

10th SICE Symposium on Computational Intelligence
December 16-17, 2016, Toyama

第10回
コンピューターショナル・インテリジェンス研究会
講演論文集

会 期： 2016年10月16日（金）， 17日（土）

会 場： 富山県民会館

SICE®

カタログ番号 16 PG0010

著作権 © 2016

公益社団法人計測自動制御学会(SICE)
〒113-0033 東京都文京区本郷 1-35-28-303

カタログ番号 16 PG 0010

著作権は、計測自動制御学会がもっている
ので、個人の使用のための複製以外の
目的で掲載の記事の一部または全文を
複製する場合には、著作権者に許可を求
め規定の複製料を支払うこと。

発行日：2016年12月16日

発行者：公益社団法人計測自動制御学会 システム・情報部門
コンピューターショナル・インテリジェンス部会

第10回コンピューショナル・インテリジェンス研究会 プログラム

会場：富山県民会館 702室

日時：12月16日(金) 12:50~17:15

12月17日(土) 9:30~16:25

12月16日(金)

12:50~13:00 開会

13:00~14:15 交通・最適化 司会：岡本 卓(千葉大学)

最適化指向マルチエージェント型交通シミュレーションにおけるパラメータ推定モデル

○榊原 一紀, 坂井 篤司(富山県立大学), 松本 卓也, 大原 誠, 玉置 久(神戸大学)

バス路線運行安定性のベイズ推定

○南 哲志, 橘 完太(工学院大学)

SMOを用いた利己的経路選択ゲーム問題の均衡解探索の高速化

○樋田 一博, 吉田 皓一, 岡本 卓, 小塚 成一(千葉大学)

14:30~15:45 最適化・画像処理 司会：榊原 一紀(富山県立大学)

差分進化における個体のグループ化とグループ別パラメータ制御の効果

○高濱 徹行(広島市立大学), 阪井 節子(広島修道大学)

天球画像のオプティカルフローを用いた旋回時の視線方向の違いによる比較

○永井 祐輔, 増田 寛之, 岡島 恵一, 本吉 達郎, 澤井 圭, 小柳 健一, 大島 徹(富山県立大学), 高山 英一((株)高山自動車)

天球画像のオプティカルフローを用いた物体の接近表現

○岡島 恵一, 増田 寛之, 永井 祐輔, 本吉 達郎, 澤井 圭, 小柳 健一, 大島 徹(富山県立大学), 高山 英一((株)高山自動車)

16:00~17:15 最適化・ディープニューラルネットワーク 司会：畠中 利治(大阪大学)

探索点の移動方向からみたPSOとFAの比較

○肖 恒, 大井 允人, 畠中 利治(大阪大学)

マルチモーダル深層自己符号化器におけるモダリティ間パラメータ共有の検討

○佐々木 勇人, 中田 雅也, 濱津 文哉, 濱上 知樹(横浜国立大学)

Deep Convolutional Neural Network を用いた乳房X線画像上の病変検出

○鈴木 真太郎, 張 暁勇, 本間 経康, 市地 慶, 魚住 洋佑(東北大学), 高根 侑美(東北大学病院), 川住 祐介, 石橋 忠司, 吉澤 誠(東北大学)

18:00~20:00 技術交流会 会場：富山県民会館8F レストラン清風

12月17日(土)

9:30~9:55 機械学習 司会：増田 寛之(富山県立大学)

モデル予測制御向けニューラルネットワークの構成検討

○堀口 辰也, 広津 鉄平 ((株)日立製作所)

自己組織的ターゲット検出モデルによる分布推定アルゴリズムについて

○岩崎 悟, 畠中 利治 (大阪大学)

多様なエージェントによる集団強化学習の自動帆走への応用

○橘 完太, 深沢 竜大 (工学院大学)

11:00~12:15 学習・予測 司会：橘 完太(工学院大学)

不確実性を考慮した遺伝的アルゴリズムによるバスダイヤの生成

○沼田雅史, 橘 完太 (工学院大学)

構造適応型Deep Belief Networkによる時系列データの分析

○鎌田 真(広島市立大学), 市村 匠, 丸山 壘 (県立広島大学)

両眼水平速度対による動的衝突予測法

○森 文彦, 菅野 直敏(玉川大学)

13:15~14:55 画像・ロボティクス 司会：松野 隆幸(岡山大学)

大豆の子実検知を行う画像センシング手法の開発

○山口 幹太, 小澤 誠一, 北園 淳(神戸大学), 吉田 武史(青山学院大学), 大川 剛直(神戸大学), 村上 則幸, 辻 博之(北海道農業研究センター)

大豆の花検知と花数計測を行う画像センシング手法の開発

○大西 哲, 北園 淳, 小澤 誠一(神戸大学), 吉田 武史(青山学院大学), 大川 剛直(神戸大学), 村上 則幸, 辻 博之(北海道農業研究センター)

ロボットによる柔軟物操作における複数視点撮影のためのハンドアイシステム

○渡部 知俊, 松野 隆幸, 白川 智也, 見浪 護 (岡山大学)

組み込みシステム向け異常検知方式

○中川 慎二 ((株)日立製作所)

15:10~16:25 カオス・ニューラルネットワーク 司会：本間 経康(東北大学)

カオス四元数連想メモリによる動的な想起

○長名 優子 (東京工科大学)

リズム現象に対するパラメータ感度の解析法とその設計への応用

○森 禎弘, 黒江 康明 (京都工芸繊維大学)

四元数ニューラルネットを用いた筋電位による前腕姿勢の推定

○小川 毅彦, ハフィズディン フィルダウス ビン ハシム (拓殖大学)

最適化指向マルチエージェント型交通シミュレーションにおけるパラメータ推定モデル

○榊原一紀 坂井篤司 (富山県立大学)
松本卓也 大原誠 玉置久 (神戸大学)

Parameters estimation model for multi-agent simulation of urban transportation systems

*K. Sakakibara, A. Sakai (Toyama Prefectural University)
T. Matsumoto, M. Ohara and H. Tamaki (Kobe University)

Abstract— We propose an assessment technique for the urban traffic system using the multi-agent simulation with optimization models. Traveler agents decide their routes and means of mobility by optimizing their utility functions. A decision making process of each agent is divided into a common part and an individual part where all the minimum travel routes are calculated for each means of mobility in the former part and the combination of transportation options for each agent with the given origin/destination places is optimized in the latter part. In this paper, we show a parameter setting method for the sense of value in the selection of the means of mobilities by using questionnaires to the residents.

Key Words: Urban traffic, Multi-agent simulation, Mathematical optimization, Questionnaire

1 はじめに

本稿ではとくに都市交通に対するマルチエージェント・シミュレーションを取り上げ、シミュレーション・パラメータの推定を最適化モデルとして記述し、メタヒューリスティクスによる最適化を試みる。マルチエージェント・シミュレーションでは一般に、シミュレーション精度が上がるに連れてそれに付随するパラメータ数が増大する傾向にあり、それらを妥当な値に設定するには困難さが伴う。そこで本研究では、現実の交通行動結果と一致するようなパラメータ群を導出する最適化モデルを提案する。

著者らはこれまでに、マルチエージェント・モデルにおいて、エージェントの意思決定に最適化アルゴリズムを組み込んだシミュレーション技法を開発し³⁾、実際の都市交通システムへの適用を通じて、交通システムの定量評価の方法を示した⁴⁾。これらでは、市町村程度の規模の地域における住民全体の交通行動を現実的な計算時間で表現し得ることを確認し、具体的な都市交通として富山県射水市における公共交通サービスを取り上げ、交通システムの定量評価を行った。

エージェントの意思決定においては、より現実に対応した交通行動を計算機上で表現をするために、住人それぞれの交通行動における価値観を陽に考慮した意思決定モデルを作成した。このモデルでは、出発地から目的地までの移動経路及び移動手段の組み合わせであるトリップの候補から、コストパラメータ、疲労度パラメータおよびエージェントの価値観パラメータを含む評価関数を計算し、評価値が最小となるトリップを探索する。ここで、コストパラメータについては、現実の交通手段の利用に対する価格を設定すればよく、容易に設定可能である。一方、疲労度パラメータについては、疲労の程度を数値化することは困難であり、その設定は容易ではない。

これまで、疲労度パラメータは、住民を対象としたアンケート結果に基づくパラメータ推定により決定していた⁵⁾。このパラメータの推定では、ある距離に対

して住民すべてが最も代表的な移動手段のみをとると仮定していたため、住民の多様性を考慮できていないという問題があった。加えて、従来のパラメータ設定では、神戸市を対象としたアンケート調査により決定をしていたが、都市の違いにより交通の特性は大きく変わることから⁶⁾、射水市を対象とした都市交通シミュレーションにおいては、従来のパラメータの決定方法は適切でないといえる。また、価値観パラメータの決定については従来は、一様乱数から得られた値を価値観パラメータとし、エージェント一人ひとりの価値観パラメータを決定していた。しかし、現実の住民の交通手段の選択に対する価値観は、住人の職業や年齢等の個人属性により異なると考えられ、従来の価値観の決定ではこのような住人の属性の違いによる価値観の差異を考慮することはできない。

そこで本稿では、住民の多様性を考慮可能な交通行動パラメータの推定法を提案する。また、射水市を対象とした交通アンケート調査を用いて、提案法によりパラメータ推定を行い、推定したパラメータを用いた交通シミュレーションの結果と公的統計資料と比較することにより提案法の妥当性を検討する。

本稿では、2章に筆者らが扱うマルチエージェントシミュレーションのモデルを示し、3章にパラメータ推定の最適化モデル、4章に最適化問題の解法、5章にパラメータ推定の結果、6章にパラメータ推定モデルの妥当性の評価結果、7章にまとめを示す。

2 都市と交通のモデル

2.1 モデルの概要

都市における日常的な人の移動は、都市と交通を構成する基本要素として、都市の構造、移動手段、住人を考え、それぞれを下記のように捉える。

都市の構造 都市は格子状に連なった複数の矩形の地区と隣接した地区の間にある区間からなるとする。エージェントの移動元 (Origin) と移動先 (Destination) (OD とよぶ) は出発地区と目的地区の組で

与えられ、エージェントの移動は地区から地区へ区間をたどることによって表わされるものとする。区間は道路の大きさ、鉄道の有無などを属性として持つ。地区を地理情報システム (GIS: Geographic Information System) ⁷⁾ のメッシュに準拠させることにより、GIS 情報の利用が可能となる。

移動手段 徒歩、自転車、自家用車、バス、鉄道などの住人が移動に用いる手段を移動手段と呼ぶ。各移動手段はコストや疲労度などのパラメータを持つ。

住人 住人は移動を行う主体であり、エージェントとしてモデル化される。住人エージェントは自身の OD を持ち、これに年齢区分や運転免許の有無などの属性やコストと疲労度に対する価値観を加味して自身のトリップを決定する。属性や価値観はエージェントによって異なるため、同一条件下においても各エージェントは異なるトリップを選択し得る。エージェントの意思決定モデルは 2.3.2 節に詳細に述べる。

2.2 基本要素

以下、エージェントの意思決定における基本要素を示す。- は定数、* のつくものはエージェントの決定変数であり、o はそれにしたがって決定される従属変数である。また + は、シミュレーションには直接関係しないものの、結果表示の見やすさのために使われる定数である。

- 規模
 - 東西方向地区数 M
 - 南北方向地区数 N
 - 住人エージェント数 I
 - 1つの住人エージェントに対応する人口 p^I
 - 移動手段種類 J
 - アルゴリズム 1(2.3.2 節に後述) 実行回数 F
- 地区 Z_{mn} ($m \in \{1, \dots, M\}, n \in \{1, \dots, N\}$)
 - バス停の有無 $s_{mn} \in \{0, 1\}$
 - + 地形 $g_{mn} \in \{0, 1, 2, \dots\}$
- 区間 D_{mn}^X ($m \in \{1, \dots, M-1\}, n \in \{1, \dots, N\}$), D_{mn}^Y ($m \in \{1, \dots, M\}, n \in \{1, \dots, N-1\}$) (D_{mn}^X は東西区間, D_{mn}^Y は南北区間)
 - 道路の容量 l_{mn}^X, l_{mn}^Y
 - 路線の有無 $a_{jmn}^X, a_{jmn}^Y \in \{0, 1\}$
 - 地区間距離 r_{mn}^X, r_{mn}^Y [m]
 - 地区間拡張距離 v_{mn}^X, v_{mn}^Y [m]
 - 道路の交通量 u_{mn}^X, u_{mn}^Y
- 住人エージェント P_i ($i \in \{1, \dots, I\}$)
 - 利用可能移動手段 $a_{ij} \in \{0, 1\}$
 - コスト価値観 w_i^C ($0 \leq w_i^C \leq 1$)

- 疲労度価値観 w_i^T ($0 \leq w_i^T \leq 1$)
($w_i^C + w_i^T = 1$)
- 出発地区 $z_{imn}^O \in \{0, 1\}$
- 目的地区 $z_{imn}^D \in \{0, 1\}$
- * 区間経路選択 $y_{ijmn}^X \in \{0, 1\}, y_{ijmn}^Y \in \{0, 1\}$

● 移動手段 M_j ($j \in \{1, \dots, J\}$)

- 道路を使用する移動手段か否か $u_j^R \in \{0, 1\}$
- バス停を使用する移動手段か否か $u_j^S \in \{0, 1\}$
- 乗り換えの可不可 $t_{j_1, j_2} \in \{0, 1\}$
- 複数回利用の可不可 $m_j \in \{0, 1\}$
- 利用コスト (距離従属) c_j^A [Yen/m]
- 利用コスト (固定) c_j^B [Yen]
- 疲労度 (距離従属) t_j^A
- 疲労度 (固定) t_j^B

2.3 住民エージェントの意思決定

2.3.1 基本方針

2 節で示したシミュレーションは、住人エージェントが与えられた OD 情報に対してトリップを決定すること、つまり、 y_{ijmn}^X, y_{ijmn}^Y を決定することで行われる。本研究では、各エージェントは移動行動に対して距離と移動手段に対する評価値を持ち、それらから計算される評価値を最適にするよう行動すると仮定する。このとき全てのエージェントの評価値を最小とするような最適化により、トリップを決定する。

ここで、エージェントの意思決定を計算量的な観点から見ると、移動手段選択に対する経路選択は非常に膨大な組み合わせとなる。したがって、実用的な時間でシミュレーションを行うには、経路探索の計算負荷を軽減することが重要である。そのため、経路探索において住民エージェントそれぞれに共通して扱うことのできる部分を共通化することによる計算負荷の軽減を図る。そのため、

1. エージェントによって拡張距離は異なる、
2. 同一の道路・線路を用いる場合は移動手段によって拡張距離は異なる、

の 2 つの仮定をおく。拡張距離とは、経路の距離に渋滞などによる影響を加味したものであり、交通量に応じた所要時間の増加を距離の増加として擬似的に捉えるものである。仮定 1 を設けることにより、最短拡張距離を持つ経路の探索をエージェント毎に行う必要がなくなる。つまり乗り換えをしない場合の経路探索についてはエージェント毎に行う必要がなく、全地区間の最短経路探索の結果を全てのエージェントで共有することが可能となる。自転車で駅まで行きそこから電車に乗り徒歩で目的地に着くなど、複数の移動手段を組み合わせる用いる場合には、エージェント各々の意思決定が必要であるが、その場合でもそれぞれの移動手段の利用区間については上記の結果をそのまま利用できるため、探索すべき組み合わせ数は大幅に減少する。また仮定 2 は、道路を使用する移動手段が経路探索結果を共有することを可能にするため、移動手段毎に計算を行う必要がなくなる。

2.3.2 エージェントの意思決定方法

住人エージェントはコストと疲労度に対する価値観を持ち、その価値観はエージェントによって異なる。エージェントはその価値観に従って移動手段および経路、つまりトリップを決定する。その意思決定過程は、前述の仮定により全てのエージェントについて以下のように共通の部分と個別の部分に分けられる。

アルゴリズム 1 (共通部) 地区間に距離と混雑度から算出される擬似的距離を設定し、全地区間について、その擬似的距離の経路和を最小にする経路を Warshall-Floyd 法⁸⁾ を用いて求める。

アルゴリズム 2 (エージェント個別部) エージェントはそれぞれ固有のコストと疲労度に関する価値観を持ち、それらとアルゴリズム 1 で得られた最短経路を用いて、評価値を計算し、それを最適にするような利用地区及び移動手段を分枝限定法⁹⁾ を用いて決定する。

アルゴリズム 2 においてエージェント P_i の意思決定は、トリップ R のコスト C_R 、疲労度 T_R および住人の価値観 w_i^C, w_i^T を用いて評価値

$$f_i(R) = w_i^C C_R + w_i^T T_R \quad (1)$$

を計算し、

$$f_i^* = \min_{R \in \mathcal{R}_i} f_i(R) \quad (2)$$

の最適値を持つ最適トリップ R_i^* を探索することで行われる。ここで、トリップのコスト C_R および疲労度 T_R は拡張距離の線形式で表されるとする。コスト C_R は与えられるものと考え、疲労度のパラメータを推定することを考える。疲労度 T_R については、

$$T_R = \sum_{\ell=1}^{L_R} (t_{j_{R\ell}}^A v_{R\ell} + t_{j_{R\ell}}^B) \quad (3)$$

と表され、ここで、 L_R はトリップ R の移動手段の段数であり、 $j_{R\ell}$ はトリップ R の ℓ 段目の移動手段、 $v_{R\ell}$ は ℓ 段目の拡張距離である。さらに、(1) 式は

$$f_i(R) = w_i^C C_R + w_i^T (t_{j_{R\ell}}^A v_{R\ell} + t_{j_{R\ell}}^B) \quad (4)$$

となる。アンケート結果から、移動手段 j の疲労度パラメータ t_j^A と t_j^B を推定する。

3 交通アンケートに基づくパラメータ推定

従来、 t_j^A と t_j^B は神戸市で実施したアンケートに基づいて推定したパラメータを用い⁵⁾、価値観パラメータについては一様乱数から決定をしていた。 t_j^A と t_j^B のパラメータ推定においては、 w_i^C, w_i^T は双方を 0.5 とし、 t_j^A と t_j^B をアンケート結果とモデルの選択の一致度を最大にする最適化問題を解くことによって与えていた。しかし、この方法では距離に対して一般的な住人の移動手段のみを評価の対象としており、住民の多様性に対する考慮が不足している。また、住民の全てのエージェントの価値観パラメータの決定については、一様乱数により決定をしていたが、この方法では、エージェントの個人属性の違いに因る交通行動に対する価値観の差異を考慮できない。

Table 1: The general outline of questionnaire

項目	内容
被験者	富山県内の高校生 およびその家族
実施期日	2015 年 10 月, 2016 年 8 月に実施
サンプル数	418
対象地域	富山県射水市および周辺地域
調査項目	①個人属性 ②免許の有無 ③指定した 2 地点間を移動 する際の利用交通手段

本章では、パラメータ推定で使用したアンケート調査について述べ、次に住民の多様性を考慮した交通アンケートに基づくパラメータ推定のための最適化問題を示す。

3.1 アンケート調査

アンケート調査の概要を Table1 に示す。調査項目②の指定した 2 地点間の利用交通手段を問う設問は計 7 問あり、設問の一つひとつが被験者の拡張距離に対する最適な交通手段を示しているものと捉える。実際には、同じ距離であっても他の要因により異なる移動手段が選ばれる場合も当然あると考えられるが、簡略化のため考慮しないものとする。

また、2 地点間を移動する場合、電車を利用した後に自転車を利用するというように、2 種類以上の交通手段を利用する場合も考えられるが、アンケート調査においては単一の交通手段で移動する場合を想定する。パラメータ推定に対する、最適化モデルにおいても、単一の交通手段で移動する場合を考える。

3.2 パラメータ推定の最適化モデル

疲労度パラメータと価値観の分布の推定は以下に示すステップ 1, ステップ 2 の 2 段階の最適化問題を解くことで推定を行う。

ステップ 1 住民の多様性を考慮するために、住民 P_i の価値観 w_i^C, w_i^T を 0.5 を平均とした両側切断正規分布に従った分布を持つと仮定した上で、疲労度パラメータ推定

ステップ 2 ステップ 1 で求めた疲労度パラメータを定数として扱いエージェントの価値観の分布を表す両側切断分布の平均と分散を推定

ここで、筆者らが対象とする都市の交通において、自家用車を使って自動車で移動するかその他の交通手段を用いるかの選択は、交通行動決定の重要な要因であると考えられ、それゆえに自動車免許の有無は交通行動に大きな差をもたらす。例えば、自動車免許を持っていない住人は自家用車を交通手段として選択しないが、だからといって必ずしも自家用車を他の交通手段よりも劣った交通手段だと考えているわけではない。各交通手段に対する価値観が同一の住人であっても、自動車免許の有無によって全く異なる交通手段選択となることは十分に考えられ、また実際に頻繁に起こっていると考えられる。したがって住民の自動車免許の有無を陽に考慮した最適化モデルを考える。

3.2.1 基本要素

パラメータ推定の最適化モデルの基本要素を以下に示す。－は定数、*のつくものは決定変数であり、○はそれにしたがって決定される従属変数である。

- － 交通手段番号 j ($j \in \mathcal{J}$)
- * 疲労度 (距離従属) t_j^A
- * 疲労度 (固定) t_j^B
- － 住人のカテゴリ c
- * カテゴリ c のエージェントの価値観の分布を表す正規分布の平均 μ_c
- * カテゴリ c のエージェントの価値観の分布を表す正規分布の標準偏差 σ_c
- － アンケートの設問番号 q ($q \in \mathcal{Q}$)
- － 設問番号 q における 2 地点間の距離 v_q ($q \in \mathcal{Q}$)
- － 住人の免許の有無 k $k = 0$ は自動車免許有りの住民を表し、 $k = 1$ は自動車免許無しの住民を表す。
- モデルを用いたシミュレーションから得られる v_q に対する j の選択確率 $p_j^M(v_q)$
- k の住人の距離 v_q に対して交通手段 j を選択するときの価値観 w の集合 $D_{jk}(v_q)$
- － q の回答者の免許有りの人の割合 R_q
- － k の住民が利用可能な移動手段の集合 \mathcal{A}_k
- － アンケート結果における設問 q の v_q に対する j の選択割合 $p_j^Q(v_q)$
- － 設問 q の距離 v_q に対してカテゴリ k の住人が選択した交通手段 j の総数 $a_{jk}(v_q)$

3.2.2 目的関数

モデルを用いたシミュレーション結果としての移動手段選択割合 $p_{jk}^M(v_q)$ と、アンケート結果から導出した選択割合 $p_{jk}^Q(v_q)$ の二乗誤差の最小化を目的とする。

$$\min \sum_{j \in \mathcal{J}, q \in \mathcal{Q}} y_{jq} \left(p_j^M(v_q) - p_j^Q(v_q) \right)^2 \quad (5)$$

目的関数に用いる重み y_{jq} については、

$$y_{jq} = b^{P_j^Q(v_q)} \quad (6)$$

とする。ただし、 b は定数である。後述するパラメータ推定では、予備実験の結果から $b = 3$ として推定を行った。この重みを導入することにより $p_{jk}^Q(v_q)$ が小さい値を取る時に重みを大きくすることができる。これにより利用されない交通手段をより考慮することができる。

3.2.3 制約条件

以下にパラメータ推定の最適化モデルの制約条件を示す。

- モデルからの選択確率の導出

$$p_j^M(v_q) = R_q \int_{D_{j0}(v_q)} \psi(w; \mu, \sigma) dw + (1 - R_q) \int_{D_{j1}(v_q)} \psi(w; \mu, \sigma) dw \quad (j \in \mathcal{J}, q \in \mathcal{Q}) \quad (7)$$

免許の有無を考慮するために、カテゴリ k 毎の $D_{jk}(v_q)$ を求め、 R_q を用いてカテゴリ毎の交通手段の選択割合を求め、加算したものを $p_j^M(v_q)$ とする。ただし、 $\psi(w; \mu, \sigma)$ は、平均 μ 、標準偏差 σ の正規分布を基とした $0 \leq w \leq 1$ の両側切断正規分布の確率分布であり、平均 0、標準偏差 1 の正規分布の確率密度関数を $\phi(\cdot)$ 、累積分布関数を $\Phi(\cdot)$ とすると、 $0 \leq w \leq 1$ において、

$$\psi(w; \mu, \sigma) = \frac{\frac{1}{\sigma} \phi\left(\frac{w-\mu}{\sigma}\right)}{\Phi\left(\frac{1-\mu}{\sigma}\right) - \Phi\left(\frac{0-\mu}{\sigma}\right)} \quad (8)$$

