレーム毎の移動ピクセル数 M_x ， M_y を算出した．歩行者，自転車の $n-1$ フレームの座標と n フレームの座標の差分から M_x ， M_y を計算した．その後，動画の縦横のサイズと緑色のテープの長さから，1ピクセルあたりの移動距離 P_{dx} ， P_{dy} を算出した． P_{dx} ， P_{dy} と1フレーム毎の移動ピクセル数 M_x ， M_y から各座標の1フレーム毎の移動距離 M_d を算出し， M_d とサンプリングタイム t_s から速度 S を算出した．




図 7 ピクセル差分の算出

$$M_x = P_x(n) - P_x(n-1) \quad (1)$$

$$M_y = P_y(n) - P_y(n-1) \quad (2)$$

$$P_{dx} = \frac{20}{1920} \quad (3)$$

$$P_{dy} = \frac{25}{1080} \quad (4)$$

$$M_d = \sqrt{(M_x \times P_{dx})^2 + (M_y \times P_{dy})^2} \quad (5)$$

$$S = M_d \times t_s \quad (6)$$

赤色座標 (r_x, r_y) と青色座標 (b_x, b_y) の連続座標から，赤色マーカーの角度 R_d と青色マーカーの角度 B_d を算出した． $n-1$ フレームの座標を基準点として扱い， n フレームの座標が基準点からどの方向に移動したのかを算出することで，角度 R_d, B_d を算出することができる．算出した歩行者，自転車同士の角度 R_d, B_d を用いて相対角度 θ_r を算出した．1フレームごとの各座標の位置 $(r_x, r_y), (b_x, b_y)$ から座標間の距離 D を算出し，撮影した動画中の衝突の恐れがあると判断した地点から5フレームを衝突地点として指定した．赤色マーカーの速度，青色マーカーの速度，歩行者，自転車同士の距離 D と相対角度 θ_r の4個の特徴量をデータセットとして活用する．正例データ数は17800セット，負例データ数は3365セット作成した．

$$R_d = \tan^{-1} \left(\frac{r_y - w_y}{r_x - w_x} \right) \quad (7)$$

$$B_d = \tan^{-1} \left(\frac{b_y - w_y}{b_x - w_x} \right) \quad (8)$$

$$\theta_r = |R_d - B_d| \quad (9)$$

$$D = \sqrt{(r_x - b_x)^2 + (r_y - b_y)^2} \quad (10)$$

5. 機械学習の概要

5.1. 使用する手法について

本研究では線形分類可能な手法である決定木と非線形分類可能な手法である Support Vector Machine(SVM)の2つの手法の予測結果を比較する．また，決定木とSVMがどのように学習を行うのか説明する．その後，データセットの正例，負例についても

説明する。

5.2. 正例, 負例の決定と判別方法

学習データは, 素性ベクトルとラベルの 2 組の集合である。学習モデルが n クラスへの分類器を構成できるとすると, ラベルは n 種類となる。素性ベクトルには, 正または負のラベルを与える。また, 正のラベルを与えられた素性ベクトルは正例(positive example)と呼ばれ, 負のラベルを与えられた素性ベクトルは負例(negative example)と呼ばれる。

また, 本研究においては, 正の素性ベクトルには 0, 負の素性ベクトルには 1 のラベルを与える。そして, 歩行者, 自転車同士が衝突の恐れはないと判断したデータを正例, 衝突の恐れがあると判断したデータを負例として扱う。

5.3. 決定木の概要

決定木とは, 世の中の物や事例が属性とその値の対の集合で定義されている場合において, これらをいくつかのクラスに分類するための規則を表現する方法の一つである。樹木状のモデルを用いて要因分析を行い, その分析結果から予測結果を算出する。

各属性をブール属性と仮定し, それらを $\{0,1\}$ の 2 クラスに分類する規則はブール関数とあらわされる。今, n 個のブール変数があると仮定する。これらのブール変数を $X_n = \{0,1\}^n$ とおく。すると, 任意のブール関数は X_n から $\{0,1\}$ への関数として定義される。即ち, 決定木とは, 各内部ノードにブール変数が, 各葉に 0 または 1 がラベル付けされた 2 分木である。決定木は 1 つの割り当て $\vec{a} \in X_n$ は, 決定木の根から葉へ 1 つのユニークなパスを決定する。各内部ノードにおいて, そのノードにラベル付けされているブール変数の値がその割り当てにおいて 0 ならば左, 1 ならば右の枝をたどる。たどり着いた葉の値が, その割り当てに対する関数の値となる [7]。本研究においては, ジニ係数を用いて分割する内容の指定を行う。決定木の樹形概念図を図 8 に示す。




