

pdi-Bagging を用いた大規模屋外駐車場で車種識別

○ 入江 穂乃香¹ 林 勲¹ 堅多 達也² (¹関西大学 ²ニチゾウテック株式会社)

Vehicle Type Discrimination in Large-scale Outdoor Parking Lot Using pdi-Bagging

* H. Irie¹, I. Hayashi¹, and T. Katada² (¹Kansai University ²Nichizo Tech Inc.)

Abstract: Recently, in many large-scale outdoor parking lots, the degree of congestion is displayed for each vehicle type section. It is important to recognize how and what kind of vehicle is parked in the lot from the viewpoint of effective utilization of the parking lot. The vehicle type is identified by the division status judgment system using a wide-angle camera. Wide-angle cameras are cheaper than infrared sensors and ultrasonic sensors. In addition, the cameras are less susceptible to the effects of weather and have the advantage of also serving as security cameras. However, since there are many cases where the amount of video data between vehicle types is imbalanced, which may affect the identification rate of vehicle types. In this paper, we try to improve the discrimination rate of vehicle type identification by using pdi-Bagging. Specifically, the generated image virtual data is added to the image data of the wide-angle camera to correct the imbalance in the amount of data. In addition, we will develop a vehicle interior situation judgment system that obtains a high vehicle type identification rate by introducing the model kickback of an ensemble learning discriminator. We introduce the outline of the basic algorithm of this system and application examples.

Key Words: Ensemble Learning, Clustering Method, Vehicle Type Discrimination

1 はじめに

近年、多くの屋外駐車場では、車両区画ごとに駐車状況を表示する装置が装備されている [1]。しかも、空車表示だけでなく駐車率の混雑度を表示する駐車場もある。また、車種を識別する駐車場も存在する。これらの駐車状況の活用により、利用者は、駐車スペースを探す利便性が増すだけでなく、駐車場の管理者にとっても、駐車率や車種判断が可能になれば、人流把握にもつながり、営業性の向上にも有効であるといえる。従来の駐車場では、赤外線センサーや超音波センサーの車両検知システムの導入によって、駐車場の車室状況を取得し車両の混雑状況を把握していた。しかし、センサー式車両検知システムは、車両台数が増えると、特に、大規模な駐車場では、設置費用や維持コストが膨大となり、対費用効果からも有効な方法とは言えない。一方、広角カメラによる車両検知システムも存在する。近年では、広角 IP カメラが製品化され、コスト面が改善されたことや市内のセキュリティ対策として監視カメラが販売されるなどにより、IP カメラの活用が広がっている。そのため、最近では、広角 IP カメラを用いた駐車場の車両検知システムが注目されている [1-4]。図 1 にその車両検知システムの映像例を示す。広角 IP カメラ式車両検知システムは導入コストが低く、天候や日照状況の影響を受けにくい利点があり、さらに、防犯用カメラとしても使用することができるので、今後も、駐車場での普及が進むと期待されている。一方、車両の種類は駐車場の場所によって大きく偏りが生じる。例えば、市街地の駐車場では自家用車の小型車が多いが、郊外や高速道路の駐車場ではバスやトラック等の大型車が多い。そのため、検知された車種ごとのデータ量は必ずしも均等とはいえず、クラスタリングモデルによる車種識別に大きく影響を与える。




Fig. 1 Large-scale Outdoor Parking Lot

本論文では、車種クラス間でデータ量の不均衡が生じている場合、アンサンブル学習 [5-8] の pdi-Bagging [9,10] を用いてバーチャルデータを発生し、車種の識別率を向上させる車種識別システムを開発する。具体的には、郊外の駐車場を事例として、郊外の大規模屋外駐車場では大型車が多いので、小型車データに仮想的な画像バーチャルデータを発生し、小型車と大型車のデータ量に均等性を担保する。また、これらのバーチャルデータを学習用の車両画像データに追加し、弱判別器としてファジィ推論 [11,12] を用いた Bagging 法で車種を識別する。このバーチャルデータを学習用データに追加し、識別率を向上させるアンサンブル学習法を pdi-Bagging と呼ぶ。バーチャルデータは広角 IP カメラから獲得した車両画像データでもあるので、本手法は、仮想的な画像データを画像学習データに追加するクラスタリング手法であるといえる。さらに、バーチャルデータの追加によるモデルの過学習を防ぐため、判別線を小型車クラスのセンター側に引き戻すモデルキックバック方式の学習法を提案する。このモデルキックバック方式は、pdi-Bagging の誤判別型バーチャルデータ発生方式に