であり、それ以外の範囲では $\psi(w; \mu, \sigma) = 0$ である。また $D_{jk}(v_q)$ は、

$$D_{jk}(v) = \left\{ w \mid \arg \min_{j' \in \mathcal{A}_k} \{ w C_R + (1-w)(t_{j'}^A v + t_{j'}^B) \} = j \right\} \quad (j \in \mathcal{J}, q \in \mathcal{Q}) \quad (9)$$

である。

- アンケート結果からの選択割合の導出：

$$p_{jk}^Q(v_q) = \frac{a_{jk}(v_q)}{\sum_j a_{jk}(v_q)} \quad (j \in \mathcal{J}, q \in \mathcal{Q}) \quad (10)$$

分母に距離 v_q 毎の回答の総数とし、分子をそれぞれの交通手段の選択数として $p_{jk}^Q(v_q)$ を求める。

4 SA によるパラメータ推定

3.2 節で示したパラメータ推定の最適化モデルを焼きなまし法 (Simulated Annealing: SA)¹⁰⁾ により求める。本章では、そのアルゴリズムを示す。

4.1 SA のアルゴリズム

下記に SA を用いたパラメータ探索の流れを示す。

- 1° 初期解 \mathbf{X} をランダムに生成し、最良解 \mathbf{X}^* として記録
- 2° 初期温度 T を設定
- 3° 試行回数 $l := 0$, 解の更新回数 $u := 0$ に設定
- 4° \mathbf{X} から近傍解 \mathbf{X}' をランダムに生成し、 $\Delta := f(\mathbf{X}') - f(\mathbf{X})$

- 5° $\Delta < 0$ の時は必ず Step6 へ、それ以外は T の値に従う確率 $e^{(-\Delta/T)}$ で Step7 へ、
- 6° $u := u + 1, \mathbf{X} = \mathbf{X}'$
 $f(\mathbf{X}) < f(\mathbf{X}^*)$ ならば、 $f(\mathbf{X}^*) := f(\mathbf{X})$,
 $\mathbf{X}^* := \mathbf{X}$
- 7° $l < l^E$ または $u < u^E$ なら、 $l := l+1$ とし、Step4 へ
- 8° $T > T^E$ なら、冷却率 r^C を用いて $T := r^C T$ とし、Step 3 へ
- 9° 最良解 \mathbf{X}^* を出力し、終了

ただし、 l^E は最大探索回数、 u^E は解の最大更新回数、 r^C は冷却率、 T^E は最小温度を表す。また、解 \mathbf{X} は、以下の要素からなるベクトルである。

- 疲労度パラメータ t_j^A, t_j^B ,
- 各カテゴリの住人の価値観の分布を表す平均 μ_c 、標準偏差 σ_c

この \mathbf{X} の評価値 $f(\mathbf{X})$ は、3.2.2 節に示した目的関数により求める。また、Step4°での近傍解の生成は、 \mathbf{X} から摂動させるパラメータを1つランダムに選択をし、そのパラメータに対応する摂動量に $[-1, 1]$ の一様乱数を乗算した値を加えたパラメータを用いた時の解を近傍解 \mathbf{X}' として生成する。

5 パラメータ推定の結果

4章で示したSA法により、3.2章で示したパラメータ推定のための最適化モデルを段階的に解いた。本研究は、射水市の都市交通シミュレーションのためのパラメータ推定を目的しており、このシミュレーションでは市内の交通行動を対象としているため、電車による市外への移動は考えない。したがって、今回推定する疲労度パラメータは徒歩 ($j = 0$)、自転車 ($j = 1$)、自家用車 ($j = 2$)、バス ($j = 3$) の疲労度パラメータである。ここで、徒歩の疲労度パラメータの固定値 t_0^B については、0に固定する。この理由としては、徒歩を利用する上で、車を駐車することやバスを利用するには時刻表を調べなければならない等の煩わしさが無いと考えられるためである。この疲労度パラメータの推定の結果を用いて、カテゴリ毎の価値観の分布を表す正規分布の平均 μ_c と分散 σ_c^2 を推定する。ここで住民の属性を表すカテゴリは、職業状態、年齢、性別等の分類が考えられるが、本研究では職業状態の分類でカテゴリ分けをし、「学生」、「フルタイム」、「パートタイム」、「無職」で住民のカテゴリを設定した。

5.1 SAのパラメータ設定

4.1節に示したSAのパラメータ値は、文献¹⁰⁾の方法に基づき決定した。 l^E 、 u^E の決定については、各パラメータの摂動パターン数に十分に探索回数および解の更新回数が大きくなるように定数を乗算する値として l^E 、 u^E を決定し、 r^C については、 $r^C = 0.95$ とした。 T^E の決定については予備実験の結果から、温度が充分低い温度として $T^E = 10^{-5}$ とした。

5.2 パラメータ推定の結果

5.1節に示したパラメータ設定で、CPU:Quad-Core Intel Xeon E5、メモリ:16GBの計算機を用いて推定を行い、計算時間は約30時間であった。30回の試行から得られた最良解 \mathbf{X}^* を Table.2 に示す。また、評価値の変化の例として3個の初期解パターンでの評価値の変化を Fig. 1 に示す。Fig.1 から、温度の低下に伴って評価値が次準最適値に収束していくことを確認できる。

次章では、パラメータ推定モデルの妥当性を検証するために Table.2 に示した疲労度パラメータを用いて筆者らが開発した都市交通シミュレーションの出力結果を統計資料と比較をする。

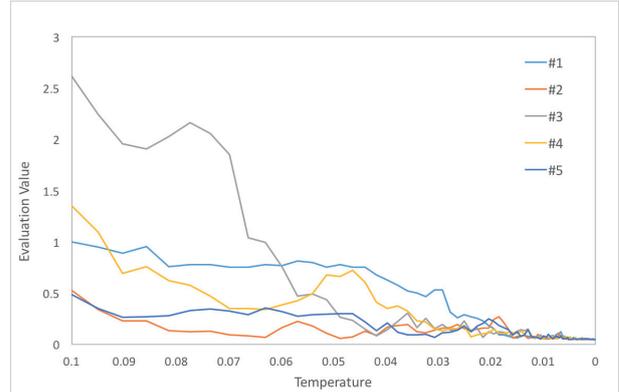


Fig. 1: Comparison of simulation result and statistical survey

Table 2: The result of estimating tiredness parameters

	t_j^A	t_j^B
walk($j = 0$)	1.704052851	0
bicycle($j = 1$)	1.138514941	304.1297134
car($j = 2$)	0.150109443	0.310758883
bus($j = 3$)	1.105191515	225.6309406

Table 3: The result of estimating average and standard deviation

Category	μ_c	σ_c
Student($c = 0$)	0.510926868	0.325543147
Fulltime($c = 1$)	0.515716822	0.230630875
Parttime($c = 2$)	0.528290436	0.223791587
Unemployed($c = 3$)	0.446483618	0.270490511

6 パラメータ推定モデルの妥当性の検証

提案したパラメータ推定モデルの妥当性の検証を筆者らが開発した都市交通シミュレータ³⁾を用いて、推定したパラメータを使用した時の出力結果と国勢調査の統計資料¹¹⁾を比較することにより行う。本章では、都市交通シミュレーションの設定を示し、パラメータ推定モデルの妥当性の検証を行う。

6.1 シミュレーションの設定

シミュレーションの対象地域は富山県射水市の中心市街地とする。住民エージェント数は、対象とした地域の5分の1とする。地区は100メートルメッシュに区切り、東西方向の地区数 M 、南北方向の地区数 N を、 $M = N = 60$ とする。住民エージェントが持つOD情報については平日・朝の通勤・通学時間帯を想定し、ま

ず Origin 側として、地区ごとの人口を GIS により取得する。次に、対象地域の主要な施設(高等学校, 大学, 病院, スーパーマーケット, 公園, 工場など)をピックアップし、年齢構成, 性別および産業別就業人口(それぞれ 2013 年当時)に基づき Destination 側を設定し、生成された Origin と Destination をランダムに組み合わせることにより各エージェントの OD, つまり発地区 z_{imn}^O と到着地区 z_{imn}^D を設定する。移動手段 M_j は順に徒歩, 自転車, 自家用車, 路線バス ($J = 4$) とする。移動手段の利用コストパラメータ c_j^A, c_j^B は, 現実のコストを設定し, 疲労度のパラメータ t_j^A, t_j^B は, 5.2 節に示したパラメータとする。エージェントの価値観は, 5.2 節に示した平均, 分散の値を基にした両側切断正規分布に従った価値観を与え, 疲労度価値観 w_i^T は $w_i^T = 1 - w_i^C$ より与える。

6.2 検証結果

妥当性の検証のために 6.1 節に示したシミュレーションの設定を用いた交通シミュレーションの出力結果と統計資料を比較する。ここでの出力結果は, 各交通手段の利用割合である。また, 統計資料としては, 交通シミュレーションの対象地域とした富山県射水市の通勤・通学で使用される交通手段の利用者数の資料を使用した。この統計資料では, 本交通シミュレーションで扱っていないタクシーやオートバイ等の交通手段の利用者数が示されているが, これらについては「その他」に含めた。

交通シミュレーションの出力結果と統計資料を比較した結果を Fig.2 に示す。この結果から, 自家用車やバスはほぼ等しい利用割合であることが確認できるが, 徒歩と自転車の利用割合については, 徒歩では約 7%, 自転車では約 11%の相違があることが確認できた。この原因としては, 本シミュレーションモデルではエージェントの自転車の保有率を設定しておらず, 全ての住民が自転車を利用できるモデルとなっていることが原因として考えられる。以上から, 提案したパラメータ推定モデルにより, 現実を模した都市交通シミュレーションを実行可能であり, パラメータ推定モデルの妥当性を確認することができた。

7 おわりに

本稿では, 住民の多様性を考慮可能な疲労度パラメータ及び交通手段選択に対する価値観の分布推定のための最適化モデルを示した。この推定モデルでは, 住民の交通手段の選択に対する価値観は多様であることを考慮したパラメータ推定が可能となる。このモデルを用いてパラメータ推定をするための解法として, 焼きなまし法による解法およびパラメータ推定で使用したアンケート調査の概要を示し, このアンケート調査を基にしたパラメータ推定の結果を示した。また, 推定したパラメータを使用した交通シミュレーションによりパラメータ推定モデルの妥当性の検証を行い, 提案したパラメータ推定モデルの妥当性を確認することができた。

今後, 現在の都市のモデルを地図データを使用したモデルへ拡張することにより, より現実を反映したマルチエージェント・モデルを開発する予定である。

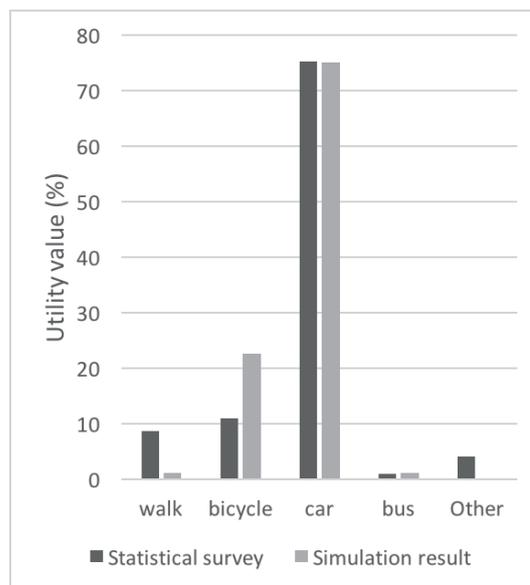


Fig. 2: Comparison of simulation result and statistical survey

参考文献

- 1) 資源エネルギー庁: 平成 19 年度エネルギーに関する年次報告書 (2008)
- 2) M. Jenks, E. Burton and K. Williams: *The Compact City: A Sustainable Urban Form?*, Spon Press (1996)
- 3) 松本卓也, 榊原一紀, 玉置久: 都市交通の数理最適化を用いたマルチエージェントシミュレーションモデル, 電気学会 電子・情報・システム部門誌 Vol.136, No.2, pp.165-172 (2016)
- 4) 坂井篤司, 六川昇, 榊原一紀, 松本卓也, 大原誠, 玉置久: 都市交通システムに対するマルチエージェント型最適化モデルと公共バス・ルート網設計への応用, 第 28 回自律分散システム・シンポジウム予稿集, pp.231-236(2016)
- 5) T. Matsumoto, H. Tamaki and T. Inamoto: Autonomous Decentralized Simulation Model of City and Urban Traffic, *Proc. of SICE Annual Conference 2010*, pp.1021-1026 (2010)
- 6) 国土交通省: 全国都市交通特性調査 (2012)
- 7) 国土交通省国土地理院: 地理情報システム (GIS) <http://www.gsi.go.jp/GIS/>
- 8) R. W. Floyd: Algorithm 97: Shortest Path, *Communications of the ACM*, Vol. 5, No. 4, 345 (1962)
- 9) 玉置久: システム最適化, オーム社 (2005)
- 10) 柳浦睦憲, 茨木俊秀: 組合せ最適化メタ戦略を中心として, 朝倉書店 (2001)
- 11) 総務省: 平成 22 年国勢調査, 従業地・通学地による人口・産業等集計 (人口の男女, 年齢, 就業者の産業 (大分類)) <http://www.e-stat.go.jp/>

バス路線運行安定性のベイズ推定

○南 哲志 橋 完太 (工学院大学)

Bayesian Estimation of Bus Operation Stability

* T. Minami and K. Tachibana (Kogakuin University)

Abstract—Arrival time of bus often delays because of traffic conditions. Recently, many researches have focused on time differences between scheduled and actual arrival time. However, as far as we searched, all researches only calculate operation stability as a deterministic value from differences of arrival time data. Bus services are influenced by time-varying traffic congestion and uncertain. Therefore calculating operation stability as a deterministic value is insufficient by nature. In this research, we build probability distribution of bus operation stability. We also define likelihood function from relationship between bus operation stability and arrival time. Using these probability distribution, we estimate bus operation stability stochastically with Bayesian approach.

Key Words: Bayesian estimation, Bus operation stability, Markov Chain Monte Carlo methods

1. はじめに

路線バスなどの交通機関の到着時刻は、交通状況などの影響を受け予定通りの時刻とならないことが多々ある。そこで近年、予定時刻と到着時刻の差に注目し、停留所、路線および路線網の信頼指標が提案されている¹⁾。また、ICカードのデータを用いてバスサービスの不信頼性とバスの利用需要を算出する研究²⁾や、BRT(Bus Rapid Transit, 高速輸送システム)の信頼性を対象にした研究³⁾が行われている。他には、AVL(Automatic Vehicle Location, バスの位置情報データ)を用いて信頼性を算出する研究が行われている^{4, 5)}。しかしいずれの研究においても、信頼性を確定的な値として算出しており、算出された信頼性がどのような値を取りうるのか、どの区間に収まるのかはあまり捉えられてこなかった。

そこで本稿では、バスの路線の運行安定性を確定的な値ではなく確率分布として導出することを提案する。なぜなら、本来、バスの運行は、信号や渋滞など様々な交通状況の影響を受けるため、安定性を確定的にひとつの値として表現することは不適當だからである。本稿では、バス路線の運行安定性(確率モデル)および、運行安定性と到着時間の関係(尤度関数)を確率分布でモデル化し、確率モデルのパラメータをベイズ推定する。

2. 信頼指標

2.1. 既存手法(PIR)¹⁾

先行研究で示された信頼指標の一つであるPIR(Punctuality Index based on Route)は予定時刻と実際の到着時刻との差が、一定範囲に収まるバスの割合を示し、以下のように定義される。

$$\begin{aligned} PIR_r &= P\{T_{Arr} \in [T_{Sch} + \delta_1, T_{Sch} + \delta_2]\} \\ &= P\{T_{Arr} - T_{Sch} \in [\delta_1, \delta_2]\} \end{aligned} \quad (1)$$

ここで T_{Arr} は路線 r のバスが実際に路線に到着した時刻、 T_{Sch} はそのバスの到着予定時刻を示し、 δ_1, δ_2 ($\delta_1 < 0 < \delta_2$) は許容時間内であるかどうかを

決める閾値である。 $P\{\cdot\}$ は括弧内の条件を満たすバスの本数の割合である。また、PIR は以下のように言い換えることもできる。

$$PIR_r = P\{t_{RUN} \in [t_{Sch} + \delta'_1, t_{Sch} + \delta'_2]\} \quad (2)$$

ここで t_{RUN} は路線の始点から終点への走行時間である。 t_{Sch} はバスの予定走行時間を表す。PIR が高いほどバスが遅れずに安定して運行していることを示す。

2.2. 提案手法(運行安定性)

運行安定性は、既存の指標と同様に、路線バスがどれだけ予定時刻通りに運行されているかの信頼指標として用いる。予定時刻と実際の到着時刻との差が大きければ大きいほど、運行安定性は低い。また、運行安定性 μ は $[a, b]$ の区間で表される。

提案手法では、運行安定性をベイズ推定することを考える。データ集合 X が与えられたときの事後分布 $P(\mu|X)$ は

$$P(\mu|X) = P(X|\mu)P(\mu) \quad (3)$$

で表される。ここで

$$X = \{x_1, x_2, \dots, x_n\} \quad (4)$$

$$x_n = \frac{t_{r,late}}{t_{r,total}} \quad (5)$$

である。また、 $t_{r,late}$ は路線 r での遅れ時間を表し、 $t_{r,total}$ は路線 r での総走行時間を表す。 x_n は、値が大きければ大きいほどバスが遅れていることを表し、運行安定性を下げる。走行時間で除すのは、長い走行時間ほど遅れやすいことを見込んでのことである。

尤度 $P(X|\mu)$ は、バスは基本的に遅れないように努力することから、遅れ時間の確率分布が指数分布的であると仮定して、係数も考慮し

$$P(X|\mu) = \prod_{x_i \in X} \alpha \mu e^{-\alpha \mu x_i} \quad (6)$$

で与える。

事前分布 $P(\mu)$ は、一様分布とする。

$$P(\mu) = \begin{cases} \frac{1}{b-a} & (a < \mu < b) \\ 0 & (\text{otherwise}) \end{cases} \quad (7)$$

運行安定性 μ と尤度の係数 α は、閾値 θ_1, θ_2 によって決まる。具体的には、 $\mu = 1$ のとき、

$$\int_0^{\theta_1} \alpha e^{-\alpha x} dx = \theta_2 \quad (8)$$

となる。これは遅延指標の x が、 θ_1 以下である割合が、 θ_2 であることを意味する。つまり、 θ_1 より遅れていないバスが θ_2 の割合であるときに、運行安定性 μ が 1 となり、安定している、ということを示す。

3. 数値的な例

先行研究¹⁾で用いられた例を参考に設定した、仮想的なバス運行の例を Table 1 と Table 2 に示す。

Table 1: Numerical example of scheduled bus operation

予定時刻	駅1	停留所2	停留所3	停留所4	駅5
バス1	7:00	7:05	7:10	7:15	7:20
バス2	7:06	7:11	7:16	7:21	7:26
バス3	7:12	7:17	7:22	7:27	7:32
バス4	7:18	7:23	7:28	7:33	7:38
バス5	7:24	7:29	7:34	7:39	7:44
バス6	7:30	7:35	7:40	7:45	7:50
バス7	7:36	7:41	7:46	7:51	7:56
バス8	7:42	7:47	7:52	7:57	8:02
バス9	7:48	7:53	7:58	8:03	8:08
バス10	7:54	7:59	8:04	8:09	8:14

Table1 では、7:00~7:59 までに駅 1 を発車し、20 分で駅 5 に到着する予定の、バス 10 本の、到着予定時刻を示している。例えばバス 1 が停留所 3 に到着する時刻は、7:10 である。また、各停留所間の予定走行時間は 5 分としている。簡単のため、乗客の乗降時間などは考慮していない。次に、実際の到着時刻とした例を Table 2 に示す。

Table 2: Numerical example of actual bus operation

発車時刻	駅1	停留所2	停留所3	停留所4	駅5
バス1	7:00	7:07	7:15	7:23	7:30
バス2	7:06	7:13	7:21	7:29	7:39
バス3	7:12	7:17	7:23	7:30	7:39
バス4	7:18	7:24	7:31	7:37	7:40
バス5	7:24	7:28	7:32	7:37	7:42
バス6	7:30	7:36	7:40	7:44	7:52
バス7	7:36	7:40	7:49	7:54	7:57
バス8	7:42	7:49	7:54	8:02	8:05
バス9	7:48	7:54	7:58	8:04	8:09
バス10	7:54	8:00	8:03	8:10	8:16

この例は、到着予定時刻を少し遅らせたものとなっている。なお、先行研究¹⁾で用いられた例では、停留所 4 にて、バス 2 がバス 3 を追い越してしまっており、わが国の道路運送法上不適切であったので、比較に問題のない形で修整した。以上を用いて、既存の手法と提案手法でどのような結果となるかを示す。

3.1 PIR

予定時刻とのズレを 10% まで許容する、とすると、

$$[\delta_1, \delta_2] = (\pm 10\% \times t_{sch}) = [-2, +2] \quad (9)$$

となり、 ± 2 分までのズレを許容することとなる。つまり、走行時間が 18 分から 22 分の間で駅 1 から駅 5 に到着したバスが、運行が安定しているバスとなる。Table 2 より、18~22 分で到着しているバスは、10 本のうち 4,5,6,7,9,10 の 6 本であるので、このルート of PIR を求めると $PIR_r = P\{|t_{Run} - t_{sch}| \leq 2\} = 6/10 = 0.6$ となる。

しかしこの指標や既存の研究には、例えば 17 分や 23 分間走行するなど、1 分ほどの僅かな違いでも信頼度が一気に下がってしまうという致命的な欠点が存在する。

3.2 バス運行安定性

本稿で使用する指標では、そういった致命的な欠点を補うため、信頼指標を確率分布として扱う。

まず、到着と予定時刻のズレを許容する閾値を、従来手法と同じく 10% 程度とすると、 $\theta_1 = 0.1$ となる。 θ_2 も任意に定められるので、例では $\theta_2 = 0.9$ とする。つまり、10% 分以下のズレしかないバスが 90% 存在すれば、運行安定性 $\mu = 1$ 、と定める。

$$\int_0^{0.1} \alpha e^{-\alpha x} dx = 0.9 \quad (10)$$

このとき、 α は(11)式で求められる。

$$\alpha = \frac{\ln(1 - \theta_2)}{\theta_1} \approx 23.0 \quad (11)$$

マルコフ連鎖モンテカルロ法を用いて、シミュレーション的に運行安定性の分布を求めると、サンプル数 10 万で行った結果を Fig. 1 に示す。

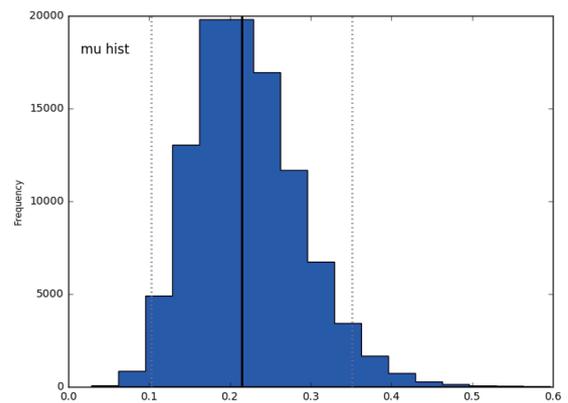


Fig. 1 The result of MCMC ($\theta_1 = 0.1, \theta_2 = 0.9$)

Table 3: The summary of the result of MCMC ($\theta_1 = 0.1, \theta_2 = 0.9$)

Mean	SD	MC Error	95%HPD interval
0.222	0.066	0.001	[0.102 0.351]

Fig.1の縦軸は $P(\mu)$ に対応する頻度であり,横軸は μ である. Fig. 1と Table 3で表した結果を見ると, 運行安定性はおよそ 0.3 ほどであり, あまり安定している運行ではない. これは 20 分の走行時間に対して 13 分も遅れているようなバスがあることから, 納得できるといえる.