図 8 決定木の樹形概念図

5.4. SVM の概要

SVMとは, 線形しきい素子と呼ばれる最も単純なニューロンモデルを用いて, 2クラスのパターン識別器を構成する手法である。

素性ベクトルの次元が n であるとする, 1つの素性ベクトルは n 次元空間中の点として表すことができる。正例と負例を入力空間と呼ばれる n 次元空間にすべて配置し, 分類を行う。正例と負例を分ける 2 クラス分類問題は, 正例と負例を分離する超平面(分離平面)を決める問題に帰着できる。SVMは, 分離平面に最も近い正例と負例との間のマージンを最大化するような分離平面を求める。また, カーネル関数により, 入力されたデータを高次元の素性空間に写像し, 分離平面を求めることで入力空間においては非線形となる分離も可能である。カーネル関数における特徴を選択することでモデルの自由度を低く抑え, 汎化能力の高い識別器を構成することが可能である [6]。本研究においては, パラメータの設定が比較的容易な RBF カーネルを使用する。分離平面を用いて正例, 負例の判断を行う SVM の分類の概要図を図 9 に示す。




図 9 SVM の分類概要図

5.5. データ数不均衡問題の対策

決定木と SVM の手法を用いて, 衝突の恐れがある地点の予測を行う。しかし, 作成したデータセットは正例と負例のデータ数が不均衡であり分類精度の低いモデルとなってしまうと考えられる。

そこで, 不均衡データに対するサンプリングの代表的な手法である SMOTE アルゴリズムを適用した。SMOTE アルゴリズムによって特徴量間の相互関係を考慮したデータを人工的に作成し, オーバーサンプリングとアンダーサンプリングを行う事でデータ数の不均衡をなくす。

6. 予想結果の比較

6.1. 手法比較の予測結果

本研究には, 決定木と SVM の手法のどちらが適しているのかを検討した。歩行者データセットを学習デ

ータ、自転車データセットをテストデータとしてモデルの予測結果の比較を行った。また、グリッドサーチ法により決定木と SVM の最適パラメータを決定した。

決定木では、サンプルを枝に分割する数の最小値 $min_sample_split = \{2^1, 2^2, \dots, 2^5\}$, 作成する葉の最大数 $maxleaf_nodes = \{2^1, 2^2, \dots, 2^5\}$, の範囲でグリッドサーチを行った。グリッドサーチの結果、最適なパラメータは $\{min_sample_split, maxleaf_nodes\} = \{2^1, 2^2\}$ であった。

SVM はコストパラメータ $C = \{2^{-15}, 2^{-14}, 2^{-13}, \dots, 2^{15}\}$, RBF カーネルのパラメータ $\gamma = \{2^{-15}, 2^{-14}, 2^{-13}, \dots, 2^{15}\}$, の範囲でグリッドサーチを行った。グリッドサーチの結果、最適なパラメータは $\{C, \gamma\} = \{2^3, 2^9\}$ であった。予測結果の内、正例で正と予測されたものを TP, 負と予測されたものを TN とし、負例で正と予測されたものを FP, 負と予測されたもの FN とし、予測性能の指標を (10)~(13) の式に示す。

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

$$Recall = \frac{TP}{TP + FN} \quad (13)$$

$$F1 = \frac{2Recall \times Precision}{Recall + Precision} \quad (14)$$

決定木と SVM の予測結果を比較したところ、SVM の結果の方が優れていた。決定木の Accuracy は 0.868, F1 は 0.860 であった。

SVM の Accuracy は 0.888 であり、F1 は 0.883 であった。予測結果の比較を表 1 に示す。

表 1 決定木と SVM の予測結果

	Accuracy	Precision	Recall	F1
決定木	0.868	0.921	0.870	0.860
SVM	0.888	0.883	0.892	0.883

予測結果は十分に良い精度を得ることができた。線形分岐可能な決定木は、非線形分類可能な SVM に比べて分類性能が高い手法ではないことから、本研究の予測結果と一致していると考えられる。