採用される。したがって、誤判別型を含む混合判別クラスター中心型バーチャルデータ発生方式でも採用される。

ここでは、バーチャルデータの発生法とキックバックの程度(レベル)による識別率の比較から、本手法の有用性を議論する。また、実際の駐車場で車種識別の画像データを用いて、バーチャルデータ発生とモデルキックバックによる pdi-Bagging を挿入した車種識別システムの有用性についても議論する。

2 駐車場の車種識別システム

図2にカメラ式車種識別システムの概要を示す。本システムでは、事前に、判定者が目視で小型車か大型車を判断した判定画像を用意すれば、それを学習データとして車両種類を識別する。したがって、日光や照明等の外乱の影響が大きく画像分類の特徴が明確にモデル化できない場合でも、学習データが用意できれば、人の感覚に近い車種識別が可能となる。また、フィルタリングやラベリング、エッジ処理等の画像処理も必要なく、対象車両に合わせたアルゴリズムの調整も必要ない。

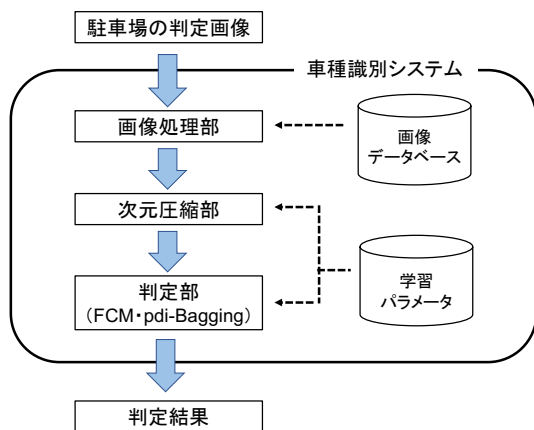


Fig. 2 Vehicle Type Detection System

まず、画像処理部では、撮影された画像から各々の駐車スペースの画像領域を切り出し、画像を規定のサイズに正規化する。そのため、元画像の駐車スペースの切り出し形状は平行四辺形であるが、アフィン変換によって長方形あるいは正方形となる。次に、次元圧縮部では、主成分分析 (Principal Component Analysis) により正規化された駐車スペースの画像を所定の次元数に圧縮する。その後、判定部では、FCM (Fuzzy C-Means) [13] と pdi-Bagging によって、駐車スペースの車両の次元圧縮データから車種を識別する。FCM によって車両クラスターを構成し、pdi-Bagging を用いて車種を識別する。FCM では、データと車種クラスとの中心とのマハラノビス距離によってクラスターのメンバシップ値を定義するが、車種クラスごとのメンバシップ値の合算による判別関数によってクラスターを構成する。なお、学習はセミハードクラスタリング法を採用し、パラメータとクラスターの混合比率は粒子群最適化法 (PSO: Particle Swarm Optimization) を用いている。最後に、パラメータ部では、次元圧縮部および判定部で用いたパラメータを格納する。

3 pdi-Bagging

pdi-Bagging の概念図を図3に示す。pdi-Bagging では、まず、全データ集合から確率的に抽出された学習データ

(TRD) を用いてファジィ推論の弱判別器 M_0 を学習し TRD の識別率を算出する。次ステップ(層)では、メンバシップ関数を用いて、特定の学習データからバーチャルデータを発生し TRD の量を増加して、ファジィ推論の弱判別器 M_1 により TRD の識別率を算出する。TRD の量を増加させることにより弱判別器の識別精度が向上する。終了判定が満足されるまでこの一連の操作を L 回繰り返し、最終的に、評価データ (CHD) を L 個の弱判別器 M_0, M_1, \dots, M_L に入力して、平均値計算により最終結果を得る。pdi-Bagging では、バーチャルデータを学習データに追加し弱判別器が同定されるので、従来のバギングや AdaBoost よりも高い精度の判別線が得られる [14]。