また, この手法を用いて, 『100 本のバスが全て遅れていない』と『100 本のバスが全て 20 分遅れている』というデータを与えると, 以下のようになる.

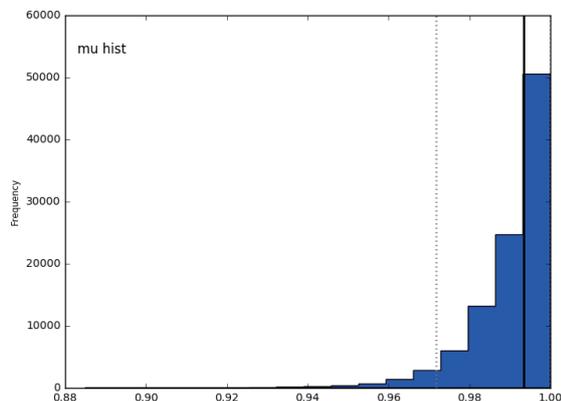


Fig. 2 The result 100 buses are on time

Table 4: The summary of the result 100 buses are on time

Mean	SD	MC Error	95%HPD interval
0.99	0.01	0.0	[0.972 1.0]

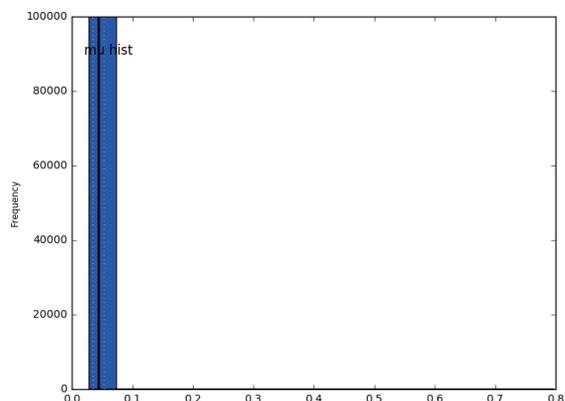


Fig. 3 The result 100 buses are delayed

Table 5: The summary of the result 100 buses are delayed

Mean	SD	MC Error	95%HPD interval
0.044	0.008	0.0	[0.035 0.053]

Fig. 2, 3, Table4, 5の結果を見ると, 従来手法では確定的な値として, 完全に安定している, もしくは全く安定していない, という事しかわからなかったが, 提案手法を用いた場合, しっかりと特徴を反映した分布となっていることがわかる.

さらに, Table1, Table2のバス 10 本が全て遅れずに到着した場合と, 全て 20 分遅れで到着した場合の結果

を以下に示す.

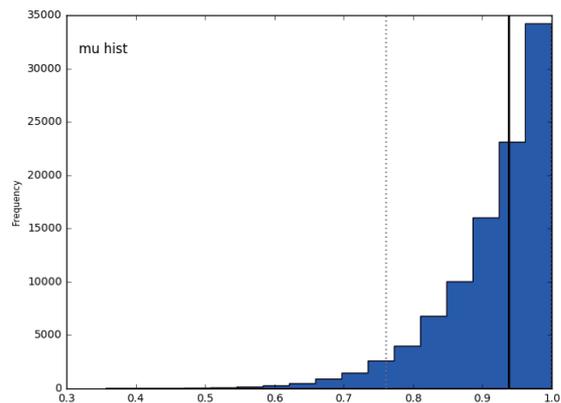


Fig. 4 The result 10 buses are on time

Table 6: The summary of the result 10 buses are on time

Mean	SD	MC Error	95%HPD interval
0.916	0.077	0.001	[0.761 1.0]

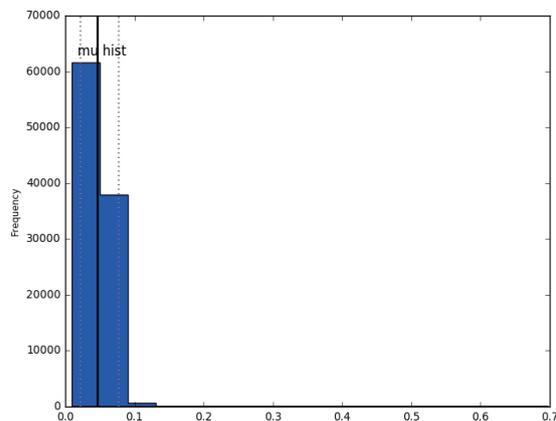


Fig. 5 The result 10 buses are delayed

Table 7: The summary of the result 10 buses are delayed

Mean	SD	MC Error	95%HPD interval
0.048	0.015	0.0	[0.022 0.077]

Table4とTable6, Table5とTable7を比較してみると, 標準偏差は増加し, それに伴い95%信用区間も広がっていることが分かる.

4. 考察

4.1 停留所に着目した場合

3節で扱った数値的な例では, 各バスに着目して運行安定性を導出したが, 本手法は各停留所に着目することもできる. その場合は, バスごとに取得していたデータである式(5)の $t_{r,late}$ を変更し,

$$x_n = \frac{t_{s,late}}{t_{r,total}} \quad (1 < s < N_r) \quad (12)$$

として停留所ごとのデータとすることで、可能となる。 N_r は路線 r での Table8 に X を、Table9 に提案手法の適用結果を示す。

Table 8: X of Numerical Example

X	停留所2	停留所3	停留所4	駅5
バス1	0.1	0.25	0.4	0.5
バス2	0.1	0.25	0.4	0.65
バス3	0	0.05	0.15	0.35
バス4	0.05	0.15	0.2	0.1
バス5	0.05	0.1	0.1	0.1
バス6	0.05	0	0.05	0.1
バス7	0.05	0.15	0.15	0.05
バス8	0.1	0.1	0.25	0.15
バス9	0.05	0	0.05	0.05
バス10	0.05	0.05	0.05	0.1

Table 9: The results of MCMC for each stop

	Mean	SD	MC Error	95% HPD interval
駅1	0.916	0.077	0.001	[0.761 1.0]
停留所2	0.709	0.163	0.001	[0.428 1.0]
停留所3	0.434	0.132	0.001	[0.203 0.705]
停留所4	0.266	0.08	0.001	[0.117 0.422]
駅5	0.222	0.066	0.001	[0.102 0.351]

また、今回は行っていないが、各路線での運行安定性を基に、バスネットワーク全体の運行安定性を導出することも可能であり、事業の健全さの参考となるような指標の導出可能性も見込める。

加えて、全停留所の遅れを路線の運行安定性として組み込むと、Fig. 6 や Table 10 となる。

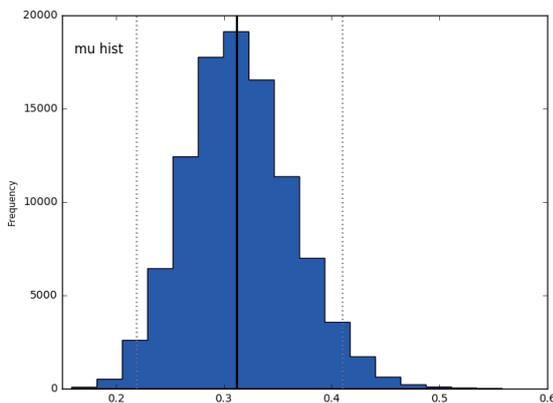


Fig. 6 The result from all stop data

Table 10: The summary of the result from all stop data

Mean	SD	MC Error	95%HPD interval
0.315	0.049	0.0	[0.0219 0.41]

駅5のみを対象とした Fig.1 や Table 3 の結果と比べると、若干だが運行安定性は上がっている傾向にある。どちらを参考とするかは、バス自体に着目するか、路

線自体に着目するかで変えると良いだろう。

4.2 閾値の変更

実際のバス路線には、混雑状況等により元々遅れが見込まれている場合もあると言える。そういった場合も、遅れが見込まれていない場合と同様に運行安定性を導出すると、安定性が低くなってしまふ。そういったときには、閾値 θ_1, θ_2 を変更することで対応する。

例えば、渋滞や信号待ちが起きる可能性が低い路線の場合は $\theta_1 = 0.01, \theta_2 = 0.999$ などとして、走行時間の1%以下のズレで到着するバスが99.9%以上のときに運行安定性 $\mu = 1$ とする。逆に、渋滞や信号待ちがあらかじめ見込まれている場合は $\theta_1 = 0.25, \theta_2 = 0.8$ などとする。実際にこの例の閾値で、3節の数値的な例に習って駅5の遅れデータを使って導出すると、

Table 11: The results after changing thresholds.

	θ_1	θ_2	Mean	SD	MC Error	95% HPD interval
駅5	0.01	0.99	0.008	0.008	0	[0.003 0.012]
駅5	0.25	0.8	0.707	0.163	0.001	[0.426 1.0]

Table 11 のような結果となり、Fig.1 や Table 3 の結果と比べると、閾値を変更することで、意図した通りの傾向で運行安定性が推移していることがわかる。

5. まとめ

本稿では、バス路線の運行安定性という信頼指標に関して、実際のバス運行を想定したモデルを用いてベイズ推定を行った。結果として、先行研究で示されてきた確定的な値とは異なり、確率分布として運行安定性を表すことが可能となった。確率分布として表せることによって、その運行安定性がどの程度で信頼可能かを示せるようになった。またベイズ的なアプローチを用いることで、少ないデータでも大まかな傾向を捉えることが可能となり、加えて前提となる尤度や事前分布を実際のデータや傾向から取り入れられるなど、柔軟性を持った基礎を確立した。

さらに、今回は架空のデータを用いて運行安定性を導出したが、実際のバスの運行データを用いることで、より実用的な手法となることが期待される。その際、曜日、日付、時間帯別など、様々な観点から運行安定性を導出することで、多面的にバス路線の運行を評価することが可能となるだろう。また、今回は予定時刻と到着時刻とのズレを対象としたが、乗車人数や潜在需要の推定にも応用が可能であると考えられる。一方で、尤度に指数分布、事前分布に[0, 1]区間の一様分布を使用したが、その妥当性についての検証を詳細にすることは課題としたい。

参考文献

- 1) Xumei Chen, Lei Yu, Yushi Zhang, Jifu Guo : Analyzing urban bus service reliability at the stop, route, and network levels, Transportation Research Part A 43 pp.722–734(2009)
- 2) Niels van Oort, Ties Brands, Erik de Romph, Jessica Aceves Flores : Unreliability Effects in Public Transport Modelling, International Journal of Trans-

- portation Vol.3, No.1, pp.113-130 (2015)
- 3) Yueying Huo, Jinhua Zhao, Wenquan Li, Xiaojian Hu : Measuring Bus Service Reliability: An Example of Bus Rapid Transit in Changzhou, Journal of Public Transportation, Vol. 17, No. 2, pp.113-133 (2014)
 - 4) Benedetto Barabino, Massimo Di Francesco, Sara Mozzoni : Regularity analysis on bus networks and route directions by automatic vehicle location raw data, IET Intell. Transp. Syst., 2013, Vol. 7, Iss. 4, pp. 473–480 (2013)
 - 5) Benedetto Barabino, Massimo Di Francesco, Sara Mozzoni : An Offline Framework for Reliability Diagnosis by Automatic Vehicle Location Data, IEEE Transactions on Intelligent Transportation Systems, Transactions on Intelligent Transportation Systems Vol. 15, No. 6, pp.2443-2456 (2016)

SMOを用いた利己的経路選択ゲーム問題の均衡解探索の高速化

○樋田一博 吉田皓一 岡本卓 小坏成一 (千葉大学)

An Efficient Improvement of the Equilibrium Solution Search on the Selfish Routing Game by using SMO

*K. Toyoda, K. Yoshida, T. Okamoto, and S. Koakutsu (Chiba University)

Abstract The selfish routing game is a mathematical model to represent the behavior of the selfish players who select a path in a network. In the selfish routing game, the result of the selfish routing are known to converge to a Nash equilibrium solution. The equilibrium solution search problem of the selfish routing game is formulated as an optimization problem with a linear equality constraint condition and a non-negative constraint condition. This study proposes a new solution search method using the sequential minimal optimization (SMO). The SMO is known as an efficiency solution search method to solve the leaning problem of the support vector machine. In the proposed method, the SMO is applied to solve the equilibrium solution search problem. The effectiveness of the proposed method is confirmed through numerical experiments.

Key Words: Selfish routing game, SMO, Normalization constraint condition

1 はじめに

社会、生物システムにおいて、複数プレイヤーが利己的に互いを干渉し合うような集団は多く存在する。そのような集団では、各プレイヤーの目的がその集団全体の目的と衝突することがあり、それによって社会的ジレンマとよばれる問題が生じる。1950年代に、Wardropによって導入された利己的経路選択ゲーム¹⁾は、ネットワークルーティングの社会的ジレンマの数理モデルである。利己的経路選択ゲームでは、各プレイヤーの利己的な経路選択の結果、各経路の選択割合が Nash 均衡解に収束することが知られている²⁾。また、利己的経路選択ゲームの均衡解における全プレイヤーの平均コストは、同条件のネットワークルーティングの最適解における全プレイヤーの平均コストに比べ悪化する可能性が示されている^{3, 4)}。さらに、既存のネットワークに選択可能な経路を追加しても期待に反して交通効率の悪化を招く Braess のパラドクスもよく知られている^{5, 6)}。現実のネットワークにおいても Braess のパラドクスに類似した現象が確認されている^{7, 8, 9, 10)}。このことから、利己的経路選択ゲームのコンピュータシミュレーションはネットワーク設計の最適化や交通整理計画などへの貢献が期待される。

パターン識別器として知られるサポートベクトルマシン (Support Vector Machine: SVM) の学習問題は線形等式制約・上下制限約最適化問題として定式化され、その高速解法として逐次最小問題最適化法 (Sequential Minimal Optimization: SMO) が考案されている¹¹⁾。SMO では、決定変数のうち 2 変数を逐次選択し、選択した変数をそれらに関する最適化問題の解析解に更新していくことで、高速に最適解を得ることができる。利己的経路選択ゲームの均衡解を求める問題は、線形等式制約・下制限約最適化問題として定式化される。し

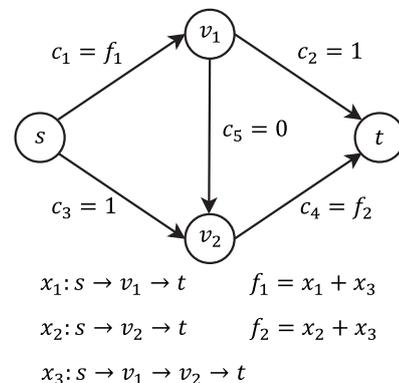


Fig. 1: A simple network of the selfish routing game たがって、利己的経路選択ゲームの均衡解探索に SMO を応用することで、均衡解探索を高速化できることが期待される。

本研究では、SVM の学習問題の高速解法である SMO を利己的経路選択ゲームの均衡解探索に応用した手法を提案し、数値実験を通して、その有効性を確認する。

2 利己的経路選択ゲームとその均衡解

Fig. 1 のようなネットワークを考える。E 本のリンクからなるネットワークにおいて、フローは出発地であるソースノード s から目的地であるシンクノード t へと通過する。ノード s からノード t への経路数を P とし、 x_p , $p = 1, \dots, P$ を p 番目の経路 (以降、経路 p と表す) を通過するフロー量とする。ノード s からノード t へフロー量 X が通過するとしたとき、 x_p は線形等式制約および非負制約条件

$$\sum_{p=1}^P x_p = X \quad (1a)$$

$$x_p \geq 0, p = 1, \dots, P \quad (1b)$$

を満たさなければならない。 \mathcal{P}_e , $e = 1, \dots, E$ を e 番目のリンクを含む経路番号の集合とし、e 番目のリンクを

通過するフロー量を $f_e(\mathbf{x}) = \sum_{p \in \mathcal{P}_e} x_p$ とする。各リンクには、非負のコスト関数 $c_e(f_e(\mathbf{x}))$, $e = 1, \dots, E$ が定義されており、 $f_e(\mathbf{x})$ の増加に対して $c_e(f_e(\mathbf{x}))$ は単調増加である。 \mathcal{E}_p , $p = 1, \dots, P$ を経路 p に含まれるリンク番号の集合とすると、経路 p における移動コスト $\tilde{c}_p(\mathbf{x})$ は

$$\tilde{c}_p(\mathbf{x}) = \sum_{e \in \mathcal{E}_p} c_e(f_e(\mathbf{x})), \quad p = 1, \dots, P \quad (2)$$

で与えられる。また、ネットワーク内のフロー全体の平均コスト $C(\mathbf{x})$ は

$$C(\mathbf{x}) = \frac{1}{X} \sum_{p=1}^P x_p \tilde{c}_p(\mathbf{x}) \quad (3)$$

で与えられる。利己的経路選択ゲームでは、全プレイヤーが制約条件 (1) の範囲内で各自の移動コストが最小となるような経路を利己的に選択し、各プレイヤーが自身の経路を変更しても、移動コストが小さくならない状態で均衡する。すなわち、利己的経路選択ゲームの均衡解 \mathbf{x}^* では、制約条件 (1) が満たされ、かつ $x_p^* > 0$ を満たす p について、

$$\forall q \in \{1, \dots, P\} \quad \tilde{c}_p(\mathbf{x}^*) \leq \tilde{c}_q(\mathbf{x}^*) \quad (4)$$

が成り立つ。さらに、制約条件 (1) と式 (4) から利己的経路選択ゲームの均衡解では

$$\begin{cases} \tilde{c}_p(\mathbf{x}^*) = C(\mathbf{x}^*) & (x_p^* > 0) \\ \tilde{c}_p(\mathbf{x}^*) \geq C(\mathbf{x}^*) & (x_p^* = 0) \end{cases} \quad (5)$$

が成り立つことを導出できる。

利己的経路選択ゲームの均衡解を得るための最適化問題は、ポテンシャル関数最小化問題

$$\text{minimize}_{\mathbf{x}} \Phi(\mathbf{x}) \quad (6a)$$

$$\text{subject to } \sum_{p=1}^P x_p = X \quad (6b)$$

$$x_p \geq 0, \quad p = 1, \dots, P \quad (6c)$$

$$\text{where } \Phi(\mathbf{x}) = \sum_{e=1}^E \int_0^{f_e(\mathbf{x})} c_e(y) dy \quad (6d)$$

として定式化される。これは線形等式制約・下限制約最適化問題である。

3 逐次最小問題最適化法

SMO は、SVM の学習法の 1 つとして考案された手法であるが、ここでは、線形等式制約・上下限制約最適化問題の解法として説明する。

凸 2 次計画問題

$$\text{minimize}_{\mathbf{x}} \frac{1}{2} \mathbf{x}^\top H \mathbf{x} + \mathbf{g}^\top \mathbf{x} \quad (7a)$$

$$\text{subject to } \mathbf{w}^\top \mathbf{x} = z \quad (7b)$$

$$0 \leq x_n \leq K, \quad n = 1, \dots, N \quad (7c)$$

を考える。ここで、 $\mathbf{x} \in \mathbb{R}^N$ は決定変数、 $H \in \mathbb{R}^{N \times N}$ は半正定値行列、 $\mathbf{g} \in \mathbb{R}^N$ は定数ベクトル、 $z \in \mathbb{R}$ は定

数である。最適化問題 (7) において、制約条件 (7b) を満たす $\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_N)^\top$ が与えられた下で、任意の 2 変数 x_i, x_j のみを更新するための最適化問題

$$\text{minimize}_{x_i, x_j} \frac{1}{2} \tilde{\mathbf{x}}^\top H \tilde{\mathbf{x}} + g_i x_i + g_j x_j \quad (8a)$$

$$\text{subject to } w_i x_i + w_j x_j = w_i \bar{x}_i + w_j \bar{x}_j \quad (8b)$$

$$0 \leq x_i, x_j \leq K \quad (8c)$$

$$\text{where } \tilde{\mathbf{x}} = [\bar{x}_1, \dots, x_i, \dots, x_j, \dots, \bar{x}_N]^\top \quad (8d)$$

$$h_{mn} = \begin{cases} h_{mn} & (m = i \text{ or } j, n = i \text{ or } j) \\ 0 & (\text{otherwise}) \end{cases} \quad (8e)$$

を考える。ここで、 h_{mn} は最適化問題 (7) の行列 H の m 行 n 列成分である。等式制約 (8b) から

$$\begin{aligned} x_i &= \frac{w_i \bar{x}_i + w_j \bar{x}_j - w_j x_j}{w_i} \\ &= \bar{x}_i + \frac{w_j}{w_i} (\bar{x}_j - x_j) \end{aligned} \quad (9)$$

であるので、これを最適化問題 (8) に代入すると、1 変数最適化問題

$$\begin{aligned} \text{minimize}_{x_j} & \frac{1}{2} \left(\left(\frac{w_j}{w_i} \right)^2 h_{ii} + h_{jj} - 2 \frac{w_j}{w_i} h_{ij} \right) x_j^2 \\ & + \left\{ \frac{\partial f(\mathbf{x})}{\partial x_j} \Big|_{\mathbf{x}=\bar{\mathbf{x}}} - \frac{w_j}{w_i} \frac{\partial f(\mathbf{x})}{\partial x_i} \Big|_{\mathbf{x}=\bar{\mathbf{x}}} \right. \\ & \left. - \left(\left(\frac{w_j}{w_i} \right)^2 h_{ii} + h_{jj} - 2 \frac{w_j}{w_i} h_{ij} \right) \bar{x}_j \right\} x_j \\ & + \text{Const.} \end{aligned} \quad (10a)$$

$$\text{subject to } 0 \leq x_j, \bar{x}_i + \frac{w_j}{w_i} (\bar{x}_j - x_j) \leq K \quad (10b)$$

とみなせる。ここで、 $\partial f(\mathbf{x}) / \partial x_n$ は、目的関数 (7a) の勾配

$$\frac{\partial f(\mathbf{x})}{\partial x_n} = g_n + \sum_{m=1}^N h_{mn} x_m \quad (11)$$

である。任意の i, j に対して $(w_j/w_i)^2 h_{ii} + h_{jj} - 2(w_j/w_i) h_{ij} \geq 0$ が成り立つので、最適化問題 (10) の目的関数 (10a) は x_j に関して極小値をもつ。したがって、目的関数 (10a) を x_j で偏微分して 0 になる条件から、最適化問題 (8) の上下限制約を無視した解

$$x'_j = \bar{x}_j + \frac{(w_j/w_i) \frac{\partial f(\mathbf{x})}{\partial x_i} \Big|_{\mathbf{x}=\bar{\mathbf{x}}} - \frac{\partial f(\mathbf{x})}{\partial x_j} \Big|_{\mathbf{x}=\bar{\mathbf{x}}}}{(w_j/w_i)^2 h_{ii} + h_{jj} - 2(w_j/w_i) h_{ij}} \quad (12a)$$

$$x'_i = \bar{x}_i + \frac{w_j}{w_i} (\bar{x}_j - x'_j) \quad (12b)$$

が得られる。つぎに、上下限制約 (8c) を満たす解 x_j^* を考える。 x'_j に対する上限値 x^U と下限値 x^L を用いて x_j^* を、

$$x_j^* = \begin{cases} x^L & (x'_j \leq x^L) \\ x'_j & (x^L < x'_j < x^U) \\ x^U & (x^U \leq x'_j) \end{cases} \quad (13)$$

と表すと、 x^L と x^U は、上下限制約 (10b) から、

• w_i, w_j が同符号の場合

$$x^L = \max \left\{ 0, \bar{x}_j + \frac{w_i}{w_j} (\bar{x}_i - K) \right\} \quad (14a)$$

$$x^U = \min \left\{ K, \bar{x}_j + \frac{w_i}{w_j} \bar{x}_i \right\} \quad (14b)$$

• w_i, w_j が異符号の場合

$$x^L = \max \left\{ 0, \bar{x}_j + \frac{w_i}{w_j} \bar{x}_i \right\} \quad (15a)$$

$$x^U = \min \left\{ K, \bar{x}_j + \frac{w_i}{w_j} (\bar{x}_i - K) \right\} \quad (15b)$$

のように定まる。

SMO では、一度の解更新で 2 変数の更新しか行わず、勾配更新の計算量は $O(N)$ となる。また、SMO アルゴリズムでは、更新する 2 変数をランダムに選択しても最適解に収束することが知られている¹¹⁾ が、問題に応じて適切に変数を選択することで速く収束することが期待される。