6.2. 行動特性比較の実験結果

先程の予測結果の比較から、SVM の手法を用いて人間の回避行動の特性一般化の検討を行う。歩行者と自転車のデータセットを用いて予測を行った。その際、グリッドサーチ法を用いて最適なパラメータを決定した。歩行者データ、自転車データはコストパラメータ $C = \{2^{-15}, 2^{-14}, 2^{-13}, \dots, 2^{15}\}$, RBF カーネルのパラメータ $\gamma = \{2^{-15}, 2^{-14}, 2^{-13}, \dots, 2^{15}\}$, の範囲でグリッドサーチを行った。グリッドサーチの結果、歩行者データの最適なパラメータは $\{C, \gamma\} = \{2^4, 2^6\}$ であった。自転車データの最適なパラメータは $\{C, \gamma\} = \{2^3, 2^6\}$ であった。また、

同じデータの組み合わせについては、10 分割交差検証を用いて予測を行った。予測結果の Accuracy の比較を表 2 に示す。

テスト \ 学習	自転車データ	歩行者データ
自転車データ	0.973	0.855
歩行者データ	0.888	0.969

10 分割交差検証の予測結果が、異なるデータを用いた予測結果よりも優れていた。これは、異なるデータを扱うよりも、同じデータで予測を行うことで予測精度が上がるためだと考えられる。

しかし、異なるデータを用いた予測の Accuracy は 85%, 88% という結果から、未知データに対する分類は十分に良い精度を得ることが出来たと言える。

自転車データセットを学習データ、歩行者データセットをテストデータとしたモデルの予測結果グラフを図 10 に示す。水色が TP, 橙色が TN, 藍色が FP, 黄色が FN と対応している。縦軸はデータ数であり、横軸は相対角度を正規化した値である。横軸 0.85~0.95 (相対角度が 175~185°), 歩行者と自転車同士が正面から向かい合う状況と、TN の分布が大きく、TP のグラフの形が近似している横軸 0.2~0.3 (相対角度が 75~90°), 歩行者と自転車同士が垂直に向かいあう状況の比較を行った。横軸 0.85~0.95 の TP, TN の合計は 2001 個、横軸 0.2~0.3 の TP, TN の合計は 2003 個と大きな違いはないが、横軸 0.85~0.95 の TN は 449 個、横軸 0.2~0.3 の TN は 193 個という差がある事が分かった。

このことから、相対角度が 175~185° の地点は衝突の恐れが多い地点であると考えられる。




図 10 相対角度の予測結果

異なるデータを用いた 2 つの予測結果を分析したところ、それぞれの予測において、距離間が近いほど負例、速度が遅いほど負例と判断されやすいことが分かった。また、相対角度が 175~185° において負例と判断されやすいことも分かった。つまり、それぞれのデータにおいて、相対角度が 180° 付近かつ距離が近い

場合、速度を落として回避行動を開始すると考えられる。これらの事から人間の回避行動の特性一般化は可能であると考えられる。

7. おわりに

今後は、よりデータ数を増やし速度、距離、相対角度の詳細な相関関係を確認する。また、自動車や船舶のシミュレーションを用いてデータセットを作成し予測を行うことで、人間の回避行動特性一般化の検証を行う。その後、人間の行動特性を加味した小型船舶向けアルゴリズムの開発を行い、小型船舶向けスマートフォンアプリケーションに小型船舶向けアルゴリズムを適用し、船舶同士の衝突回避実験を行う。

文 献

- [1] ”海上保安庁統計年報 第 64 巻 平成 25 年度出版”, <http://www.kaiho.mlit.go.jp/info/tokei/h25tokei/h25tokei.pdf>, 2019 年 1 月 12 日参照
- [2] 建部謙治, 辻本誠, 志田弘二: “回避行動開始点の判定と前方回避距離, 歩行者の回避行動に関する研究(II)”, 日本建築学会計画系論文集, vol. 465, p. 95-104 (1994)
- [3] 建部謙治: “歩行者の属性による回避行動特性”, MARA Journal, vol. 3, no. 2, p. 23-29 (1997)
- [4] 辻本誠, 志田弘二, 建部謙治: “歩行解析の画像処理技術の応用に関する研究”, 日本建築学会計画系論文報告集, vol. 436, p. 41-47 (1992)
- [5] ”OpenCV, Open-source Computer Vision Library”, www.opencv.org, 2019 年 1 月 16 日参照
- [6] 佐々木裕, 磯崎秀樹, 鈴木潤, 国領弘治, 平尾努, 賀沢秀人, 前田英作: “SVM を用いた学習型質問応答システム SAIQA-II”, 情報処理学会論文誌, vol. 45, no. 2, p. 638-639 (2004)
- [7] 榊原康文: “決定木による分類規則の学習について —理論的側面から—”, 情報基礎研究会資料, vol. 55, p.1-3, (1991)