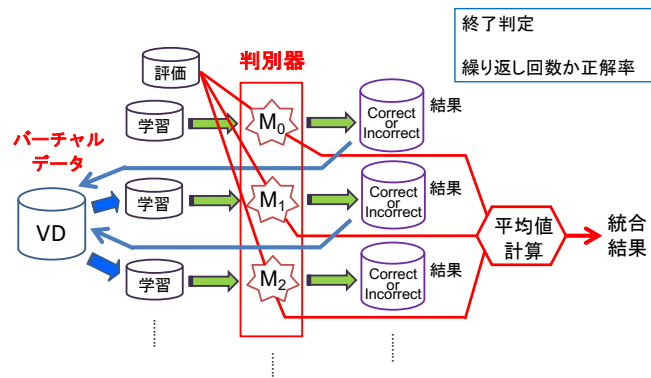


Fig. 3 pdi-Bagging Algorithm

pdi-Bagging では、弱判別器として簡易型ファジィ推論 [12] によるファジィクラスタリングを用いる。簡易型ファジィ推論は、if-then 型でルールを表現し、前件部では、メンバシップ関数のファジィ集合を定義し、後件部では、シングルトンを定義する。ここでは、三角型のメンバシップ関数を一般化した正規な台形型ファジィ集合を用いる。

いま、出力変数を z 、後件部のシングルトンを p_i で表すと、ファジィルール r_i , $i = 1, 2, \dots, R$ は次のようになる。

$$r_i : \text{if } x_1 \text{ is } \mu_{F_{i1}}(x_1) \text{ and } \dots \text{ and } x_n \text{ is } \mu_{F_{in}}(x_n) \\ \text{then } C = \{C_{ik} \mid z = p_i\} \quad (1)$$

ただし、 C は出力クラスの変数であり、 C_{ik} はルール r_i のクラス値が C_k であることを示す。

次に、pdi-Bagging におけるバーチャルデータの生成方法について説明する。いま、 W 個のデータからなるデータ集合 D の第 d 番目のデータを $\mathbf{x}^D(d) = (x_1^D(d), x_2^D(d), \dots, x_j^D(d), \dots, x_n^D(d))$ で表す。バーチャルデータ $\mathbf{x}^V(d)$ は、ある特定の正判別データ $\mathbf{x}^C(d)$ や誤判別データ $\mathbf{x}^E(d)$ の周辺に発生する。 $\mathbf{x}^V(d)$ を構成する第 j 属性目のバーチャルデータ $x_j^V(d)$ の発生は、ある実数 h , $0 \leq h \leq 1$ が与えられると、ファジィ数 F のメンバシップ関数 $\mu_F(x_j)$ を用いて次のように発生する。

バーチャルデータの発生方法として次の2種類を用いる。

(1) 誤判別型 (E)

任意の学習データ $\mathbf{x}^S(d)$ のクラスが弱判別器により誤判別と判別された場合、その誤判別データ $\mathbf{x}^E(d)$ の周辺にバーチャルデータ $\mathbf{x}^V(d)$ を発生する。

(2) 混合判別クラスター中心型 (MC)

バギングの各層で正判別クラスター中心型と誤判別型を交互に用いて、バーチャルデータ $\mathbf{x}^V(d)$ を $\mathbf{x}^C(d)$ や $\mathbf{x}^E(d)$ の周辺に発生する。