4 提案手法

利己的経路選択ゲームの均衡解を得るための最適化問題 (6) の解法として SMO を用いた手法を提案する。

4.1 解更新式

最適化問題 (6) において、制約条件式 (6b), (6c) を満たす $\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_N)^\top$ が与えられた下で、任意の 2 変数 x_i, x_j のみを更新するための最適化問題

$$\underset{x_i, x_j}{\text{minimize}} \quad \sum_{e \in \mathcal{E}_{i,j}} \int_0^{f_e(\bar{\mathbf{x}})} c_e(y) dy \quad (16a)$$

$$\text{subject to } x_i + x_j = \bar{x}_i + \bar{x}_j \quad (16b)$$

$$x_i, x_j \geq 0 \quad (16c)$$

$$\text{where } \bar{\mathbf{x}} = (\bar{x}_1, \dots, x_i, \dots, x_j, \dots, \bar{x}_P)^\top \quad (16d)$$

$$c_e(y) = a_e + b_e y, \quad e = 1, \dots, E \quad (16e)$$

を考える。ここで、 $\mathcal{E}_{i,j}$ は経路 i, j に含まれるリンク番号集合である。各リンクの非負コスト関数は、式 (16e) に示す線形コスト関数を仮定する。

線形等式制約 (16b) から

$$x_i = \bar{x}_i + \bar{x}_j - x_j \quad (17)$$

であるので、これを最適化問題 (16) に代入すると、1 変数最適化問題

$$\underset{x_j}{\text{minimize}} \quad g(\bar{\mathbf{x}}) \quad (18a)$$

$$\text{subject to } x_j, \bar{x}_i + \bar{x}_j - x_j \geq 0 \quad (18b)$$

$$\text{where } g(\bar{\mathbf{x}}) = \sum_{e \in \mathcal{E}_{i,j}} a_e f_e(\bar{\mathbf{x}}) + \frac{1}{2} b_e f_e(\bar{\mathbf{x}})^2 \quad (18c)$$

が得られる。ここで、 $f_e(\bar{\mathbf{x}}) \geq 0$, $e = 1, \dots, E$ であるので、最適化問題 (18) の目的関数 $g(\bar{\mathbf{x}})$ は x_j に関する凸 2 次関数で、 x_j に関して極小値をもつ。したがって、目的関数 $g(\bar{\mathbf{x}})$ を x_j で偏微分して 0 になる条件から、最適化問題 (16) の下限制約 (16c) を無視した解が得ら

れる。 $\mathcal{E}_{i,j}$ のうち経路 i のみに含まれているリンク番号集合を $\mathcal{E}_{i,j}^i$ 、経路 j のみに含まれているリンク番号集合を $\mathcal{E}_{i,j}^j$ とする。このとき、 $f_e(\bar{\mathbf{x}})$, $e \in \mathcal{E}_{i,j}$ を

$$f_e(\bar{\mathbf{x}}) = \begin{cases} \sum_{p \in \{\mathcal{P}_e \setminus \{i\}\}} \bar{x}_p + \bar{x}_i + \bar{x}_j - x_j & (e \in \mathcal{E}_{i,j}^i) \\ \sum_{p \in \{\mathcal{P}_e \setminus \{j\}\}} \bar{x}_p + x_j & (e \in \mathcal{E}_{i,j}^j) \\ \sum_{p \in \{\mathcal{P}_e \setminus \{i,j\}\}} \bar{x}_p + \bar{x}_i + \bar{x}_j & (\text{otherwise}) \end{cases} \quad (19)$$

と表すことができ、 $\bar{\mathbf{x}}$ が定数であることに注意すると、 $\partial g(\bar{\mathbf{x}})/\partial x_j$ は

$$\frac{\partial g(\bar{\mathbf{x}})}{\partial x_j} = - \sum_{e \in \mathcal{E}_{i,j}^i} a_e + b_e (\tilde{f}_e^i(\bar{\mathbf{x}}) - x_j) + \sum_{e \in \mathcal{E}_{i,j}^j} a_e + b_e (\tilde{f}_e^j(\bar{\mathbf{x}}) + x_j) \quad (20a)$$

$$\tilde{f}_e^i(\bar{\mathbf{x}}) = \sum_{p \in \{\mathcal{P}_e \setminus \{i\}\}} \bar{x}_p + \bar{x}_i + \bar{x}_j \quad (20b)$$

$$\tilde{f}_e^j(\bar{\mathbf{x}}) = \sum_{p \in \{\mathcal{P}_e \setminus \{j\}\}} \bar{x}_p \quad (20c)$$

で与えられる。したがって、最適化問題 (16) の下限制約 (16c) を無視した解

$$x_j' = \frac{\sum_{e \in \mathcal{E}_{i,j}^i} (a_e + b_e \tilde{f}_e^i(\bar{\mathbf{x}})) - \sum_{e \in \mathcal{E}_{i,j}^j} (a_e + b_e \tilde{f}_e^j(\bar{\mathbf{x}}))}{\sum_{e \in \mathcal{E}_{i,j}^i} b_e + \sum_{e \in \mathcal{E}_{i,j}^j} b_e} \quad (21a)$$

$$x_i' = \bar{x}_i + \bar{x}_j - x_j' \quad (21b)$$

が得られる。つぎに、上下限制約 (16c) を満たす解 x_j^* を考える。 x_j^* に対する上限値 x^U と下限値 x^L を用いて x_j^* を、

$$x_j^* = \begin{cases} x^L & (x_j \leq x^L) \\ x_j' & (x^L < x_j' < x^U) \\ x^U & (x^U \leq x_j) \end{cases} \quad (22)$$

と表すと、 x^L と x^U は、上下限制約 (18b) から、

$$x^L = 0 \quad (23a)$$

$$x^U = \bar{x}_i + \bar{x}_j \quad (23b)$$

と定まる。

4.2 2 変数の選択

提案手法の解法で逐次選択する 2 変数の選択方法について説明する。

第 1 変数は均衡条件式 (5) を違反する変数を選択する。高速に発見するため、 $x_p > 0$ である変数から先に評価する。具体的には、 $x_p > 0$ かつ $|\tilde{c}_p(\mathbf{x}) - C(\mathbf{x})| > \epsilon$ を満たす変数 x_p を選択する。 $x_p > 0$ である変数から選択できない場合、 $x_p = 0$ かつ $\tilde{c}_p(\mathbf{x}) < C(\mathbf{x})$ を満たす変数 x_p を選択する。いずれの方法でも変数が選択できない場合は、均衡解が得られていると判定し、探索を終了する。

第2変数は $x_p > 0$ である変数からランダムに選択する。選択された2変数について更新を行い、第1変数の更新量が小さい場合には更新を行わず、第2変数を選択しなおす。 $x_p > 0$ である変数で更新が行われない場合には、残りの変数からランダムに選択し更新を行う。すべての第2変数候補について更新が行われない場合は、第1変数を再選択する。すべての第1変数候補について、更新が行われない場合は、均衡解が得られていると判定し、探索を終了する。

5 数値実験

同条件の利己的経路選択ゲームに対し、均衡解が得られるまでの計算時間を比較し、提案手法の有効性を検証する。比較手法として、代表的な均衡解探索法であるレプリケータ力学系を用いる。

ノード s を入力層、ノード t を出力層とし、所望の経路数が得られるように隠れ層を決定する階層型ネットワークを用いて実験を行う。たとえば、所望の経路数が10の場合、隠れ層を2層として、各層のノード数を5, 2とし、隣接する層のすべてのノード間をリンクで結合したネットワークを用いる。

ネットワーク内のリンク数を E とし、次式にしたがって、各リンクのコスト関数をランダムに設定する。

$$c_e(\mathbf{x}) = a_e + b_e f_e(\mathbf{x}) \quad (24a)$$

$$0.5 \leq a_e, b_e \leq 1.0, e = 1, \dots, E \quad (24b)$$

ノード s からノード t へ通過するフロー量を $X = 1$ とし、全経路で均一なフロー量が通過する状態を均衡解探索の初期条件とする。レプリケータ力学系による均衡解探索法（以降、比較手法とよぶ）では、全経路において更新量の絶対値が許容誤差 $\epsilon = 10^{-9}$ 以下になれば収束とみなし、探索を終了する。また、SMOによる均衡解探索法（以降、提案手法とよぶ）では、全経路が均衡条件式(5)を許容誤差 $\epsilon = 10^{-9}$ 以下で満たした場合に収束とみなし、探索を終了する。各経路数に対し100回ずつ実験を行い、収束するまでのステップ数と計算時間の平均値を比較する。

実験結果として、平均更新ステップ数を Fig. 2 に、平均計算時間を Fig. 3 に示す。なお、提案手法と比較手法で得られた均衡解 \mathbf{x}^* の平均コスト $C(\mathbf{x}^*)$ は、 10^{-4} のオーダーで一致することを確認している。Fig. 2 から、経路数の増加に応じて収束するまでの更新ステップ数が増加しているが、比較手法より速く収束していることがわかる。Fig. 3 から、経路数の増加に対する計算時間は、比較手法と同様な増加傾向がみられるが、提案手法によりその計算時間を大幅に削減し、比較手法に対して平均12.3倍の高速化を達成していることがわかる。

以上の結果から、提案手法による均衡解探索の高速化の有効性が確認できる。

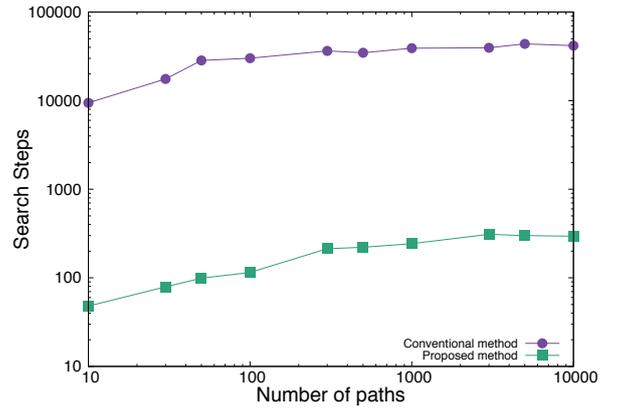


Fig. 2: Average of search steps

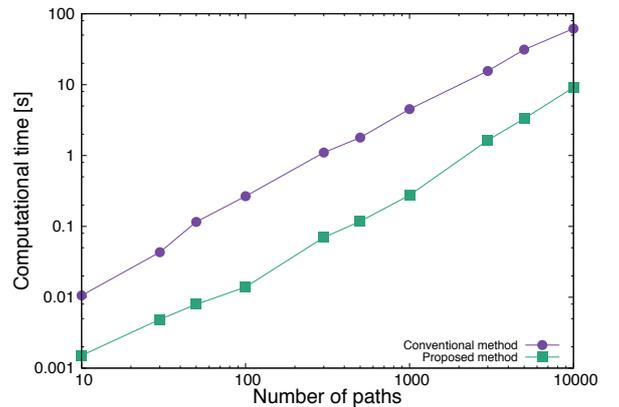


Fig. 3: Average of computational time

6 おわりに

本研究では、利己的経路選択ゲームの均衡解を求める問題と SVM の学習問題が類似した制約条件をもつ最適化問題として定式化されることから、SVM の高速解法である SMO を利己的経路選択ゲームの均衡解探索に応用し、均衡解探索の高速化を図る手法を提案した。数値実験から、利己的経路選択ゲームの均衡解探索に SMO を応用することが可能であり、ネットワークの規模にかかわらず、均衡解探索の高速化を確認し、その有効性を確認した。今後の課題として、より均衡解探索を高速化するような2変数の選択方法の提案などがあげられる。

謝辞

本研究は JSPS 科研費 16K00324 の助成を受けたものである。

参考文献

- 1) J. G. Wardrop: Some theoretical aspects of road traffic research, Proc. of Institute of Civil Engineers, Pt.II, 325/378 (1952)
- 2) N. Nisan, T. Roughgarden, É. Tardos, and V.

- V. Vazirani Eds: Algorithmic game theory, Cambridge University Press (2007)
- 3) T. Roughgarden and É. Tardó: How bad is selfish routing?, *J. ACM*, **49-2**, 236/259 (2002)
 - 4) T. Roughgarden: Selfish routing and the price of anarchy, MIT Press (2005)
 - 5) D. Braess: Über ein paradoxon aus der verkehrsplanung, *Unternehmensforschung*, **12**, 258/268 (1968)
 - 6) D. Braess, A. Nagurney, and T. Wakolbinger: On a paradox of traffic planning, *Transportation Science*, **39**, 446/450 (2005)
 - 7) J. E. Cohen and P. Horowitz: Paradoxical behaviour of mechanical and electrical networks, *Nature*, **352-6337**, 699/701 (1991)
 - 8) M. G. Pala, S. Baltazar, P. Liu, H. Sellier, B. Hackens, F. Martins, V. Bayot, X. Wallart, L. Desplanque, and S. Huant: Transport inefficiency in branched-out mesoscopic networks: An analog of the Braess paradox, *Phys. Rev. Lett.*, **108-076802** (2012)
 - 9) N. G. Bean, F. P. Kelly, and P. G. Taylor: Braess's paradox in a loss network, *J. Appl. Probab.*, **34-1**, 155/159 (1997)
 - 10) J. E. Cohen and C. Jeffries: Congestion resulting from increased capacity in single-server queueing networks, *IEEE/ACM Trans. Netw.*, **5-2**, 305/310 (1997)
 - 11) 竹内, 鳥山 : サポートベクトルマシン (機械学習プロフェッショナルシリーズ) , 講談社 (2015)

差分進化における個体のグループ化と グループ別パラメータ制御の効果

○高濱徹行（広島市立大学） 阪井節子（広島修道大学）

Effect of Parameter Control According to Groups Composed of Individuals for Differential Evolution

*T. Takahama (Hiroshima City University) and S. Sakai (Hiroshima Shudo University)

Abstract— Differential Evolution (DE) has been successfully applied to various optimization problems. The performance of DE is affected by algorithm parameters such as a scaling factor and a crossover rate. Many studies have been done to control the parameters adaptively. One of the most successful studies on controlling the parameters is JADE. In JADE, the values of each parameter are generated according to one probability density function (PDF) which is learned by the values in success cases where the child is better than the parent. It is expected that search performance is improved by learning multiple PDFs for each parameter based on some characteristics of individuals. In this study, search points are divided into plural groups according to a criterion such as clustering-based grouping or rank-based grouping. PDFs are learned by parameter values in success cases for each group. The effect of JADE with multiple PDFs is shown by solving various benchmark problems.

Key Words: differential evolution, group-based learning, adaptive parameter control

1 はじめに

差分進化 (Differential Evolution, DE) は 1995 年に Storn と Price [1, 2] によって提案された実数空間における最適化アルゴリズムであり, 進化的アルゴリズム (Evolutionary Algorithm, EA) の一つである. DE は非線形問題, 微分不可能な問題, 非凸問題, 多峰性問題など様々な最適化問題に適用されてきており, これらの問題に対して高速で頑健なアルゴリズムであることが示されてきている [3]. また, DE は進化的計算に関する国際会議のコンペティションにおいて優秀な成績を収めている [4–6].

DE の利用が増加してきている主な理由としては, 単純な算術演算に基づいているため高速に動作すること, アルゴリズム・パラメータがスケールングファクター F , 交叉率 CR , 集団サイズ N の 3 つと単純であることが挙げられる. しかし, パラメータ設定によって DE の性能は大きく変化し, 問題によって適切なパラメータ設定が異なるため, パラメータ設定は非常に重要な検討課題となっている. アルゴリズムパラメータを調整する主な方法は, 下記のように大別できる.

(1) 観測による調整 (observation-based tuning): 探索状況を観測し, 観測量に応じて適切なパラメータ値を推論し, パラメータを動的に調整する. ファジィ推論を用いる FADE (Fuzzy Adaptive DE) [7], ファジィクラスタリングを用いる DESFC (DE with Speciation and Fuzzy Clustering) [8], 単峰性・多峰性を検出する LMDE (DE with detecting Landscape Modality) [9, 10], ランク情報に基づきパラメータ値を選択する RDE (Rank-based DE) [11, 12] が提案されている. FADE では世代間における探索点の移動量と関数値の変化量を, DESFC では探索点の分割エントロピー (partition entropy) を, LMDE では直線上に生成したサンプリング点における関数値の変化を, RDE では探索点の関数値に対するランク情報を観測量として用いている.

(2) 成功による調整 (success-based tuning): 良い探索点を生成した場合を成功と捉え, 成功したときのパラメータ値が使用されやすいようにパラメータを動的に調整する. なお, 個体の遺伝情報に制御パラメータを含む自己適応 (self-adaptation) も成功による調整の一種であると考えられる. 自己適応により F, CR, N を調整する DE-SAP (Differential Evolution with Self-Adapting Populations) [13], 自己適応により F, CR を調整し成功率により変異戦略の選択確率を調整する SaDE (Self-adaptive DE) [14], 成功に応じて F, CR の平均値を調整する JADE (adaptive DE with optional external archive) [15], JADE の改良である MDE- p BX (modified DE with p -best crossover) [16], SHADE (Success-History based Adaptive DE) [17], CADE (Correlation-based Adaptive DE) [18] などが提案されている.

(3) (1) と (2) を組み合わせた調整: 関数の山谷構造を観察して JADE のパラメータ調整を修正する JADE-HV [19], さらに JADE のアーカイブを使用する確率も調整する JADEaa-HV [20] などが提案されている.

しかし, (1) は問題や問題のスケールに依存しない観測量を設定するのが困難であるという課題がある. (2) では, 探索点の近傍で良い探索点を発見した場合, 集団が収束する方向にパラメータが調整される. このため, 良い探索点が存在する範囲の狭い稜構造問題や多峰性の問題において, 小さな成功 (small success) の方向にパラメータが調整され, 大きな成功 (big success) を見逃し, 局所解に収束してしまうことがある. この問題を軽減するために提案されているのが (3) の方法である.

本研究では, 局所解への収束を避けるための工夫がなされている (2) に属する JADE を対象とし, JADE

を改良する方法を提案する。JADE では、成功時のパラメータ値を用いて、パラメータを生成するための確率分布における平均値（中央値）を学習する。このとき、一種類のパラメータに対して一つの確率分布を用いている。しかし、観測された探索点の性質によって異なるパラメータ分布を学習することにより探索性能を向上できる可能性がある。この方法は (3) に含まれると考えられる。

本研究では、この可能性を検証するために、個体群を複数のグループに分割し、グループ毎にパラメータ分布を学習する方法を提案する。グループ化の方法は、関数値のランクによってグループ化する方法、k-means法により近い個体によってグループ化する方法について検討する。幾つかのベンチマーク問題を最適化し、性能を比較することにより、本手法の有効性を示す。

以下、2. で DE について、3. で JADE について簡潔に説明する。4. で、本手法のアルゴリズムを説明する。5. で他の方法と比較した性能を示す。6. はまとめである。

2 差分進化 (Differential Evolution)

DE のアイデアとアルゴリズムについて説明する。

2.1 概要

Differential evolution (DE) は Storn and Price [1,2] によって提案された進化的アルゴリズムである。DE は確率的な直接探索法であり、解集団を用いた多点探索を行う。

DE には幾つかの形式が提案されており、DE/best/1/bin や DE/rand/1/exp などがよく知られている。これらは、DE/base/num/cross という記法で表現される。“base” は基本ベクトルとなる親の選択方法を指定する。例えば、DE/rand/num/cross は基本ベクトルのための親を集団からランダムに選択し、DE/best/num/cross は集団の最良個体を選択する。“num” は基本ベクトルを変異させるための差分ベクトルの個数を指定する。“cross” は子を生成するために使用する交叉方法を指定する。例えば、DE/base/num/bin は一定の確率で遺伝子を交換する交叉 (binomial crossover) を用い、DE/base/num/exp は、指数関数的に減少する確率で遺伝子を交換する交叉 (exponential crossover) を用いる。

2.2 アルゴリズム

DE/rand/1/bin のアルゴリズムは以下のように記述できる [5, 21].

Step0 初期化. N 個の初期個体 \mathbf{x}_i を探索空間 S 内に生成し、初期集団 $\{\mathbf{x}_i \mid i = 1, 2, \dots, N\}$ を構成する。

Step1 終了判定. 終了条件を満足すれば、アルゴリズムは終了する。終了条件としては、最大の繰返し回数や関数評価回数を用いることが多い。

Step2 突然変異. 各個体 (target vector) \mathbf{x}_i に対して、3 個体 $\mathbf{x}_{r_1}, \mathbf{x}_{r_2}, \mathbf{x}_{r_3}$ を \mathbf{x}_i および互いに重複しないようにランダムに選択する。基本ベクトル \mathbf{x}_{r_1} および差分ベクトル $\mathbf{x}_{r_2} - \mathbf{x}_{r_3}$ から変異ベクトル (mutant vector) \mathbf{m}_i を以下のように生成する。

$$\mathbf{m}_i = \mathbf{x}_{r_1} + F(\mathbf{x}_{r_2} - \mathbf{x}_{r_3}) \quad (1)$$

ここで、 F はスケールリングパラメータである。

Step3 交叉. 変異ベクトル \mathbf{m}_i と親 \mathbf{x}_i を交叉し、子ベクトル (trial vector) $\mathbf{x}_i^{\text{child}}$ を生成する。交差点 j を全ての次元 $[1, n]$ からランダムに選択する。子ベクトル $\mathbf{x}_i^{\text{child}}$ の j 番目の要素を \mathbf{m}_i の j 番目の要素から継承する。それ以外の次元は、交叉パラメータ CR の確率で、 \mathbf{m}_i の要素から継承する。残りの部分は、親 \mathbf{x}_i から継承する。実際の処理では、Step2 と Step3 は一まとまりの処理で実現される。

Step4 生存者選択. 子ベクトルを評価する。子ベクトル $\mathbf{x}_i^{\text{child}}$ が親ベクトルよりも良ければ子ベクトルが生存者となり、親を子ベクトルで置換する。

Step5 Step1 に戻る。

3 JADE

JADE では、スケールリングファクターの平均値 μ_F と交叉率の平均値 μ_{CR} によって良好なパラメータ値の確率分布を表現し、成功した時のパラメータ値を用いて適応的に平均値を更新する。初期値は、 $\mu_F = \mu_{CR} = 0.5$ である。各個体 \mathbf{x}_i のために、異なるスケールリングファクター F_i と交叉率 CR_i が次式に従って独立に生成される。

$$F_i \sim C(\mu_F, \sigma_F) \quad (2)$$

$$CR_i \sim N(\mu_{CR}, \sigma_{CR}^2) \quad (3)$$

ここで、 $C(\mu_F, \sigma_F)$ は位置パラメータ μ_F 、尺度パラメータ $\sigma_F = 0.1$ の Cauchy 分布に基づく確率分布である。 $N(\mu_{CR}, \sigma_{CR}^2)$ は平均 μ_{CR} 、標準偏差 $\sigma_{CR} = 0.1$ の正規分布に基づく確率分布である。 CR_i は区間 $[0, 1]$ となるように切り捨てられる。 F_i は負の値あるいは 0 の場合は再生成され、それ以外の場合は 1 以下となるように切り捨てられる。位置パラメータ μ_F と平均 μ_{CR} は、安定した学習を実現するために、指数移動平均を用いて更新される。

$$\mu_F = (1 - c)\mu_F + cS_{F^2}/S_F \quad (4)$$

$$\mu_{CR} = (1 - c)\mu_{CR} + cS_{CR}/S_N \quad (5)$$

ここで、 S_N は親より良い子が生成された成功した回数、 S_F, S_{F^2}, S_{CR} はそれぞれ親よりよい子が生成された成功時の F_i, F_i^2, CR_i の和である。すなわち、 μ_{CR} は成功時の単純な算術平均により更新される。これに対して、 μ_F は多様性を保持するために、大きな値を重視した重み付き平均によって更新される。定数 c は値を更新する際に使用される区間 $(0, 1]$ の重みであり、推奨値は 0.1 である。

JADE では “current-to-pbest” と呼ばれる突然変異戦略が提案され、親と上位個体の中間点が基本ベクトルとなる。変異ベクトルは次式で生成される。

$$\mathbf{m}_i = \mathbf{x}_i + F_i(\mathbf{x}^{pbest} - \mathbf{x}_i) + F_i(\mathbf{x}_{r_2} - \mathbf{x}_{r_3}) \quad (6)$$