pdi-Bagging のアルゴリズムを次のように表す。

- Step 1 計測データ D (個数: W 個) を学習データ D^{TRD} (個数: W^{TRD} 個) と評価データ D^{CHD} (個数: W^{CHD} 個) に分割する。また、 D^{TRD} から構成されるバーチャルデータを D^V で表す。
- Step 2 第 l 番目の弱判別器 M_l に D^{TRD} を入力し、第 l 番目の結果 R_l の識別率 r_l^{TRD} を得る。ただし、 M_0 は初期弱判別器である。
- Step 3 正判別あるいは誤判別された第 d 番目のデータを D^{TRD} から一時的に抽出する。正判別あるいは誤判別データ $\mathbf{x}^S(d)$ の第 j 番目の属性値 $x_j^S(d)$ に対して、メンバシップ関数 $\mu_F(x_j)$ によりバーチャルデータ $x_j^V(d)$ を発生させる。
- Step 4 バーチャルデータ $\mathbf{x}^V(d)$ のクラス k^* を求める [10]。 $l > 2$ の第 $l-1$ 番目の D^V からバーチャルデータ $\mathbf{x}^V(d)$ を除去し、第 l 番目の D^V にクラス k^* をもつバーチャルデータ $\mathbf{x}^V(d)$ を追加する。
- Step 5 乱数により D^V から v 個のバーチャルデータを取り出し D^{TRD} に加える。
- Step 6 $l = l+1$ として Step2 から 5 までを繰り返し、しきい値 θ に対して $r_l^{CHD} \geq \theta$ を満足した $K = l$ の時点、あるいは、弱判別器の個数 L と繰り返し回数 K 、 $K \leq L$ に対して $l \geq K$ を満足した時点でアルゴリズムを終了する。
- Step 7 $M_0, M_1, \dots, M_l, \dots, M_K$ に D^{CHD} を適用し、平均値計算により結果の識別率 r_K^{CHD} を得る。

4 車種識別への応用

図 2 の車種識別システムの画像処理部では、撮影画像を取り扱う。撮影画像は、大規模屋外駐車場に設置された 5 台の広角 IP カメラで撮影され、全撮影画像から 22 日間の画像データを学習データとして、11 日間の画像データを評価データとした。図 1 にその元画像の一例を示し、図 4 にトラックとバス (大型車) の拡大画像を示す。図 1 において、赤色や緑色の平行四辺形は駐車か空車の判定を推定した区域であり、この枠内の車両の車種を識別する。駐車スペースとして切り出された平行四辺形の画像は、アフィン変換により $30 \times 40 \text{ pixel}$ の長方形の正規化画像に変換される。図 5 にその正規化画像の例を示す。(a) と (b) に小型車を示し、(c) にトラックの大型車、(d) にバスの大型車を示す。駐車スペースの方位のまま車両画像を正規化しているので、車両の形状が変形しているのがわかる。

次に、次元圧縮部の主成分分析によって、圧縮前の 3,600 次元が 100 次元に圧縮された。判定部では、車種クラスを小型車と大型車の 2 クラスとして、FCM によって得られた 8 個のクラスターの中で、第 5 クラスターの画像データを用いた。第 5 クラスターの画像データは、小型車が 1,281 個、大型車が 6,080 個の合計 7,361 個である。

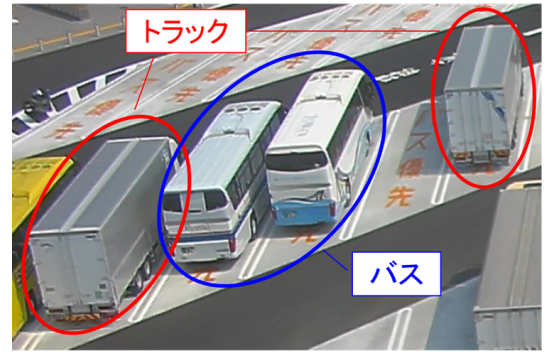


Fig. 4 Trucks and Buses



Fig. 5 Normalized Vehicle Images

pdi-Bagging を用いた車種識別では、寄与率を考慮し、100 次元の主成分から第 1 主成分と第 2 主成分のみの 2 次元属性の問題として取り扱った。したがって、ここでは、2 次元の 2 群判別問題となる。ただし、小型車のデータ数が大型車と比較して、約 1/6 程度となっている。そのため、従来法での車種識別の結果は、小型車が 65.06%、大型車が 96.80% の平均値 87.26% であった。この原因は小型車のデータ数が極端に少ないためであり、クラス間のデータ数の不均一が精度に影響を与えていると考えられる。そこで、pdi-Bagging を用いて、バーチャルデータを小型車の領域に大型車の台数とほぼ同程度になるまで発生させた。

一方、画像データを第 1 主成分と第 2 主成分の 2 次元上に表示した場合、小型車と大型車のクラスは、第 1 主成分のみで分離され、第 2 主成分には関与していない。小型車と大型車のデータ分布の例を図 6 と図 7 に示す。図 6 は学習データ、図 7 は評価データである。青色のデータが小型車を表し、桃色のデータが大型車を表す。また、第 1 主成分の 0.6 にガイドラインを入れている。学習データでは、小型車のデータ数が極端に少なく、第 1 主成分でのみ分離されている。そこで、バーチャルデータは、小型車クラス領域で、かつ、小型車を大型車と誤判別した学習データ周辺に発生させることにする。ただし、バーチャルデータは、過去の論文の結果 [9] から、識別率が良い誤判別型と混合判別クラスター中心型のみで発生することとする。

Table 1 Discrimination Rate of pdi-Bagging without Kickback and with Kickback

バーチャルデータ発生法	車種	キックバックなし pdi-Bagging	キックバックあり pdi-Bagging			
			1段階	2段階	3段階	4段階
誤判別型 (E) (%)	小型車	92.24	88.45	86.98	84.45	73.97
	大型車	96.26	98.04	98.19	98.02	99.10
	平均	95.58	96.37	96.24	95.66	94.73
混合判別クラスター中心型 (MC) (%)	小型車	91.54	88.35	82.70	85.26	74.80
	大型車	96.54	98.15	98.56	97.76	99.04
	平均	95.68	96.44	95.80	95.58	94.82




Fig. 6 Training Data Distribution of Small Type Vehicles and Large Type Vehicles




Fig. 7 Testing Data Distribution of Small Type Vehicles and Large Type Vehicles

弱判別器には簡易型ファジィ推論を用い、まず各入力区間 $[0, 1]$ に5種類の台形型メンバシップ関数を設定し、データ空間の全領域に25個の基盤ルールを設定した。基盤ルールのメンバシップ関数は台形型とするが、各次元の両端に配置するメンバシップ関数は直角台形型とした。ファジィ推論の前件部の初期値設定は既定法とし、前件部と後件部の学習順序は、後件部→前後件部交互学習とした。各入力の5種類のメンバシップ関数の学習係数 $K_b, K_\alpha, K_c, K_\beta$ は同一とし0.01に設定した。また、後件部のシングルトンの学習係数 K_p は、最初の後件部学習では0.4に設定し、交互学習の後件部学習では0.6とした。後件部と前後件部交互学習のエポック回数はをそれぞれ(10, 10, 10)である。バーチャルデータ発生時のメンバシップ関数 $\mu_F(x_j)$ は正規分布とし、バーチャルデータのクラス推定のための評価値の重みを $(w_1, w_2, w_3) = (0.5, 0.25, 0.25)$ に設定している。バーチャルデータの発生個数は、正誤判別データから11個とした。アルゴリズムの終了規範は繰り返し判定として、回数は $K = 5$ とした。ただし、混合判別型は、奇数層を

誤判別型とし、偶数層を正判別型とする。1エポックごとに乱数によりデータの並び順序を変更し、これらを1試行として、10試行の誤判別型と混合判別クラスター中心型の識別率を比較した。




Fig. 8 Data Distribution of Estimated Training Data by pdi-Bagging(E)




Fig. 9 Data Distribution of Estimated Training Data by pdi-Bagging(MC)

全画像データを5分割し、5-fold validationによって識別精度を得た。結果を表1のキックバックなし pdi-Baggingに示す。バーチャルデータの追加によって、誤判別型(E)の小型車の識別率は、従来法の65.06%から92.24%と向上している。また、混合判別クラスター中心型(MC)でも、小型車の識別率は91.54%と向上している。一方、大型車では、従来法の識別率の96.80%から、EとMCのそれぞれで96.26%と96.54%と若干低下している。しかし、平均値では、87.26%から95.58%や95.68%と向上している。これらの結果から、バーチャルデータの追加によって、識別率が向上することがわかる。なお、誤判別型と混合判別クラスター中心型の比較では、従来の結果[10]と同様に、混合判別クラスター中心型が誤判別型よりも識別率が