ここで、 \mathbf{x}^{pbest} は上位 $100p\%$ 個体からランダムに選択された個体であり、 p の推奨値は 0.05 である。

JADE ではアーカイブを使用する方法も提案されているが、本研究ではアーカイブを使用しないため、説明は省略する。

4 提案手法

4.1 グループ化

本研究では、種類の異なる2つの方法でグループ化を実現する。以下では、個体集団を $\{\mathbf{x}_i \mid i = 1, 2, \dots, N\}$, グループ数を K とする。

k-means を用いたクラスタリングによるグループ化

個体のまとまり別にパラメータを制御するため、個体集団をクラスタリングし、距離の近いグループに分ける。クラスタ数を K とし、k-means 法によるクラスタリングを利用してグループ化を実現する。

- (0) 初期化. 最初に第1世代のみランダムにクラスタを割り当てる。このために、各点 \mathbf{x}_i について、所属するクラスタ $C_k, k = 1, \dots, K$ をランダムに選択する。 k はクラスタ番号である。第2世代からは、グループ化の継続性を保つために、前の世代のクラスタ割り当てを初期値として使用する。

- (1) 更新ステップ. クラスタの重心 $\boldsymbol{\mu}_k$ を新しいクラスタ中心とする。

$$\boldsymbol{\mu}_k = \frac{1}{|C_k|} \sum_{\mathbf{x}_i \in C_k} \mathbf{x}_i \quad (7)$$

- (2) 割当ステップ. 各点を最も近いクラスタに割り当てる。

$$C_k = \{\mathbf{x}_i \mid \arg \min_{1 \leq h \leq K} \|\mathbf{x}_i - \boldsymbol{\mu}_h\| = \boldsymbol{\mu}_k\} \quad (8)$$

- (3) 割当に変化がなくなるまで、(1)へ戻る。

個体 \mathbf{x}_i のグループ番号 $group(\mathbf{x}_i)$ は、その個体が属するクラスタ番号となる。

関数値のランクによるグループ化

関数値の良い順に各個体にランク $r_i, (r_i = 1, 2, \dots, N)$ を付与する。ここで、最良の個体のランクは1である。個体 \mathbf{x}_i のグループ番号 $group(\mathbf{x}_i)$ は、以下のようになる。

$$group(\mathbf{x}_i) = \left\lceil \frac{r_i}{N} K \right\rceil \quad (9)$$

4.2 グループ別パラメータ制御

JADE のパラメータ制御をグループ別に行うために、各グループ $k = 1, \dots, K$ に対して以下の式を用いる。

$$F_i \sim C(\mu_F^k, \sigma_F) \quad (10)$$

$$CR_i \sim N(\mu_{CR}^k, \sigma_{CR}^2) \quad (11)$$

$$\mu_F^k = (1-c)\mu_F^k + cS_{F_2}^k/S_F^k \quad (12)$$

$$\mu_{CR}^k = (1-c)\mu_{CR}^k + cS_{CR}^k/S_N^k \quad (13)$$

ここで、 μ_F^k はグループ k に対する F の Cauchy 分布の位置パラメータ、 μ_{CR}^k はグループ k に対する CR の正規分布の平均である。 S_N^k はグループ k において親より良い子が生成された成功した回数、 $S_{F_1}^k, S_{F_2}^k, S_{CR}^k$ はそれぞれグループ k において親よりよい子が生成された成功時の F_i, F_i^2, CR_i の和である。JADE と同様に、 CR_i は区間 $[0, 1]$ となるように切り捨てられる。 F_i は負の値あるいは0の場合は再生成され、それ以外の場合は1以下となるように切り捨てられる。

4.3 アルゴリズム

提案手法のアルゴリズムは以下の通りである。

Step0 パラメータの初期化

スケーリングファクターの平均値 $\mu_F^k = 0.5$, 交叉率の平均値 $\mu_{CR}^k = 0.5$ とする。パラメータ生成時の標準偏差を $\sigma_F = 0.1, \sigma_{CR} = 0.1$ とする。ただし、 $k = 1, \dots, K$ はグループ番号である。

Step1 個体の初期化

初期集団 $P = \{\mathbf{x}_i \mid i = 1, 2, \dots, N\}$ を探索空間 S 中でランダムに生成する。 N は集団サイズである。

Step2 終了条件

関数評価回数が最大評価回数 FE_{max} を超えれば、アルゴリズムは終了する。成功時のパラメータ値を保持するリスト S^k を空にする。

Step3 グループ化

クラスタリングによるグループ化の場合には、k-means 法によりクラスタリングを行い、各個体のグループ番号を決定する。ランクによるグループ化の場合には、個体集団 $\{\mathbf{x}_i\}$ を関数値についてソートし、ランク r_i を求め、グループ番号を決定する。

Step4 DE 操作

各個体 \mathbf{x}_i について、グループ番号 $k = group(\mathbf{x}_i)$ を求める。交叉率 CR_i を正規分布 $N(\mu_{CR}^k, \sigma_{CR}^2)$ で生成する。スケーリングファクター F_i を Cauchy 分布 $C(\mu_F^k, \sigma_F)$ に基づき生成する。パラメータを F_i, CR_i として DE/current-to-pbest/1/bin 操作を実行し、子 \mathbf{x}_i^{child} を生成する。子が親より良ければ、成功と判断し、子を生存者として選択し、成功時のパラメータ値 (F_i, CR_i) をリスト S^k に追加する。成功でなければ、親 \mathbf{x}_i を生存者とする。

Step5 パラメータの更新

全てのグループにおいて、 μ_F^k と μ_{CR}^k を S^k に基づいて更新する。

Step6 Step2 へ戻る。

提案手法の擬似コードを図1に示す。‘+’で始まる行は、JADE に対する変更点を示している。

5 実験

5.1 テスト問題

表1に、テスト問題の関数定義とその初期化領域を示す。なお、 D は次元数を表している。

次元数 $D = 30$ に設定し、JADE と共通のアルゴリズムパラメータは JADE と同じものを採用した。すなわち、個体数 $N = 100$, 平均値の初期値 $\mu_F^k = \mu_{CR}^k = 0.5$ ($k = 1, \dots, K$), パラメータ生成時の固定された標準偏差 $\sigma_F = \sigma_{CR} = 0.1$ とする。なお、クラスタリングによるグループ化および関数値のランクによるグループ化を使用し、グループ数 $K=2,3$ とした。各関数について50回の試行を行い、JADE の結果と比較を行う。

```

JADE with groups/current-to-pbest/1/bin()
{
+  $\mu_F^k = \mu_{CR}^k = 0.5$  ( $1 \leq k \leq K$ );
 $\sigma_F = \sigma_{CR} = 0.1$ ;
// Initialize a population
 $P = N$  individuals generated randomly in  $S$ ;
 $FE = FE + N$ ;
for( $t=1$ ;  $FE < FE_{max}$ ;  $t++$ ) {
+  $S^k = \phi$  ( $1 \leq k \leq K$ );
+ Divide  $P$  into  $K$  groups according to a criteria;
for( $i=1$ ;  $i \leq N$ ;  $i++$ ) {
+  $k = \text{group}(x_i)$ ;
+  $CR_i = \mu_{CR}^k + N(0, \sigma_{CR}^2)$ ;
if( $CR_i < 0$ )  $CR_i = 0$ ;
else if( $CR_i > 1$ )  $CR_i = 1$ ;
do {
+  $F_i = \mu_F^k + C(0, \sigma_F)$ ;
} while( $F_i \leq 0$ );
if( $F_i > 1$ )  $F_i = 1$ ;
 $x^{pbest} =$  Randomly selected from top 100% in  $P$ ;
 $x_{r1} =$  Randomly selected from  $P(r1 \notin \{i\})$ ;
 $x_{r2} =$  Randomly selected from  $P(r2 \notin \{i, r1\})$ ;
 $m_i = x_i + F_i(x^{pbest} - x_i) + F_i(x_{r1} - x_{r2})$ ;
 $x_i^{child} =$  generated from  $x_i$  and  $m_i$ 
by binomial crossover as a trial vector;
 $FE = FE + 1$ ;
// Survivor selection
if( $f(x_i^{child}) < f(z)$ ) {
 $z_i = x_i^{child}$ ;
 $S^k = S^k \cup \{(F_i, CR_i)\}$ ;
// a success case is added to  $S^k$ 
}
else  $z_i = x_i$ ;
}
 $P = \{z_i\}$ ;
+ for( $k=1$ ;  $k \leq K$ ;  $k++$ ) {
+ if( $|S^k| > 0$ ) {
+  $\mu_F^k = (1 - c)\mu_F^k + c \sum_{F_i \in S^k} F_i^2 / \sum_{F_i \in S^k} F_i$ ;
+  $\mu_{CR}^k = (1 - c)\mu_{CR}^k + c \sum_{CR_i \in S^k} CR_i / |S^k|$ ;
}
}
}
}

```

Fig. 1: The pseudo-code of proposed method

5.2 実験結果

JADEと提案手法の比較結果を表2に示す。提案手法については、クラスタリングを用いた場合 (clustering)、関数値のランクを用いた場合 (rank) について、グループ数 $K=2,3$ の場合を示した。各関数毎に最大評価回数 FE_{max} および各試行における最良値の平均値と標準偏差を示した。さらに、Wilcoxon signed rank test を行い、JADEに対して有意に優れていた場合に +、有意に劣っていた場合に -、有意差がない場合に = を付与した。なお、有意水準 5% の場合は +, -, 有意水準 1% の場合は ++, -- で表現している。全てのアルゴリズム中で最良の結果を太字で示した。

提案手法において、関数値のランクによるグループ化の場合、グループ数が2のときは9個の関数 $f_1, f_4, f_6, f_8 \sim f_{13}$ で JADE と比較して優位に優れており、優位に劣った関数はない。グループ数が3のときは8個の関数 $f_1, f_2, f_6, f_8 \sim f_{10}, f_{12}, f_{13}$ において JADE と比較して優位に優れており、優位に劣った関数はない。クラスタリングによるグループ化の場合、グループ数が2のときは f_8 のみで優位に優れており、劣った

Table 1: Test functions of dimension D . These are sphere, Schwefel 2.22, Schwefel 1.2, Schwefel 2.21, Rosenbrock, step, noisy quartic, Schwefel 2.26, Rastigrin, Ackley, Griewank, and two penalized functions, respectively [22]

Test functions	Bound constraints
$f_1(\mathbf{x}) = \sum_{i=1}^D x_i^2$	$[-100, 100]^D$
$f_2(\mathbf{x}) = \sum_{i=1}^D x_i + \prod_{i=1}^D x_i $	$[-10, 10]^D$
$f_3(\mathbf{x}) = \sum_{i=1}^D \left(\sum_{j=1}^i x_j \right)^2$	$[-100, 100]^D$
$f_4(\mathbf{x}) = \max_i \{ x_i \}$	$[-100, 100]^D$
$f_5(\mathbf{x}) = \sum_{i=1}^{D-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$[-30, 30]^D$
$f_6(\mathbf{x}) = \sum_{i=1}^D [x_i + 0.5]^2$	$[-100, 100]^D$
$f_7(\mathbf{x}) = \sum_{i=1}^D i x_i^4 + \text{rand}[0, 1]$	$[-1.28, 1.28]^D$
$f_8(\mathbf{x}) = \sum_{i=1}^D -x_i \sin \sqrt{ x_i } + D \cdot 418.98288727243369$	$[-500, 500]^D$
$f_9(\mathbf{x}) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12, 5.12]^D$
$f_{10}(\mathbf{x}) = -20 \exp \left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2} \right) - \exp \left(\frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i) \right) + 20 + e$	$[-32, 32]^D$
$f_{11}(x) = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos \left(\frac{x_i}{\sqrt{i}} \right) + 1$	$[-600, 600]^D$
$f_{12}(x) = \frac{\pi}{D} [10 \sin^2(\pi y_1) + \sum_{i=1}^{D-1} (y_i - 1)^2 \{1 + 10 \sin^2(\pi y_{i+1})\} + (y_D - 1)^2] + \sum_{i=1}^D u(x_i, 10, 100, 4)$ where $y_i = 1 + \frac{1}{4}(x_i + 1)$ and $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a \leq x_i \leq a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	$[-50, 50]^D$
$f_{13}(x) = 0.1[\sin^2(3\pi x_1) + \sum_{i=1}^{D-1} (x_i - 1)^2 \{1 + \sin^2(3\pi x_{i+1})\}] + (x_D - 1)^2 \{1 + \sin^2(2\pi x_D)\} + \sum_{i=1}^D u(x_i, 5, 100, 4)$	$[-50, 50]^D$

関数はない。グループ数が3のときは f_4, f_8 で優れているが f_7 で劣った結果となっている。したがって、クラスタリングによるグループ化の効果は低いが、関数値のランクによるグループ化の効果は高く、JADEと同等以上の優れた性能を実現できたと考えられる。

各問題における最良個体の関数値の平均値および μ_F^k と μ_{CR}^k の値の変化を調べるために、単峰性関数である f_1 のグラフを図2に、多峰性関数である f_{10} のグラフを図3に示す。横軸は関数評価回数である。縦軸については、最上段は関数値、続いて $\text{rank}(K=2)$, $\text{rank}(K=3)$, clustering($K=2$), clustering($K=3$) の場合における μ_F^k (左側) と μ_{CR}^k (右側) の変化を示している。

関数値によるグループ化において、単峰性の関数 f_1 では、JADEの値と比較して、優良なグループの μ_F^1 および μ_{CR}^1 の値は小さくなり、優良でないグループの μ_F^k および μ_{CR}^k の値は大きくなる傾向がある。多峰性の関数 f_{10} でも同様の傾向にある。したがって、グループ化によって JADE と異なるパラメータの制御が実現され、探索効率の向上に繋がったと考えられる。これに対して、クラスタリングによるグループ化においては、単峰性関数、多峰性関数のいずれにおいても μ_F^k および μ_{CR}^k の値に対するグループ間の差は小さく、ほとんどのグループにおいて JADE と同様の制御が行われている。このため、グループ化しても JADE と同程度の探索効率となったと考えられる。

Table 2: 実験結果

	FE_{max}	JADE	rank $K=2$	rank $K=3$	clustering $K=2$	clustering $K=3$
f_1	150,000	9.38e-59 ± 6.5e-58	4.32e-66 ± 1.3e-65 ++	3.36e-64 ± 2.2e-63 ++	1.41e-56 ± 9.8e-56 =	3.48e-61 ± 1.7e-60 =
f_2	200,000	4.19e-31 ± 2.4e-30	5.10e-32 ± 2.7e-31 =	2.57e-37 ± 1.6e-36 ++	9.81e-28 ± 6.8e-27 =	3.80e-29 ± 2.5e-28 =
f_3	500,000	8.17e-62 ± 3.0e-61	1.77e-59 ± 1.2e-58 =	2.25e-60 ± 1.5e-59 =	2.70e-61 ± 7.8e-61 =	2.07e-60 ± 1.2e-59 =
f_4	500,000	2.01e-23 ± 9.8e-23	1.20e-24 ± 4.3e-24 +	3.70e-24 ± 1.0e-23 =	9.18e-24 ± 2.7e-23 =	4.16e-23 ± 1.5e-22 +
f_5	300,000	5.78e-01 ± 3.5e+00	7.97e-02 ± 5.6e-01 =	7.26e-01 ± 3.5e+00 =	1.59e-01 ± 7.8e-01 =	6.88e-02 ± 4.8e-01 =
f_6	10,000	3.02e+00 ± 1.3e+00	1.78e+00 ± 1.2e+00 ++	1.98e+00 ± 1.1e+00 ++	3.02e+00 ± 1.1e+00 =	2.76e+00 ± 1.4e+00 =
f_7	300,000	6.04e-04 ± 2.4e-04	7.11e-04 ± 2.3e-04 =	6.80e-04 ± 2.2e-04 =	6.62e-04 ± 2.3e-04 =	7.31e-04 ± 2.1e-04 -
f_8	100,000	2.37e+00 ± 1.7e+01	2.46e-05 ± 3.1e-05 ++	1.18e+01 ± 3.6e+01 +	2.23e-05 ± 1.9e-05 ++	2.30e-05 ± 2.3e-05 ++
f_9	100,000	1.01e-04 ± 3.9e-05	5.64e-05 ± 2.8e-05 ++	5.95e-05 ± 3.0e-05 ++	9.19e-05 ± 4.1e-05 =	9.79e-05 ± 5.6e-05 =
f_{10}	50,000	9.20e-10 ± 6.4e-10	4.22e-10 ± 3.0e-10 ++	3.41e-10 ± 3.1e-10 ++	9.01e-10 ± 7.8e-10 =	7.80e-10 ± 6.3e-10 =
f_{11}	50,000	1.15e-08 ± 6.9e-08	1.97e-04 ± 1.4e-03 +	3.46e-04 ± 1.7e-03 =	1.10e-07 ± 4.7e-07 =	8.81e-07 ± 6.0e-06 =
f_{12}	50,000	2.40e-16 ± 1.6e-15	4.99e-18 ± 2.6e-17 ++	1.37e-18 ± 5.5e-18 ++	2.98e-17 ± 1.6e-16 =	2.00e-17 ± 7.2e-17 =
f_{13}	50,000	1.15e-16 ± 2.2e-16	2.17e-17 ± 5.1e-17 ++	1.69e-17 ± 7.5e-17 ++	2.39e-16 ± 7.2e-16 =	2.57e-16 ± 1.0e-15 =
+		—	9	8	1	2
=		—	4	5	12	10
-		—	0	0	0	1

6 おわりに

本研究では、個体集団を一定の基準によりグループ化し、グループ毎に JADE のパラメータを制御する方法を提案した。グループ化の基準として、関数値のランクと距離によるクラスタリングという 2 種類の基準を提案した。このうち、関数値のランクに基づくグループ化は本手法の基本モデルである JADE より優れた性能が実現できることを示した。

本論文では、グループ数が 2,3 の場合を検討したが、適切なグループ数についてさらに検討する必要がある。現在、 μ_F^k や μ_{CR}^k の初期値を 0.5 としているが、より適切な初期値の設定方法について検討する必要がある。また、最良個体や最悪個体に対する特別な制御についても検討したいと考えている。

謝辞 この研究の一部は、本研究は JSPS 科研費 26350443 の援助を受けた。

参考文献

- 1) R. Storn and K. Price: “Minimizing the real functions of the ICEC’96 contest by differential evolution”, Proc. of the International Conference on Evolutionary Computation, pp. 842–844 (1996).
- 2) R. Storn and K. Price: “Differential evolution – A simple and efficient heuristic for global optimization over continuous spaces”, Journal of Global Optimization, **11**, pp. 341–359 (1997).
- 3) U. K. Chakraborty Ed.: “Advances in Differential Evolution”, Springer (2008).
- 4) S. Das and P. Suganthan: “Differential evolution: A survey of the state-of-the-art”, IEEE Transactions on Evolutionary Computation, **15**, 1, pp. 4–31 (2011).
- 5) T. Takahama and S. Sakai: “Constrained optimization by the ε constrained differential evolution with gradient-based mutation and feasible elites”, Proc. of

the 2006 IEEE Congress on Evolutionary Computation, pp. 308–315 (2006).

- 6) T. Takahama and S. Sakai: “Constrained optimization by the ε constrained differential evolution with an archive and gradient-based mutation”, Proc. of the 2010 IEEE Congress on Evolutionary Computation, pp. 1680–1688 (2010).
- 7) J. Liu and J. Lampinen: “A fuzzy adaptive differential evolution algorithm”, Soft Computing, **9**, 6, pp. 448–462 (2005).
- 8) T. Takahama and S. Sakai: “Fuzzy c-means clustering and partition entropy for species-best strategy and search mode selection in nonlinear optimization by differential evolution”, Proc. of the 2011 IEEE International Conference on Fuzzy Systems, pp. 290–297 (2011).
- 9) T. Takahama and S. Sakai: “Differential evolution with dynamic strategy and parameter selection by detecting landscape modality”, Proc. of the 2012 IEEE Congress on Evolutionary Computation, pp. 2114–2121 (2012).
- 10) T. Takahama and S. Sakai: “Large scale optimization by differential evolution with landscape modality detection and a diversity archive”, Proc. of the 2012 IEEE Congress on Evolutionary Computation, pp. 2842–2849 (2012).
- 11) 高濱, 阪井, 原: “RDE: 探索点のランク情報を利用した効率的な differential evolution の提案”, 電子情報通信学会論文誌 D, **95**, 5, pp. 1196–1205 (2012).
- 12) T. Takahama and S. Sakai: “Efficient constrained optimization by the ε constrained rank-based differential evolution”, Proc. of the 2012 IEEE Congress on Evolutionary Computation, pp. 62–69 (2012).
- 13) J. Teo: “Exploring dynamic self-adaptive populations in differential evolution”, Soft Computing, **10**, 8, pp. 673–686 (2006).