Table 2 Average Values of Data Distribution for Small and Large Type Vehicles by pdi-Bagging(E)

車種	主成分属性	教師値	キックバックなし pdi-Bagging	キックバックあり pdi-Bagging			
				1 段階	2 段階	3 段階	4 段階
小型車	第 1 主成分	0.4519	0.4582	0.4528	0.4263	0.3929	0.3841
	第 2 主成分	0.6608	0.6598	0.6597	0.6673	0.6765	0.6793
大型車	第 1 主成分	0.8237	0.8290	0.8275	0.8194	0.8086	0.8058
	第 2 主成分	0.4936	0.4907	0.4920	0.4964	0.5018	0.5031

高い。誤判別型の学習データに対する推定の識別データ分布を図 8 に示し、混合判別クラスター中心型の学習データに対する推定の識別データ分布を図 9 に示す。また、誤判別型の学習データに対する小型車と大型車の識別データ分布の平均値を表 2 に示す。図 6 の学習データにおける小型車クラスの第 1 主成分の平均値は 0.4519 であり、大型車クラスの第 1 主成分の平均値は 0.8237 であった。しかし、図 8 の誤判別型 (E) の学習データにおける小型車クラスの平均値は 0.4582 であり、大型車クラスの平均値は 0.8290 であった。また、図 9 の混合判別クラスター中心型 (MC) の学習データにおける小型車クラスの平均値は 0.4553 であり、大型車クラスの平均値は 0.8284 であった。これらの結果から、バーチャルデータを発生させた場合、バーチャルデータの発生数によっては、学習データに対する推定の判別線は過剰に第 1 主成分のプラス方向にシフトしていると考えられる。

そこで、第 1 主成分における判別線のプラス方向への過学習を抑えるため、モデルキックバックを提案する。モデルキックバックとは、過学習に対して判別線を元の位置方向に戻す処理である。ファジィ推論は、式 (1) からファジィルールの前件部のメンバシップ関数でデータ空間を分割し、その前件部のメンバシップ値で後件部のシングルTONを重み付け平均によって結合し全体の推定値を計算している。また、ファジィルールは、初期値配置 → 後件部学習 → 前後件部学習の過程で学習される。したがって、バーチャルデータの発生時に、バーチャルデータを過分に発生するか、バーチャルデータを一方のクラスのみ追加した場合、モデルキックバックは、前後件部学習で最適ルールが得られた場合のみに必要となる。ここでは、モデルキックバックの方法として、小型車クラスと大型車クラスの中点から小型車クラスに向かって第 1 主成分のマイナス方向に 4 段階でキックバックを実行した。




Fig. 10 1st Data Distribution of Estimated Training Data by pdi-Bagging(E)




Fig. 11 2nd Data Distribution of Estimated Training Data by pdi-Bagging(E)




Fig. 12 3rd Data Distribution of Estimated Training Data by pdi-Bagging(E)




Fig. 13 4th Data Distribution of Estimated Training Data by pdi-Bagging(E)

誤判別型でのモデルキックバックによる学習データの推定の識別データ分布の平均値の変化を表 2 に示す。また、モデルキックバックの第 1 段階から第 4 段階の学習データに対する推定の識別データの分布を図 10 ~ 図 13 に示す。

表2から、モデルキックバックにより、小型車と大型車の第1主成分の平均値が第1主成分のマイナス方向に移動していることがわかる。実際、図10～図13のように、小型車と大型車を識別する境界線は、第1主成分のマイナス方向へ移動している。このモデルキックバックを施したことによる誤判別型と混合判別クラスター中心型の評価データに対する識別率を表1のキックバックあり pdi-Bagging に示す。モデルキックバックを4段階で施したことによって、小型車の識別率は減少し、大型車の識別率は上昇している。しかし、平均値では、誤判別型の第1段階で最大識別率96.37%を得て、混合判別クラスター中心型の第1段階で最大識別率96.44%を得ている。これらの識別率は、キックバックなし pdi-Bagging の識別率よりも高い。なお、誤判別型と混合判別クラスター中心型の比較では、ほぼ同程度の高い識別率となっており、両手法とも、モデルキックバックの効果が現れていると思われる。