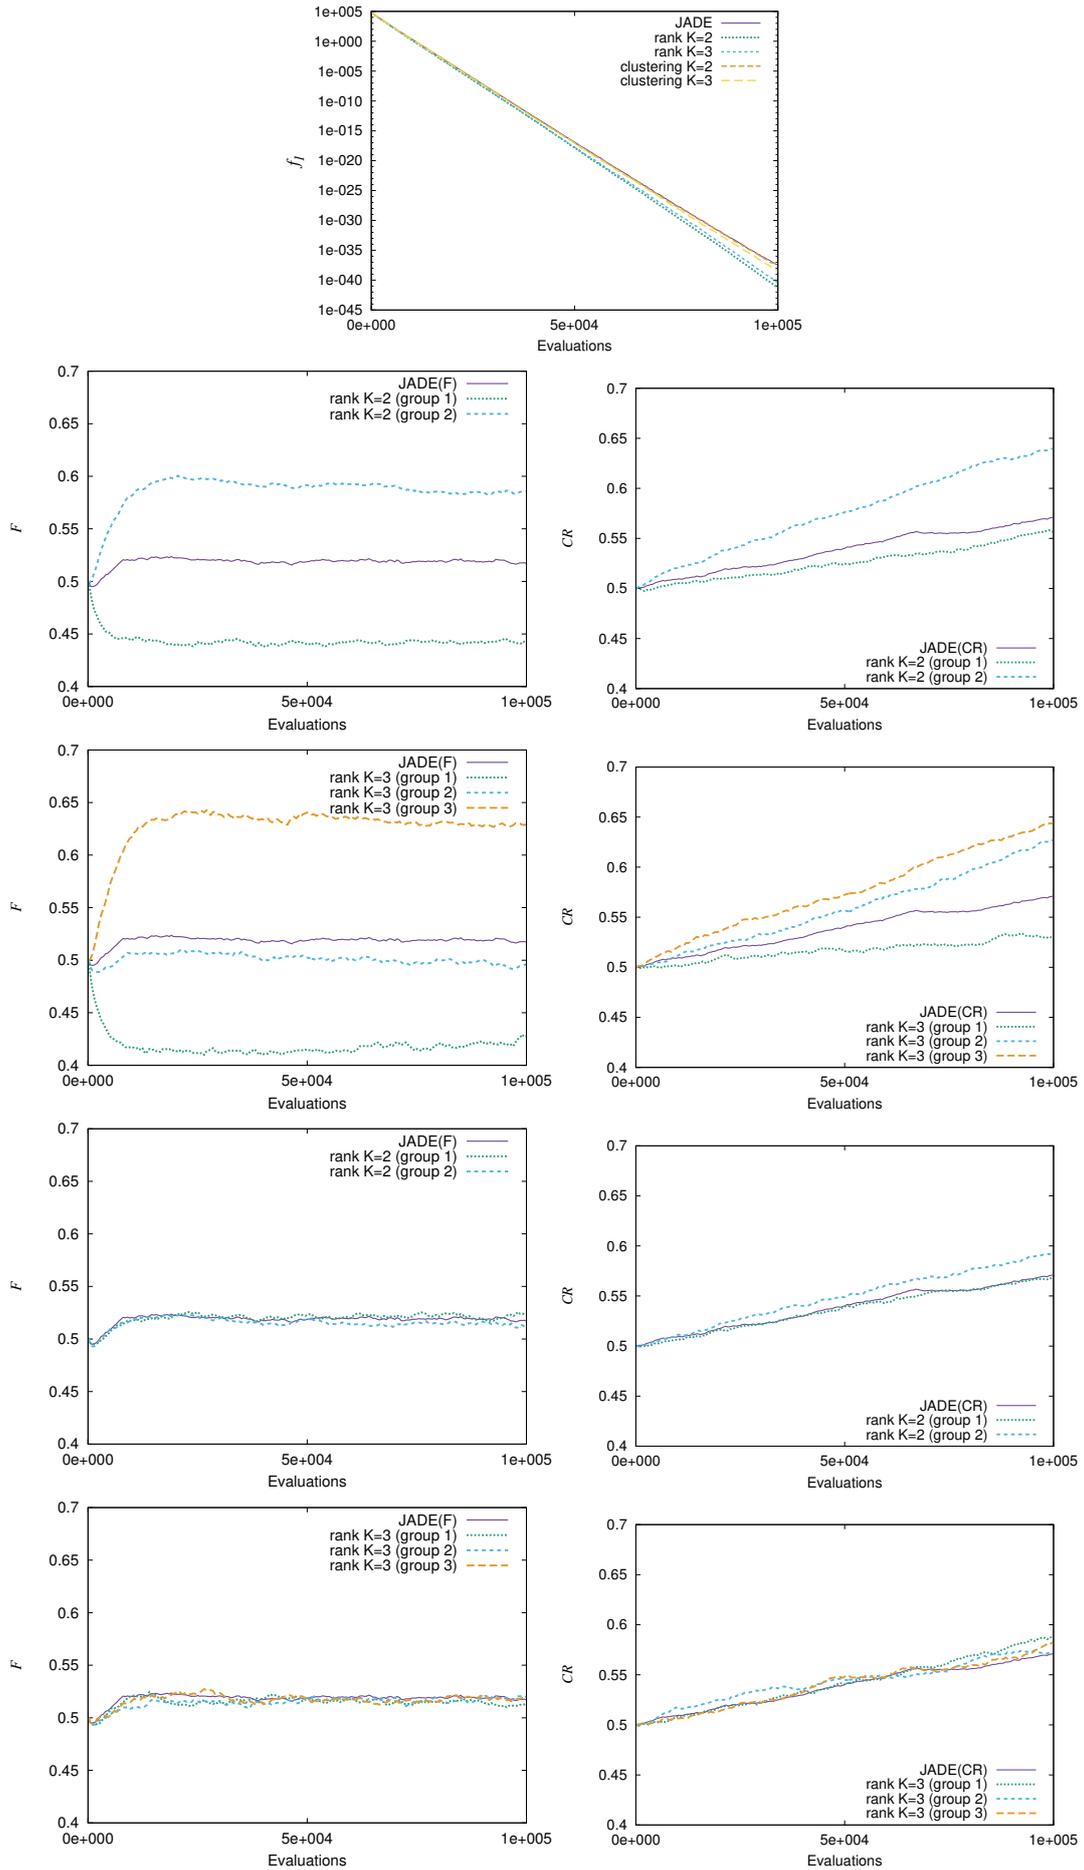


Fig. 2: f_1 における関数値, μ_F^k , μ_{CR}^k の変化

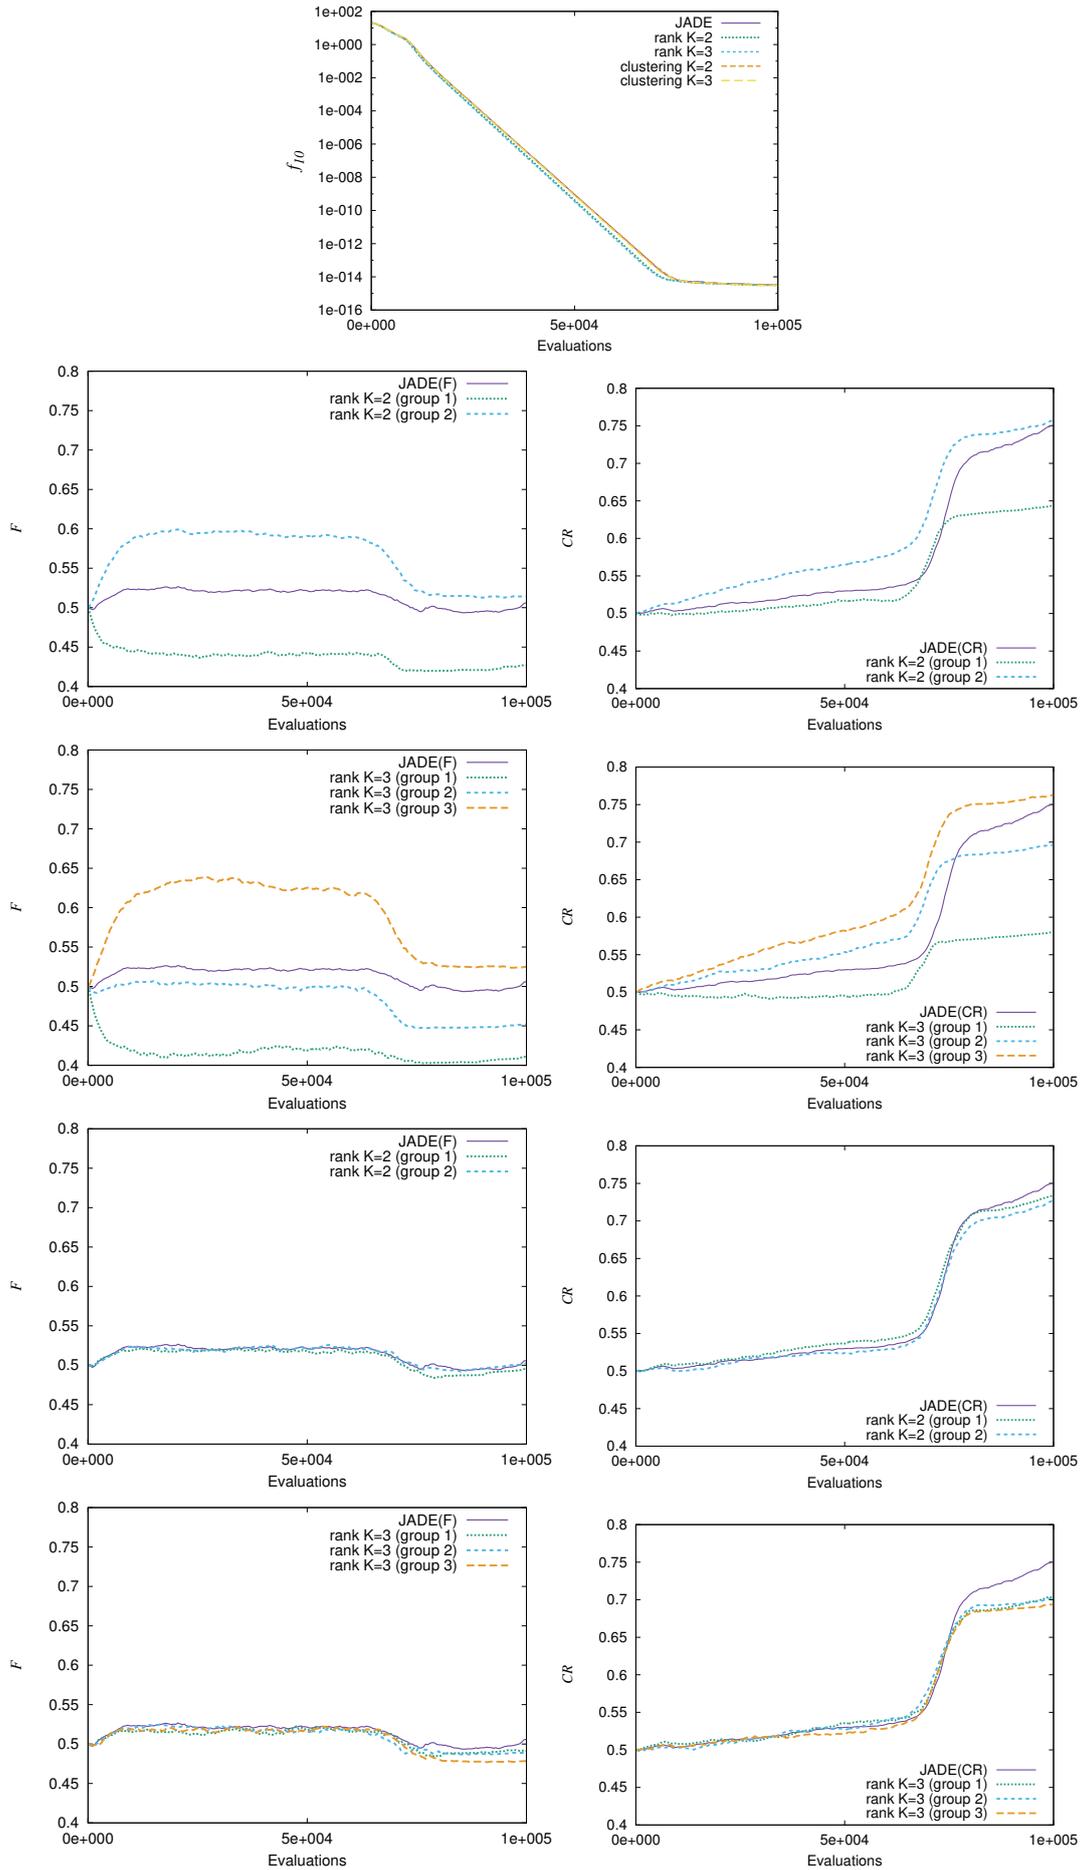


Fig. 3: f_{10} における関数値, μ_F^k , μ_{CR}^k の変化

- 14) A. K. Qin and P. N. Suganthan: “Self-adaptive differential evolution algorithm for numerical optimization”, Proc. of the 2005 IEEE Congress on Evolutionary Computation, pp. 1785–1791 (2005).
- 15) J. Zhang and A. C. Sanderson: “JADE: Adaptive differential evolution with optional external archive”, IEEE Transactions on Evolutionary Computation, **13**, 5, pp. 945–958 (2009).
- 16) S. M. Islam, S. Das, S. Ghosh, S. Roy and P. N. Suganthan: “An adaptive differential evolution algorithm with novel mutation and crossover strategies for global numerical optimization”, IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, **42**, 2, pp. 482–500 (2012).
- 17) R. Tanabe and A. Fukunaga: “Success-history based parameter adaptation for differential evolution”, Proc. of the 2013 IEEE Congress on Evolutionary Computation, pp. 71–78 (2013).
- 18) T. Takahama and S. Sakai: “An adaptive differential evolution considering correlation of two algorithm parameters”, Proc. of the Joint 7th International Conference on Soft Computing and Intelligent Systems and 15th International Symposium on Advanced Intelligent Systems (SCIS&ISIS2014), pp. 618–623 (2014).
- 19) T. Takahama and S. Sakai: “Improving an adaptive differential evolution using hill-valley detection”, International Journal of Hybrid Intelligent Systems, **13**, 1, pp. 1–13 (2016).
- 20) T. Takahama and S. Sakai: “An adaptive differential evolution with adaptive archive selection and hill-valley detection”, Proc. of the 2016 IEEE Congress on Evolutionary Computation, pp. 48–55 (2016).
- 21) T. Takahama, S. Sakai and N. Iwane: “Solving non-linear constrained optimization problems by the ϵ constrained differential evolution”, Proc. of the 2006 IEEE Conference on Systems, Man, and Cybernetics, pp. 2322–2327 (2006).
- 22) X. Yao, Y. Liu, K.-H. Liang and G. Lin: “Fast evolutionary algorithms”, Advances in Evolutionary Computing: Theory and Applications (Eds. by A. Ghosh and S. Tsutsui), Springer-Verlag New York, Inc., New York, NY, USA, pp. 45–94 (2003).

天球画像のオプティカルフローを用いた旋回時の視線方向の違いによる比較

○永井祐輔 増田寛之 岡島恵一 本吉達郎 澤井圭 小柳健一 大島徹 (富山県立大学)
高山英一 (高山自動車)

Comparison with Difference of Gaze Direction of Cornering using Optical Flow on Spherical Image

*Y. Nagai, H. Masuta, Y. Okajima, T. Motoyoshi, K. Sawai, K. Koyanagi and T. Oshima
(Toyama Prefectural University)
E. Takayama (TAKAYAMA CARS,CO.,Ltd.)

Abstract— Recently, various companies have developed an automatic driving vehicle. However, it is problem that people have a feeling of strangeness to the automatic control while a vehicle cornering. For comfortable cornering control, cooperation with gaze direction, the run trace of the vehicle and flow of the view are important to the comfortable cornering. We focused on the relation between gaze direction and flow of the optical alignment on the retina. Therefore, we compare the difference of gaze direction using optical flow according to sphere image. And, we discuss the relation between the gaze direction and the optical flow in the spherical view.

Key Words: Spherical Image, Optical Flow

1 はじめに

現在、自動運転化が進む中、人間にとっての快適と感じる運転が重要な課題となっている。その中でも、旋回は「直進・停止」と並ぶ車両の基本動作の一つであり、快適さの差が顕著に表れる行動である。そこで、本研究では快適な旋回のための車両制御システムの実現を目標とする。快適な旋回のための車両制御システムを実現するためには、人間と車両の旋回の中に存在するズレを無くす必要がある。走行のズレは違和感を生み、走行時の快適さを損なう。そのため、快適な旋回制御を実現を目指す上で、人間と車両の旋回に存在するズレは解決しなければならない問題の一つとなる。しかし、同じ人間であっても熟練運転者と初心運転者の間では旋回時の快適さに大きな差が生じる。そこで、旋回に差を生む要因を調べることで快適な旋回制御につなげる。

人間の運動行動に利用されている情報のうち90%は視覚情報であるとされている¹⁾。森らの研究では、熟練運転者と初心運転者では注視点の位置に差が生じることを示し、注視点の位置と車両の軌道に関連性があることを示唆している²⁾。岸田らの研究では、旋回時の近傍に現れる特に速度が速い成分のオプティカルフローを遮蔽することにより頭部運動が安定化し、転舵速度標準偏差が減少することを示した³⁾。Salvucciらは、車両の進行方向と近い点と遠い点を用いることで旋回する旋回モデルを構築し、運転者の特性を表現することに成功した⁴⁾。これらから、旋回において視覚情報は旋回時の運転行動に影響を与えているといえる。しかし、多くの関連研究は旋回時の視覚情報を利用しているが、前提とされてるカーブ先に視線を向ける意図については議論されていない。

そこで、本稿では、旋回時にカーブの先に視線を向けることで、目に入射される光の流れの変化に着目し、旋回時に旋回時にカーブ先に視線を向けた時と向けて

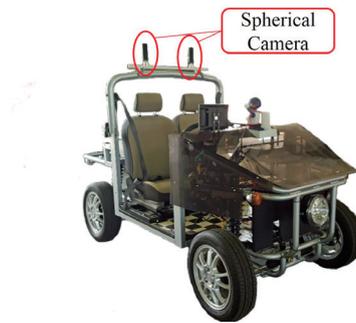


Fig. 1: UCEV "TORiCLE Zero"

いない時の天球画像のオプティカルフローを比較することで、視線方向が運転者に与える影響について考察する。

2 実験機材

2.1 超小型電気自動車

株式会社高山自動車と共同開発した超小型電気自動車「10-1000型」(以下、UCEVとする)の外観と仕様をFig.1, Table 1に示す。本車両は2人乗りで定格4.5[kW]の駆動モータが搭載されている。さらに、ステアリングモータや、ブレーキモータ、発話・動作を行うインタラクションロボット、そしてこれらを制御するECUを搭載した。また、シート後部のフレームは全天球カメラを取り付けられる仕様になっており、カメラで撮影しながらの走行が可能である。

2.2 全天球カメラ

本研究では旋回時の画像を撮影にRICOH株式会社の全天球カメラTHETA Sを使用する。ここで、THETA Sによって撮影された画像をFig.2に示す。THETA Sの仕様をTable 2に示す。THETA Sは2つの魚眼レンズと等立体角射影方式により射影された2枚の平面画像を組み合わせることによって、上下左右360°]の

Table 1: Specification of UCEV

Overall Length	2490 [mm]
Overall Width	1290 [mm]
Overall Height	1680 [mm]
Wheelbase	1730 [mm]
Weight	500[kg]
Maximum Speed	60[km/h]
Differential Gear Ratio	7.448
Drive System	Rear - drive
Suspension	MacPherson Strut
Front Wheel Brake	Disc Brake
rear Wheel Brake	Drum Brake
Rated Output of Motor	4.5 [kW]
battery	Lead Storage Battery 12V/42Ah × 6 Lead Storage Battery 12V/28Ah × 6



Fig. 2: A Snapshot of Spherical Camera

画像を取得することが可能である。旋回時の環境情報を取得するにはカーブの先まで撮影することができるカメラが必要となる。THETA Sであれば1枚の画像で上下左右180°の範囲を撮影できるため旋回時の走行動画取得に適切であると判断した。また、全天球カメラは球面レンズに入射した光を平面上に射影している。人間の網膜も球状であり、この球面への光の入射が人間の物体のとらえ方と類似しているため、人間に違和感を持たせない旋回制御に有効であると考えられる。

3 旋回中の走行イメージ

3.1 球面画像と平面画像の対応

天球画像のオプティカルフローを求めるには、射影された後の平面画像ではなく射影される前の球面画像で物体の動きを考える必要がある。なぜならば、人間の網膜上の光の流れに似た情報を得るためには網膜のように球面上で光の流れを考える必要がある。そのため、平面に射影されている画像を球面画像に復元する必要がある。ここで、球面画像と平面画像の対応図をFig. 3に示す。等立体角射影は、入射する光とx軸のなす角を θ [rad]、焦点距離を f とすると、

$$r = 2f \sin \frac{\theta}{2} \quad (1)$$

よりYZ平面上の点 I に射影される。THETA Sは、球面へ入射された光をLive Streaming Viewモードで撮影する場合、 600×600 [pixel]の平面画像に射影する。

次に、球面座標と平面に射影された点に対応させる。ここで、方位角を α 、仰俯角を δ とすると球面上の光

Table 2: Specification of THETA S

Photographing Distance	10 [cm] ~
Projection method	Equisolid Angle Projection
External Interface	Micro USB 2.0 HDMI-Micro(Type-D)1.4
Live streaming resolution(USB)/frame rate	M : 1280× 720/15fps
Live streaming resolution(HDMI)/frame rate	L : 1920× 1080/30fps M : 1280× 720/30fps S : 720× 480/30fps

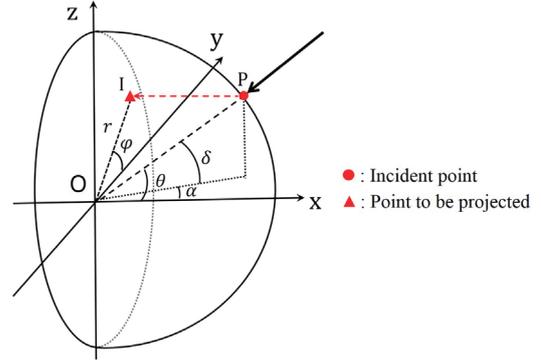


Fig. 3: Projection of Spherical Camera

の入射点 $P(P_x, P_y, P_z)$ は

$$\begin{bmatrix} P_x \\ P_y \\ P_z \end{bmatrix} = \begin{bmatrix} f \cos \delta \cos \alpha \\ f \cos \delta \sin \alpha \\ f \sin \delta \end{bmatrix} \quad (2)$$

と表すことができる。また、点 I と原点を結んだ距離 r と y 軸のなす角 ϕ と θ を用いると射点 P は、

$$\begin{bmatrix} P_x \\ P_y \\ P_z \end{bmatrix} = \begin{bmatrix} f \sin(\frac{\pi}{2} - \theta) \\ f \cos(\frac{\pi}{2} - \theta) \cos \phi \\ f \cos(\frac{\pi}{2} - \theta) \sin \phi \end{bmatrix} \quad (3)$$

と表すことができる。そして、式(2)、式(3)を用いて r と y 軸のなす角 ϕ を求める。ここで、式(2)、式(3)の P_x に関する式より、 θ は、

$$\theta = \cos^{-1}(\cos \delta \sin \alpha) \quad (4)$$

となる。ここで、式(2)、式(3)の P_y に関する式と式(4)より ϕ は、

$$\phi = \cos^{-1} \left[\frac{\cos \delta \cos \alpha}{\sin \{ \cos^{-1}(\cos \delta \sin \alpha) \}} \right] \quad (5)$$

で求められる。そして、射影された点 I の成分 I_x, I_y は、

$$\begin{bmatrix} I_x \\ I_y \end{bmatrix} = \begin{bmatrix} r \cos \phi \\ r \sin \phi \end{bmatrix} \quad (6)$$

と表すことができる。従って、式(2)、式(5)、式(6)より、球面画像の画素値は、方位角 α 、仰俯角 δ を用いることで平面画像から対応する画素値を参照することができる。今後、球面画像で画像処理を行う際、この変換式を用いて平面から対応する画素値を参照することで画像処理を行う。

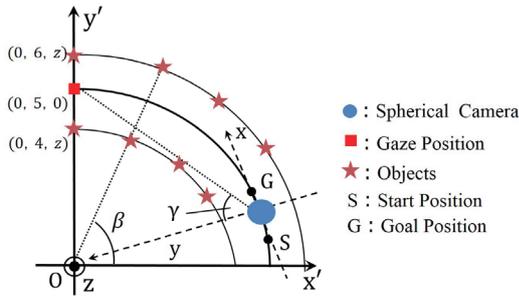


Fig. 4: simulation condition

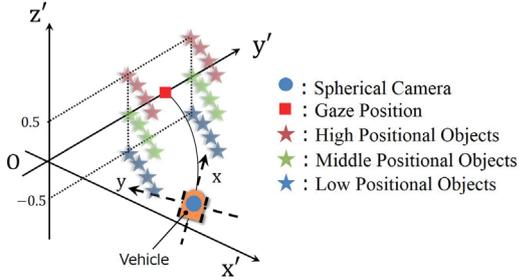


Fig. 5: Coordinate System Σ_0

3.2 シミュレーション

前節で、球面上の入射点を平面に射影された画像から算出できることを示した。ここでは、実際の全天球カメラの映像からオプティカルフローを取得する前に、旋回を行う際の視線の違いによって、旋回中に見える背景の動きをMATLABを用いてシミュレーションを行った。シミュレーションの際の視線条件を以下に示す。

case1 視線を常に車両の前方に向ける (Σ_0 座標系)

case2 視線を常にカーブの先に向ける (Σ_1 座標系)

今回想定した旋回状況を Fig. 4 に示す。想定した状況は、曲率 5[m] の経路を一定速度で 0.17[m] 移動した時の背景の動きである。そして、旋回経路の両側となる曲率 6[m]、曲率 4[m] の円周上に物体を配置した。物体の位置は、物体と x' 軸のなす角を β とした時 $\beta = 45, 60, 75, 90^\circ$ の位置に配置した。また、物体は各点毎に全天球カメラと同じ高さ、全天球カメラよりも 0.5[m] 高い位置、全天球カメラよりも 0.5[m] 低い位置に配置している。

次に、各条件の座標の取り方を Fig. 5, Fig. 6 に示す。 Σ_0 座標系は x 軸を円周の接線方向に向けるように取るものとする。一方、 Σ_1 座標系は注視点に x 軸を向けるように取り x と直交するように y 軸を取る。

視線を円周の接線方向に向けたまま旋回した時の結果を Fig. 7 に、視線をカーブの先に向けて旋回した時の結果を Fig. 8 に示す。ここで、表示されているベクトルは、見やすくするため拡大して表示している。また、 x 軸の正の方向を正面し視線の方向とする。Fig. 7 では、視線方向が円周の接線方向であるため、物体は正面に向かって左側に見える。そして、微小区間の旋回を行うと 8 か所にある物体の全てが右方向に向かって流れていることがわかる。一方、Fig. 8 では、視線方向をカーブ先に向けるためカメラの座標軸を回転さ

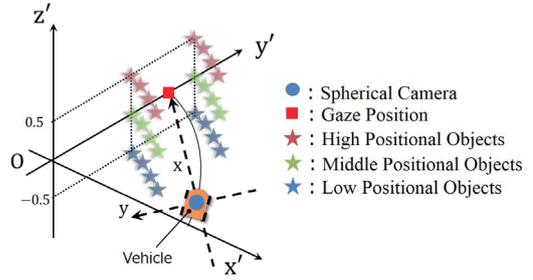


Fig. 6: Coordinate System Σ_1

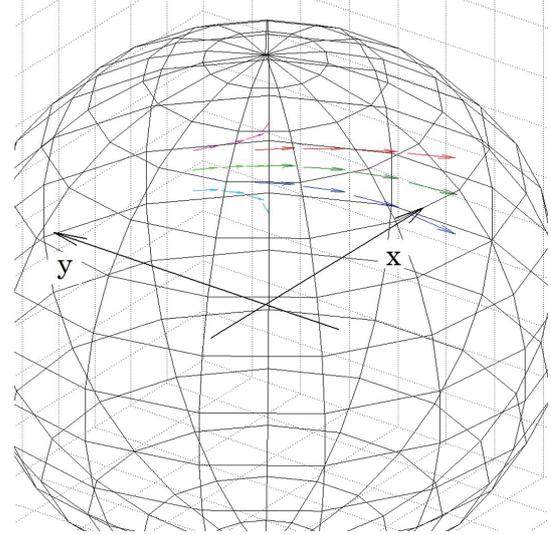


Fig. 7: Simulation Result on the case1

せているため、物体は正面付近に見えることがわかる。そして、視線をカーブ先に向けるときと向けない時で大きく異なる点は、case2 では旋回経路の内側にある物体は正面に向かって左方向に流れている。また、旋回経路の外側にある物体は正面に向かって右方向に流れていることがわかる。さらに、視線方向をカーブ先に向けることで各物体の移動量が小さくなっていることがわかる。

3.3 Σ_0 座標系でカーブ先に視線を向けた時の物体の動きを表示

Fig. 7, Fig. 8 より、視線方向が異なると物体の移動方向に差が生じることを示した。ここでは、視線方向の違いによる変化を見やすくするため、 Σ_0 座標系で Σ_1 座標系の物体の移動ベクトルを算出する方法について示す。球面上の物体の座標は、方位角 α と仰俯角 δ を用いると式 (2) で与えられる。ここで、 Σ_0 座標系での注視点の移動ベクトルを $[\Delta\alpha_g, \Delta\delta_g]$ と置くと、 Σ_0 座標系上で、注視点の移動を加えた時の物体の位置は、式 (2) と物体の移動量より、

$$\begin{bmatrix} P_x \\ P_y \\ P_z \end{bmatrix} = \begin{bmatrix} f \cos(\delta - \Delta\delta_g) \cos(\alpha - \Delta\alpha_g) \\ f \cos(\delta - \Delta\delta_g) \sin(\alpha - \Delta\alpha_g) \\ f \sin(\delta - \Delta\delta_g) \end{bmatrix} \quad (7)$$

と変化する。 Σ_0 座標系で Σ_1 座標系と同じ物体の移動ベクトルを算出する際には、式 (7) を用いて球面上の座標を表すことができる。

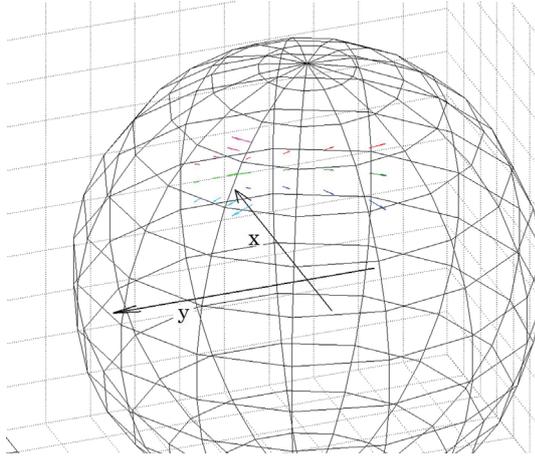


Fig. 8: Simulation Result on the case2

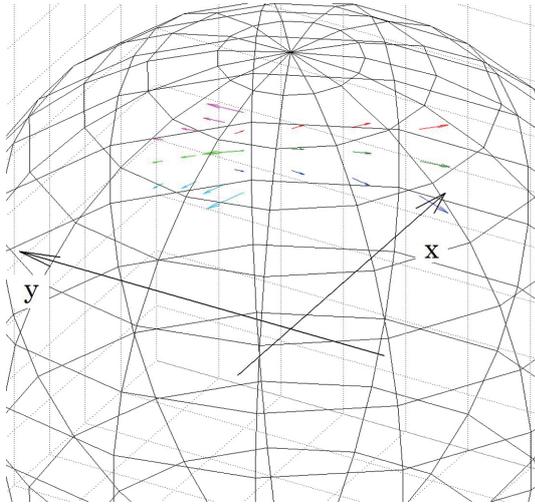


Fig. 9: Simulation Result on the case2 in Σ_0

式 (7) より求めた Σ_0 座標系の物体の移動ベクトルの動きを Fig. 9 に示す. Fig.7, Fig. 8, Fig. 9 より, Fig. 7 と Fig. 9 は基準座標は同じであるが, 物体の移動ベクトルは視線方向をカーブ先に向けた時の結果と同様の結果が得られていることがわかる. このことから, 旋回時にカーブ先に視線を向けた時の物体の移動ベクトルは, Σ_0 座標系での注視点の移動ベクトルと物体の移動ベクトルとの差を取ることで求めることが可能である.

視線を車両の正面方向に向けた時の物体の動きを見ると, カーブの先に視線を置き, その注視点に向かうように車両が移動すると, 周囲の物体は放射状に広がるのがわかった. このことから, 注視点の位置と車両の移動方向が一致しているとき物体のフローは放射状に広がるのではないかと推測する.

4 球面画像のオプティカルフロー

シミュレーションの結果より, 視線方向の違いによって背景の動きに差が出ることを示された. そこで, 実動画からオプティカルフローを算出する方法として, HoG 特徴量を用いたテンプレートマッチングを行うことでオプティカルフローを得る方法を示す.

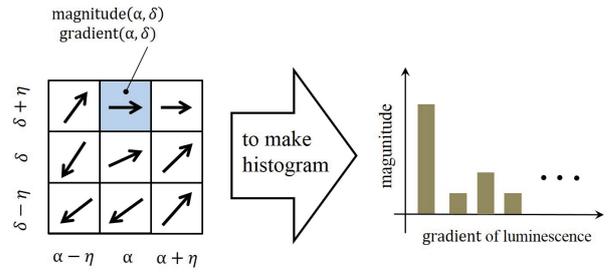


Fig. 10: Acquisition of HoG

4.1 HoG 特徴量

本研究では, 球面画像でテンプレートマッチングに使用する特徴量として Histogram of oriented gradient (HoG) 特徴量を用いる⁵⁾. HoG 特徴量は画像内の物体の形状を取得する際に用いられる. HoG 特徴量は, セルを構成する複数のピクセルの輝度の勾配方向をヒストグラム化した特徴量である. HoG 特徴量の取得過程を Fig. 10 に示す. 本来, 輝度の勾配を算出する際にはピクセル単位で画素値を指定して勾配方向を算出するが, 本研究では球面画像を扱うため, 画素値の指定をピクセル単位ではなく角度単位で指定する. ここで, 座標点 (α, δ) における方位角方向の輝度の差を $grad_\alpha(\alpha, \delta)$, 仰俯角方向の輝度の差を $grad_\delta(\alpha, \delta)$, とすると,

$$\begin{cases} grad_\alpha(\alpha, \delta) = I(\alpha + \Delta\alpha, \delta) \\ \quad \quad \quad - I(\alpha - \Delta\alpha, \delta) \\ grad_\delta(\alpha, \delta) = I(\alpha, \delta + \Delta\delta) \\ \quad \quad \quad - I(\alpha, \delta - \Delta\delta) \end{cases} \quad (8)$$

で表される. ここで, $I(\alpha, \delta)$ は角度 α, δ によって参照される輝度値であり, $\Delta\alpha, \Delta\delta$ はそれぞれの角度方向における微小変化量である. また, 式 (8) より, 輝度勾配の大きさを $m(\alpha, \delta)$, 輝度勾配の角度を $\theta_{grad}(\alpha, \delta)$ とすると

$$m(\alpha, \delta) = \sqrt{(grad_\alpha)^2 + (grad_\delta)^2} \quad (9)$$

$$\theta_{grad}(\alpha, \delta) = \tan^{-1} \frac{grad_\delta}{grad_\alpha} \quad (10)$$

で求められる. そして, 式 (9), 式 (10) の値より求められるヒストグラムを \mathbf{H} とすると

$$\mathbf{H} = [h_1, h_2, \dots, h_n] \quad (n = 16) \quad (11)$$

となる. ここで, n は勾配角度の分割数を表し, h_n は, n 番目の勾配角度を持つ輝度勾配の大きさの和である. マッチングを行う際には, このヒストグラム \mathbf{H} を用いて行う.

4.2 テンプレートマッチング

本研究では, HOG 特徴量を用いたテンプレートマッチングを行うことで物体のオプティカルフローを算出する. 球面画像のオプティカルフローの算出概要を Fig. 11 に示す. テンプレートマッチングは, 球面画像を方位角, 仰俯角ともに $1[^\circ]$ 毎に点を取り, 各点でのヒストグラムを取得する. これを 1 フレーム前の画像と現在の画像で行い, 前の画像の画像からテンプレートと

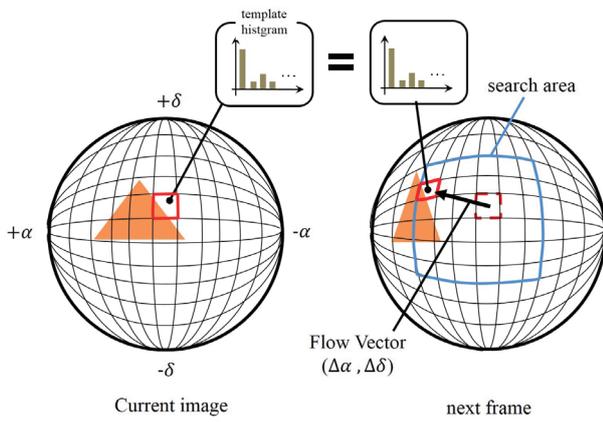


Fig. 11: Template Matching using HOG on Spherical Image

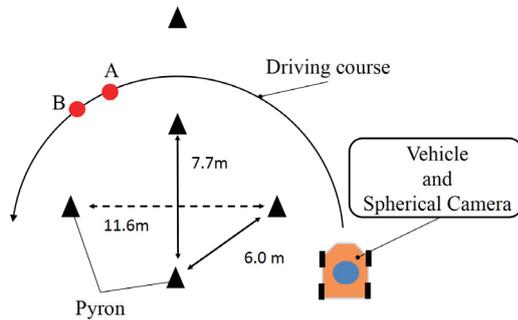


Fig. 12: Driving course

なる点を決定し、その点を中心としてに現在の画像から探索領域を設定する。そして、その探索領域内を $1[^\circ]$ 毎に探索し、最も一致度の高い座標を物体の移動先とした。また、一致度の評価関数には \cos 類似度と強度の一致度を示すガウス関数を用いた。

5 走行実験

5.1 概要

球面画像でオプティカルフローを算出する方法を示したため、実際の走行動画を用いて視線方向の違いによる物体の流れの比較を行う。今回走行したコースを Fig.12 に示す。今回、左旋回を行った走行動画を使用する。走行環境は、奥行が約 $40[m]$ 、幅が約 $20[m]$ で天井と照明がある環境で動画の撮影を行った。運転者には、旋回時にはできるだけカーブの先に視線を向けて旋回を行うように指示をした。オプティカルフローの算出に用いた動画は、Fig.12 の A 地点、B 地点で示した部分の動画を使用した。使用した動画はフレームレート $10[\text{fps}]$ であり、A 地点から B 地点までの間隔は $1[s]$ である。

5.2 結果

実際の走行動画から求めたオプティカルフローを示す。Fig.13, Fig.14 は走行動画内の A 地点の結果である。Fig.13 は視線を正面に向けているときの結果となっている。一方、Fig.14 は注視点を動画内の赤丸の位置に仮定したとき、赤丸の移動ベクトルを Fig.13 のオプティカルフローに反映させたときの結果である。この時、注視点の移動ベクトルはテンプレートマッチング

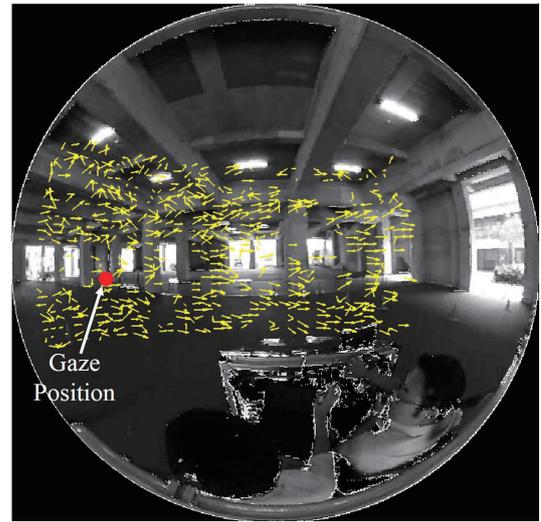


Fig. 13: Experimental result on the case1 at point A

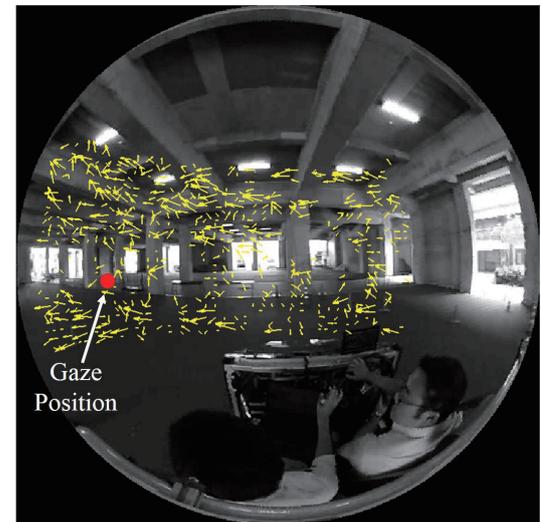


Fig. 14: Experimental result on the case2 at point A

で求めたものではなく、目視によって動画内のピクセルの移動量から角度の移動量に変換した。Fig.13 より、視線を正面に向けた時の物体の移動は全体的に右方向に動いていることがわかる。Fig.14 より、視線を注視点に向けた時の物体の動きは注視点を境に左側では物体は左方向に、注視点の右側では右方向に流れていることが読み取られる。これは、シミュレーションにおけるカーブ先に視線を向けた時の結果と似た傾向であることがわかる。

Fig.15, Fig.16 は B 地点のオプティカルフローである。Fig.15 は視線を正面に向けているときの結果となっている。一方、Fig.16 は注視点を A 地点と同じ位置に仮定したとき、赤丸の移動ベクトルを Fig.15 のオプティカルフローに反映させたときの結果である。B 地点の結果を見ると、A 地点の結果と同様に視線を正面に向けた時の物体の移動ベクトルは全体的に右方向に流れていることがわかる。しかし、注視点の移動量を物体の移動ベクトルに反映させたとき、A 地点の Fig.14 の結果と比較すると、注視点の右側にあるベクトルの中にも左方向に移動するベクトルの割合が多くなっていることが読み取られる。

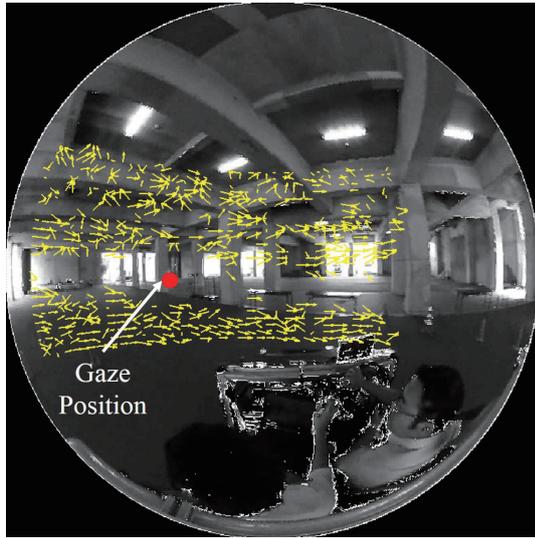


Fig. 15: Experimental result on the case1 at point B

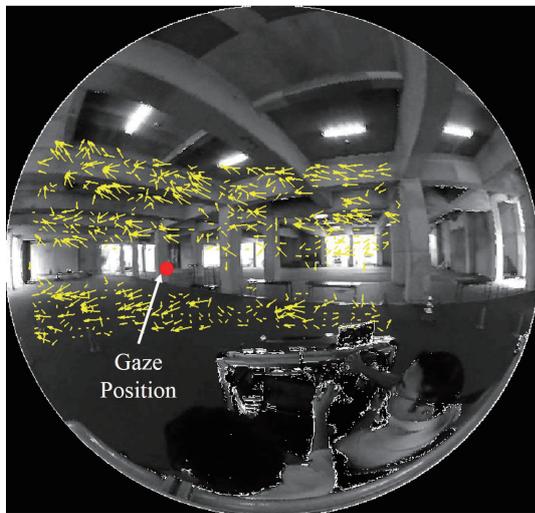


Fig. 16: Experimental result on the case2 at point B

5.3 考察

実際に旋回を行った時の走行動画を用いてオプティカルフローを算出した。A地点の画像では旋回時視線をカーブの先に向けた時と車両の正面方向に向けた時を比較した際、シミュレーションの結果と同様に視線を正面に向けた時では背景の物体が全体的に右方向に流れる傾向が、注視点の移動ベクトルを反映させたときでは注視点を基準に放射状に広がる傾向が見られた。また、B地点の結果では注視点の変化を物体の移動ベクトルに反映させたとき注視点の右側にある物体であっても移動するベクトルの割合が多くなった。

この原因として、A地点では、今回設定した注視点の位置と車両の移動方向が一致していたからであると考えられる。しかし、B地点では、今回設定した注視点の位置と車両の移動方向が一致していなかったためシミュレーションの結果と一致しなかったと考えられる。その原因として、B地点ではA地点と同じ位置を注視点と仮定したため、本来の注視点の位置よりも外側になってしまったためであると考えられる。

今回の実験では、視線を車両の正面方向に向けた時

とカーブの先に向けた時のオプティカルフローを比較した。シミュレーションの結果では、視線をカーブの先に向け視線方向に車両が移動した際、周囲の物体が放射状に広がることを示した。また、視線をカーブ先に向けていない時と比べると視線をカーブ先に向けた時では、物体の移動ベクトルの大きさも小さくなっている。

今回の実験から、旋回時にカーブの先に視線を向けるという動作は、視点中心の移動ベクトルの大きさを小さくする行為であると考えられる。そして、その視点中心に車両が移動するように人間はステアリングを制御しているのではないかと推測する。このことから、熟練者は、この注視点を適切な位置に置けているため快適な旋回を行うことができるのではないかと考える。

6 まとめ

本研究では、球面画像のオプティカルフローを旋回時の視線方向の違いによって比較を行った。球面画像のオプティカルフローを求めるため、MTLABを用いて、旋回時に視線をカーブ先に向けた時と車両の正面に向けた時の物体の動きを計算した。その結果、視線方向の違いによって物体の動きに差が生じることがわかった。次に、実際に走行することによって得られた球面画像からオプティカルフローをHoG特徴量を用いたテンプレートマッチングを行うことで算出する方法と平面画像とは異なる角度単位で画素値を指定する方法について提案した。最後に実際に撮影した旋回時の球面動画でオプティカルフローを算出し、シミュレーションと似た傾向の結果が得られることを確認した。そこから、人間は旋回の際に視線方向と車両の進行方向を一致させるために旋回時のオプティカルフローを算出しているのではないかと推測した。

今後、走行条件を見直しや走行時に今回のシミュレーションの妥当性を示す。また、テンプレートマッチング方法の改良を行うことで車両制御を行う際に使用できる精度のオプティカルフロー検出を実現する。また、その過程で球面画像のマッチングを行う際に有効な特徴量について明らかにする。

参考文献

- 1) 三浦 利章：行動と視覚的注意, p.53/p54, 風間書房 (1996)
- 2) 森 みどり, 中易 秀敏, 三好 哲也：ドライビングシミュレータとアイトラッキングシステムを用いた運転者の眼球運動と車両軌跡の同期解析, 日本機械学会論文集, 79巻-803号, p2408/p2423 (2013)
- 3) 岸田英里, 松寄直幸, 上沼研也, 繁樹博昭, 北崎充晃, 巖桂二郎：運転行動を向上させるための視覚情報制御技術に関する検討, 日本機械学会論文集, 74巻-745号, p2254/p2263 (2013)
- 4) D.D.salvucci and R.Gray : A two-point visual control model of steering, Perception, Vol.33, p1233/p1248, (2004).
- 5) N.Dalal and B.Triggs : Histograms of Oriented Gradients for Human Detection, In Proc. IEEE Conf. on Computer Vision and Pattern Recognition 2005, Vol.1, p886/p893, (2005).

天球画像のオプティカルフローを用いた物体の接近表現

○岡島恵一 増田寛之 永井祐輔 本吉達郎 澤井圭 小柳健一 大島徹 (富山県立大学)
高山英一 (高山自動車)

Explanation of Approaching Object using Optical Flow on Spherical Image

*Y. Okajima, H. Masuta, Y. Nagai, T. Motoyoshi, K. Sawai, K. Koyanagi and T. Oshima
(Toyama Prefectural University)
E. Takayama (TAKAYAMA CARS. Co., Ltd)

Abstract— In recent years, it is important for driving support systems to use cameras. The conventional method often applied the Time-To-Collision (TTC) as Control of driving support systems. However, the control method of TTC doesn't match the driver's feeling. Therefore, the driver feels uncomfortable. To correspond to a human sense, a vehicle control needs human like perception. In this paper, we use a sphere camera which is projected on the spherical coordination like a human retina. We show that an optical flow on the spherical view when a vehicle collides with an object.