以上の結果から、pdi-Bagging のモデルキックバックは、学習データに対する過学習を抑え、モデルキックバック後では、評価データに対する識別精度が向上する効果があるといえる。

5 おわりに

本論文では、バーチャルデータの発生とモデルキックバック方式を採用した pdi-Boosting を用いて、大規模屋外駐車場の広角 IP カメラ映像から車両の種別を識別する車種識別システムを構築した。また、実際の大規模屋外駐車場の画像データに対する結果から、本システムが車種を高精度で識別できることを示した。今後、判別線の同定精度を向上させるため、より効率的なバーチャルデータの発生方法やキックバックの方式等について議論する必要がある。

なお、本研究の一部は、科学研究費補助金基盤研究(C)一般「バーチャルデータ発生型ファジィバギングを用いた放送映像の卓球戦略獲得ボードの開発」(No.20K11981, 2020年～2025年)の助成を得た。

参考文献

- 1) ニチゾウテック：駐車場誘導・管制システムの設計・施工, <https://www.nichizotech.co.jp/product/parking/>, 2021年7月1日現在(2021)
- 2) 川口, マッキン, 堅多, 永井：広角監視カメラを用いた平面駐車場内の混雑度分類手法の検討, 情報処理学会第82回全国大会, No.1U-06(2020)
- 3) 川口, マッキン, 永井, 堅多：CNNによる平面駐車場混雑度分類手法の提案, 情報処理学会第83回全国大会, No.5R-02(2021)
- 4) 堅多：カメラ式車両検知ソフトの開発, ニチゾウテック技報, Vol.1, pp.56-61(2021)
- 5) L.Breiman: Bagging Predictors, *Machine Learning*, Vol.24, No.2, pp.123-140(1996).
- 6) 上田：アンサンブル学習, 情報処理学会論文誌, Vol.46, No.SIG15(CVIM12), pp.11-20(2005)
- 7) R.Polikar: Ensemble Based Systems in Decision Making, *IEEE Circuits and Systems Magazine*, Vol.6, No.3, pp.21-45(2006).

- 8) 近藤, 菊地, 堀田, 渋谷, 前田：ランダムな特徴選択とバギングを利用した欠陥分類, 画像電子学会誌, Vol.38, No.1, pp.9-15(2009)
- 9) 入江, 林：正誤バーチャルデータの発生による pdi-Bagging の特性評価, 第29回インテリジェント・システム・シンポジウム講演論文集, Paper ID:No.A3-3(2019)
- 10) 入江, 林：pdi-Bagging による発生バーチャルデータのクラス決定法の提案, 第34回人工知能学会全国大会講演論文集, Paper ID:No.103-GS-8-04(2020)
- 11) 入江, 林:台形型メンバシップ関数による学習型ファジィ推論の設計評価, 知能と情報, Vol.31, No.6, pp.908-917(2019)
- 12) 市橋, 渡邊:簡略ファジィ推論を用いたファジィモデルによる学習型制御, 日本ファジィ学会誌, Vol.2, No.3, pp.429-437(1990)
- 13) 市橋, 野津, 本多:セミハードクラスタリングとその識別器への応用, 日本知能情報ファジィ学会誌, Vol.22, No.3, pp.358-367(2010)
- 14) 林, 鶴背:確率的データ補間を用いたBCIのためのBoosting アルゴリズムの提案, 信学技報, Vol.109, No.461, pp.303-308(2010)

[連絡先]

林 勲 関西大学大学院 総合情報学研究科
〒569-1095 大阪府高槻市霊仙寺町2-1-1
tel. 072-690-2448
fax. 072-690-2491
e.mail ihaya@kansai-u.ac.jp