Key Words: Optical Flow, Spherical Image

1 背景

近年、安全・安心な社会の実現、便利でゆとりある生活の実現のために、ロボットが生活、公共の場でより身近な存在として役立つことが期待されており、例として日産自動車株式会社は Robotic Agent (ロボティック・エージェント) や、ロボティック・インターフェースの研究を行っている。これらは走行中にロボットが話しかけたり、登録されている建物の説明を行ったりすることで楽しく運転することができる。さらに、顔画像や発話音声により運転者の状態を推定し、運転者をポジティブな状態に誘導する発話や、動作を行う¹⁾²⁾。

我々はロボットと運転支援を組み合わせることで、運転者が運転をより楽しく、かつ運転技術の向上を目指してきた³⁾。しかし、従来のロボット制御は車両の速度や、ピッチレートなどの情報のみ使用しており、車両が走行している道路や、周辺の障害物などの情報を考慮していなかった。運転者は車両周辺の環境に配慮した運転を行う必要もあるため、車両の情報だけではなく、車両が走行している環境の情報もロボット制御の入力として用いるべきである。

車両の周辺の情報を用いた運転支援技術として、先行車両従走時の衝突軽減ブレーキやアダプティブ・クルーズ・コントロール (ACC) などがある。これらの運転支援技術の制御は Time-To-Collision (TTC) が使用されている。TTC は先行車両との車間距離を相対速度で除した値であって、同一相対速度が継続した場合の先行車両へ衝突するまでの時間を表したものであり、安全性に直接関係する指標として考えられている⁴⁾。このように走行中の安全性の指標を距離ではなく、時間から推定する手法が多く使用されている。しかし、相対速度が小さい場合に車間距離が短いにもかかわらず、非常に大きな TTC をとることがある。また、TTC は先行車両が真正面にいる場合の値であるため、TTC による車両制御のタイミングと運転者のタイミングが合わないことが多い。その結果、従来の TTC による運転制御は運転者にとって違和感に繋がる⁵⁾。そのため、運転者の感覚に合った車両制御を行うために従来の TTC とは異なった入力値を用いる必要がある。そこで我々

はヒトの網膜に射影される立体角を立体角の変化で除した値である τ [s] という理論に着目した⁶⁾。ヒトは τ を用いてキャッチボールや、自動ドアをくぐり抜けるなどの行為を行っている⁷⁾。したがって、 τ の値を用いた車両制御を行うことで運転者に違和感のない運転支援ができる。

そこで我々は全天球カメラから出力される天球画像から車両と障害物が衝突するまでの時間 τ [s] を算出し、 $1/\tau$ という接近感に表現することで車両走行時のロボット制御を行う提案を行った⁸⁾。全天球カメラの射影方式は等立体角射影方式であり、ヒトの網膜に投影される光と投影される光が類似している。実験結果から運転者が走行中に認識する接近感と等立体角射影方式である全天球カメラを用いた接近感は対応していることがわかった。しかし、ピクセル数から立体角を求める場合、複数の物体の接近を表現できない。また、本来 τ とはヒトの感じる光学的流動の変化である。そのため、オプティカルフローを用いて立体角を求めることが望ましい。

したがって、本稿では HoG 特徴量を用いたオプティカルフローから障害物の立体角を求めた場合の $1/\tau$ という接近感の提案とピクセル数から立体角を求めた場合の $1/\tau$ という接近感を求めた。

2 立体角を用いた接近の情報

生態心理学とは環境の中にヒトが知覚する情報があり、ヒトと環境が相互に関係し合うことで知覚が引き起こされるという概念の心理学である⁹⁾。生態心理学において立体角の変化はヒトの視覚において重要な役割を持つ。

Fig.1 のような対象者が障害物に近付いていく場合を例に挙げる。物体の大きさを D [m]、対象者と障害物との距離を r [m]、対象者の速度 v [m/s]、対象者の網膜に投影された障害物の立体角を A [sr]、 s [s] 後の対象者と vs [m] の距離にある障害物の立体角を A' [sr]、立体角の変化率を \dot{A} [sr]、対象者と障害物が衝突するまでの残り時間を τ [s] とすると、 τ 、 A 、 \dot{A} は、

$$A = \pi \frac{D^2}{2r^2} \quad (1)$$

$$\dot{A} = \frac{A' - A}{s} \quad (2)$$

$$\tau = \frac{A}{\dot{A}} \quad (3)$$

$$1/\tau = \frac{\dot{A}}{A} \quad (4)$$

となる。式 (1), (2), (3) から対象者と障害物が接近すると、立体角は大きくなり、立体角の増加率が大きいほど τ が小さくなる。

Lee は行為者の二次元の網膜への「刺激」、そこに成立する「像」をもとにして、対象との「距離」や接近する対象の「速度・加速度」を計算しているのではなく、 τ のような環境の面の肌理の変化として存在する情報から「衝突までの時間」と「衝突の激しさ」という行為者と環境との「関係」を直接知覚しているとしている⁶⁾。 τ は立体角の変化が起きない場合、無限に発散する。そのため、本研究では式 (4) のように τ の逆数を用いて車両と障害物の接近の考察を行った。

3 運転支援を行うハードウェア

3.1 超小型電気自動車

本研究では実験車両として超小型電気自動車 (UCEV: Ultra Compact Electronic Vehicle) を使用した。Fig.2 に株式会社高山自動車と共同開発した試験車両「TORiCLE Zero」を示す。また、仕様を Table1 に示す。開発中の本車両は 2 人乗りで定格 4.5 kW の駆動モータが搭載されている。本車両は超小型モビリティ規格に準拠する車両である。本車両の特徴は、4 輪独立懸架を備え、バッテリーをシャシ下部に搭載した低重心構造となっており、より走りの気持ちよさ・楽しさを目指した構成となっている。

3.2 全天球カメラ

本研究ではリコーイメージング株式会社が開発した THETA S を用いた。THETA S は射影方式は等立体角射影方式であるため、Fig.3 のような天球画像を出力する。これは RICOH THETA S が球面に投影されている光を平面上に射影しており、カメラの光軸と入射光のなす角が大きくなっても像の面積が立体角に比例して射影されるからである。立体角は球面の表面積であるため RICOH THETA S を使用することにより、立体角を算出することができる。これにより、運転者が感じる車両と障害物が衝突するまでの残り時間 τ [s] を表現することができる。本実験における THETA S の解像度は 600×1200 であり、フレームレートは 10 fps である。

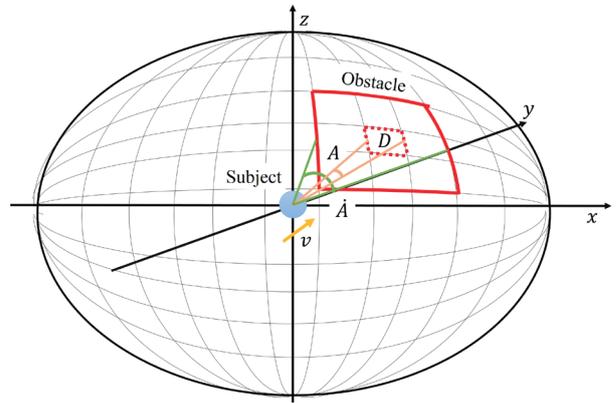


Fig. 1: The τ model of sphere image



Fig. 2: UCEV "TORiCLE Zero"



Fig. 3: The output Image of sphere camera

4 オプティカルフローを用いた立体角

天球画像を従来の画像処理のようにピクセルの値を配列に格納し、画像処理する場合、天球画像の極のピクセルが 2 つ以上の配列を格納されている。そのため、天球画像の画像処理を行う場合、直交座標系ではなく、Fig1 のように天球座標からピクセルを参照する必要がある。本研究では、THETA S を使用しており、解像度は 600×1200 である。そのため、 δ 方向は 1 pixel につき 0.3 deg、同様に α 方向も 1 pixel につき 0.3 deg

Table 1: Spec. of UCEV”TORiCLE Zero”

Overall Length	2490[mm]
Overall Width	1290[mm]
Overall Height	1680[mm]
Wheelbase	1730[mm]
Weight	500[kg]
Maximum Speed	60[km/h]
Differential Gear Ratio	7.448
Drive System	Rear-drive
Suspension	MacPherson Strut
Front Wheel Brake	Disc Brake
Rear Wheel Brake	Drum Brake
Rated Output of Motor	4.5[kW]
Battery	Lead Storage Battery 12V/42Ah × 6 Lead Storage Battery 12V/28Ah × 1

となる。また、直交座標系における $(x,y)=(300,600)$ は天球座標系における $(\alpha,\delta)=(0,0)$ となる。

天球画像のオプティカルフローから立体角を求める場合、HoG 特徴量を用いたオプティカルフローからピクセルの移動量を算出した¹⁰⁾。

そのため、HoG 特徴量を算出するための輝度勾配やオプティカルフローのピクセルのマッチングは角度単位のピクセル数を参照して計算を行った。

その後、立体角は Fig.4 のように移動したピクセルの終点の中でも座標の端に位置するピクセルを繋いでいく凸包処理から求めた。凸包処理は包装アルゴリズムを使用している。

終点を凸包処理をした立体角と始点を凸包処理をした立体角の差分から立体角の変化率が算出できる。これにより、 $1/\tau$ という接近感の表現を行うことができる。

5 走行実験

5.1 実験目的

天球画像のピクセル数から立体角を求めた場合の接近表現を算出し、障害物と走行車両が接近した時の運転者の感じる接近が表現できているか考察を行った。また、立体角を求める最初の手順として HoG 特徴量を用いたオプティカルフローを算出した。

5.2 実験方法

実験方法として走行動画を全天球カメラで取得し、その天球画像から障害物の立体角を算出することで $1/\tau$ という表現を求めた。走行動画は Fig.6 のように車両が障害物に近付いていき、車両と障害物が衝突した時の走行を使用した。障害物は白く塗った段ボールを 1.5 m まで積み上げ、カメラと同じ高さの位置に赤の画用紙を貼った。走行前の車両と障害物の距離は 30 m である。

天球画像のピクセル数から立体角を求める場合、天球画像の HSV から赤色検出を行った。全天球カメラから出力される天球画像内の障害物の面積は立体角として扱うことができる。そのため、天球画像の赤色のピ

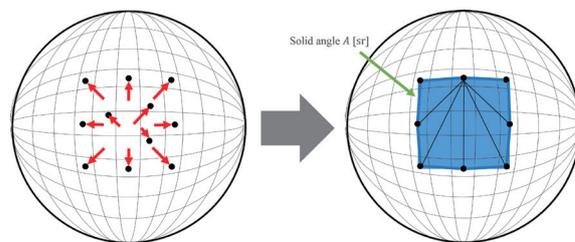


Fig. 4: Convex hull algorithm

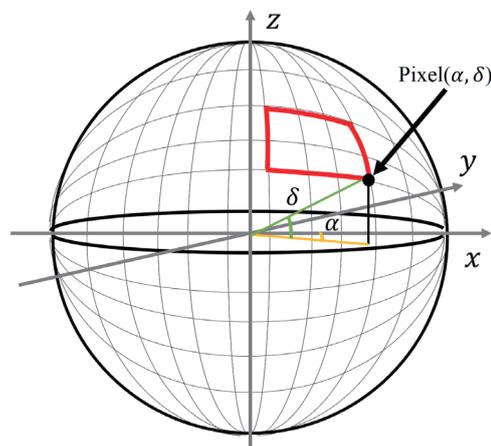


Fig. 5: Projection into sphere coordination

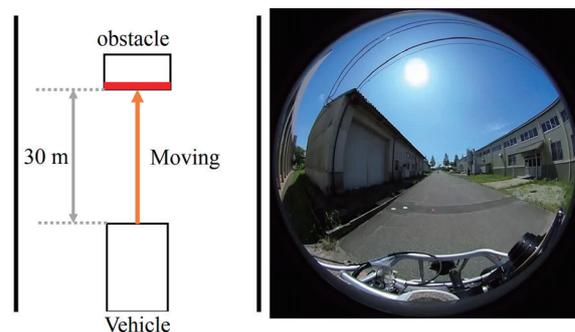


Fig. 6: Experimental Environment

クセル数を立体角 A とおき、その微分を \dot{A} とおくことで、 $1/\tau$ という接近感の表現を行った。

また、天球画像のオプティカルフローから立体角を求める予備実験として、HoG 特徴量を用いたオプティカルフローからピクセルの移動量を算出した。

5.3 実験結果

超小型電気自動車に障害物に衝突した時の車両のアクセル開度、車両速度を Fig.7 に示す。アクセル開度を 80 % まで上昇させ、速度を上げる。そして、速度を最大 21 km/h まで上げた。その後、運転者は速度一定にすることを意識して車両が障害物に接近した。

Fig.8 は車両が障害物に衝突した時を 0 s とした時間と $1/\tau$ という表現の関係を示している。車両と障害物が衝突した後、障害物はカメラに向かって倒れた。ピクセル数から立体角を算出した場合、障害物に衝突する時間に近付くにつれて $1/\tau$ という表現が大きくなっている。

Fig.9, 10, 11, 12 はそれぞれ車両と障害物が衝突する 2.0 s 前, 1.0 s 前, 0.5 s 前, 衝突時の HoG 特徴量を用いたオプティカルフローを表している。どの時間においても物体が流れていく方向にオプティカルフローが算出されている。また、衝突する 1.0 s 前から障害物の上端のオプティカルフローが算出されていない。これはマッチング精度が低い可能性や、フローを算出するためのピクセル探索が行われていない可能性がある。今後、マッチング精度の向上させ、立体角の変化率を出力できるよう改善を行う必要がある。

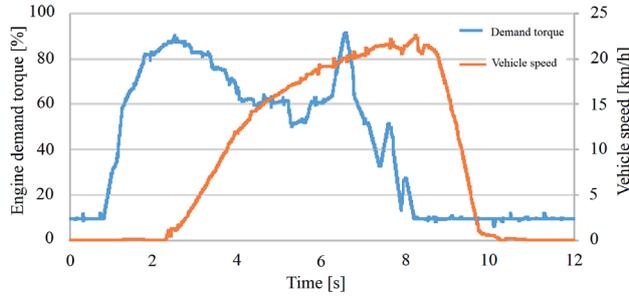


Fig. 7: measurement data

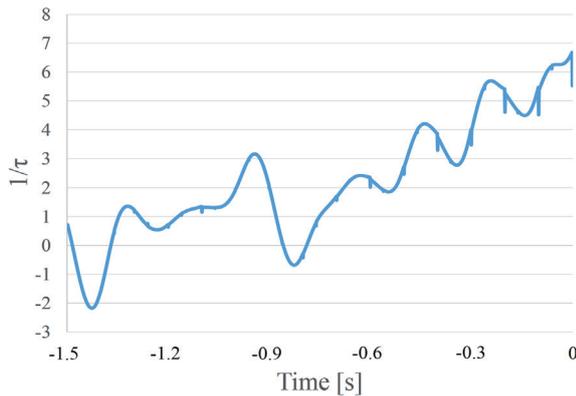


Fig. 8: Explanation of approaching object



Fig. 9: Before 2.0 s



Fig. 10: Before 1.0 s



Fig. 11: Before 0.5 s



Fig. 12: Collision

6 まとめ

本研究では、運転者がより安全に車両を運転できるようにロボットによる運転支援を行う提案をした。本稿では光学的流動の変化に着目し、オプティカルフローを用いた車両と障害物の接近感の表現を行い、ピクセル数から立体角を求めた場合の接近感の表現との比較を行った。実験結果から、オプティカルフローから立体角を求めた場合はピクセル数から立体角を求めた場合よりも早く接近感が表現できた。そのため、全天球カメラの解像度とマッチング精度を上げることにより、十分ロボットによる運転支援のための制御を行えると考えられる。今後の展望として、マッチング精度を向上させて全天球カメラを用いたロボット制御を開発し、実際に運転者の走行中にロボットによる運転支援を行う。

参考文献

- 1) 日産株式会社, "Robotic Agent(ロボティック・エージェント)", http://www.nissan-global.com/JP/TECHNOLOGY/OVERVIEW/robotic_agent.html
- 2) 日産株式会社, "ロボティック・インターフェース", <http://www.nissan-global.com/JP/TECHNOLOGY/OVERVIEW/ri.html>
- 3) Yoshikazu Okajima, Hiroyuki Masuta, Toru Oshima, Ken'ichi Koyanagi, Tatsuo Motoyoshi, Eiichi Takayama, "The Inference of Robot Utterance Timing based on Vehicle Acceleration Condition", 2016 Joint 8th International Conference on Soft Computing and Intelligent Systems and 2016 17th International Symposium on Advanced Intelligent Systems, pp.299-304, 2016.
- 4) David N Lee: A theory of visual control of braking based on information about time-to-collision, Perception, Vol.5, pp. 437-459, 1976
- 5) 森田 和元, 大野 督史, 関根 道昭, "Time-To-Collision はブレーキ操作タイミングを決定するか", 第 4 回 ITS シンポジウム 2005, P2-5, 2005
- 6) 乾 敏郎, 竹市 博臣, 野澤 晨, 津崎 実, 森 晃徳, 行場 次朗, 吉川 左紀子, 横澤 一彦, 積山 薫, 今水 寛, 河合 優年, 佐々木 正人, "認知心理学 I 知覚と運動", pp. 276-279, 東京大学出版会, 1995
- 7) 三嶋 博之, "エコロジカル・マインド 知性と環境をつなぐ心理学", pp. 158-172, 日本放送出版協会, 2000
- 8) 岡島 恵一, 増田 寛之, 本吉 達郎, 澤井 圭, 小柳 健一, 大島 徹, "全天球カメラを用いた車両走行時における物体の接近に関する考察", 第 32 回ファジィシステムシンポジウム 講演論文集, pp.675-680, 2016.
- 9) James J. Gibson, "生体心理学的視覚論 ヒトの知覚世界を探る", サイエンス社, 1991
- 10) N.Dalal, B.Triggs, "Histogram of Oriented Gradients for Human Detection", In Proc. IEEE Conf. on Computer Vision and Pattern recognition 2005, Vol. 1, pp. 886-893, 2005

探索点の移動方向からみた PSO と FA の比較

○肖恒, 大井允人, 畠中利治 (大阪大学)

Comparison between PSO and FA about Agent's Moving Direction

* H. Xiao, M. Oi, and T. Hatanaka (Osaka University)

Abstract— Optimization problems have been focused on for so many years. Some smart solving methods have been thought out for them. Swarm intelligence algorithm have been developed as one of these methods. There are so many famous swarm intelligence algorithms such like particle swarm optimization and firefly algorithm. Since their dynamics models are different, we focused ourselves on the position changing while agents moving. In this paper, we will discuss on the difference between an actual moving vector of swarm model and the gradient of the objective function. Some experimental results are shown and discuss on the feature of each swarm model.

Key Words: Swarm Intelligence, Particle Swarm Optimization, Firefly Algorithm, Function Optimization Problems, Gradient Method

1 Introduction

Complex optimization problems have attracted so many researchers for dealing them in lots of years. To these optimization problems, people thought thousands of ways to solve them. And it is known that Computational intelligence^{1, 2, 3)} is a great thought that can help us to deal with real problems around our actual world modeled as function optimization problems. As specific applications of computational intelligence, some kinds of nature-inspired algorithms have been developed in this two decades such like the swarm intelligence algorithm^{4, 5, 6)}. There are numerous ideas about the swarm intelligence algorithms like: particle swarm optimization (PSO)⁷⁾, firefly algorithm (FA)^{8, 9)}, brain storm optimization (BSO)¹⁰⁾, cuckoo search¹¹⁾, bat algorithm^{12, 13)}, artificial bee colony (ABC)^{14, 15)} and so on.

There are so many swarm intelligence algorithms. They performed different for solving different optimization problems. And the algorithms can also performed different among themselves. Since the algorithms have different properties, it will be important to know the differences between them. In our research, we focus on the agents' movements while the algorithm running.

For swarm intelligence algorithms, agents will follow the inherent dynamics models to move in the search space. Their moving vector will be changed through some rules in every iteration. So we paid attention to that it is important to research on how the agents moving. And through the gradient of the objective function, we can compute and analysis the agent's moving vector and the true gradient, then it will help us understand how the agents changing moving directions.

2 Swarm intelligence

2.1 Particle Swarm Optimization (PSO)

In PSO, particles which were used in the algorithm were randomly placed in the search space. For computing the optimum of the problem, we should let the particles moving with a variable speed (step size). Moreover, each particle will compare its current position with its best position so far. Then, the agent will memorize its best position. Through numerous

iterations, agents will memorize their best position and communicate with each other. Then we will get the global optimum.

In the PSO algorithm, every agent's current best value p_{best} was renewed in every step. At the same time, the swarm's optimum g_{best} was also renewed with agents' communication. And the velocity of agents would also change with the time.

PSO's update equations were defined as follow:

$$\begin{cases} v_i^{t+1} = wv_i^t + c_1r_1(p_{best}^t - x_i^t) + c_2r_2(g_{best}^t - x_i^t) \\ x_i^{t+1} = x_i^t + v_i^{t+1} \end{cases} \quad (1)$$

Where, w is an inertia weight, c_1 , c_2 are constants, r_1 , r_2 are randomly selected from the uniform distribution over $[0,1]$. v_i^t is the velocity of particle i at t time, while v_i^{t+1} is the velocity at $t+1$ time.

2.2 Firefly Algorithm (FA)

FA is an efficient swarm intelligence algorithm which was developed by Xin-She Yang. This algorithm simulates the flashing behavior of fireflies. In the nature, fireflies can flash when they moving so that they can communicate with each other for finishing some work.

When the firefly flashing, its intensity will attract others to come together. When researchers applied this behavior to solve the complex optimum problems, they found that it was good at searching method for finding global optimums.

When the algorithm start, agents will be placed in random locations (not beyond the limit range). Compare their intensity then move the agent which is less bright to the brighter one. It should be considered that the brightness will be changed with the distance r_{ij} . So attractiveness would be varied. The attractiveness will be changed base on the distance between agent i and j .

FA's update equation was proposed as below:

$$x_i^{t+1} = x_i^t + \beta e^{-\gamma r_{ij}^2} (x_j^t - x_i^t) + \alpha \varepsilon_t \quad (2)$$

Where α is a parameter controlling the step size. ε_t is a vector. γ is the absorption coefficient.

3 Numerical Experiments

For get to know how the agents moving with different dynamics models, we did the test with PSO and FA for some minimum optimization problems. In which we will record the angles between actual moving vector and theoretical moving vectors for all the agents. And we also compute the minimum angle value, medium value and the maximum value. All the data will be shown in the results.

There are some functions that we used for test. Their models will be shown as below.

- Sphere function

$$f_{sp}(x) = \sum_{i=1}^d x_i^2 \quad (3)$$

- Branin function

$$f_{br}(x) = a(x_2 - bx_1^2 + cx_1 - r)^2 + s(1 - t) \cos(x_1) + s \quad (4)$$

- Shubert function

$$f_{sh}(x) = \left(\sum_{i=1}^5 i \cos((i+1)x_1 + i) \right) \left(\sum_{i=1}^5 i \cos((i+1)x_2 + i) \right) \quad (5)$$

The results were shown as below. There are two figures for each function test with PSO or FA. In one figure (fig. 1-1, 2-1, 3-1, 4-1, 5-1, 6-1) it's shown that all agents' mean angle value in 50 implement times. In another figure (fig. 1-2, 2-2, 3-2, 4-2, 5-2, 6-2) it's shown that the minimum, medium, maximum value of the agents' mean angle values. The horizontal axis means generation times, while the vertical axis means the angle value.

Table 1 Parameter setting

Parameter Setting
Agent numbers: 100
PSO parameter: $c_1=1.4, c_2=1.4, w=0.7$
FA parameter: $\alpha=0.01, \beta=1.0, \gamma=0.05$
Iteration numbers: 50
Implement times: 50
Dimension: 2
Search space range: $[-5, 15]$

From the test result, we can see that in the result of PSO, agents' angles were so different in each implement time. While in the result of FA, agents' angles distribution is so similar in every time. For in PSO, agents' mean angle values were so different distributed. We thought about explanations for these. We thought that for the FA, agents can move with

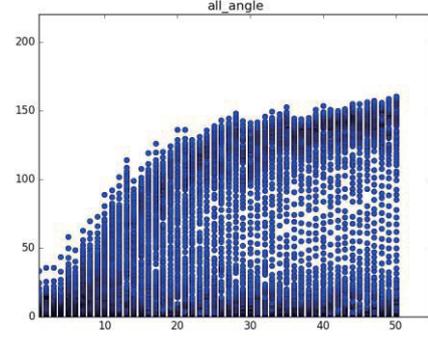


Fig.1-1: All agents' angles in PSO for Sphere function.

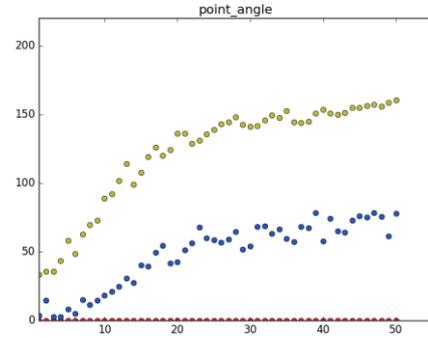


Fig.1-2: Minimum, medium, maximum value of the angles in PSO for Sphere function.

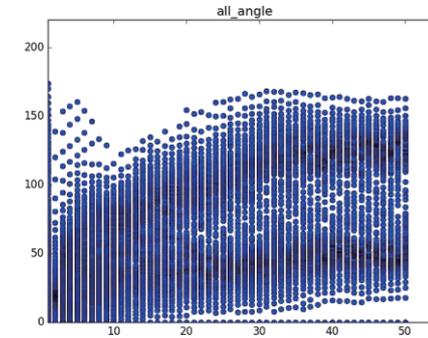


Fig.2-1: All agents' angles in PSO for Branin function.

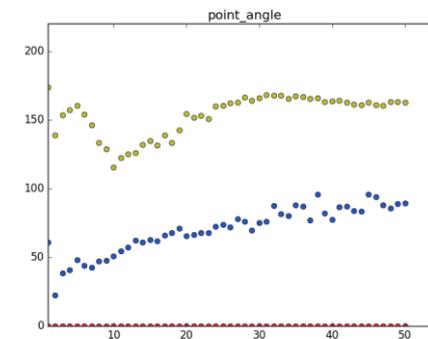


Fig.2-2: Minimum, medium, maximum value of the angles in PSO for Branin function.

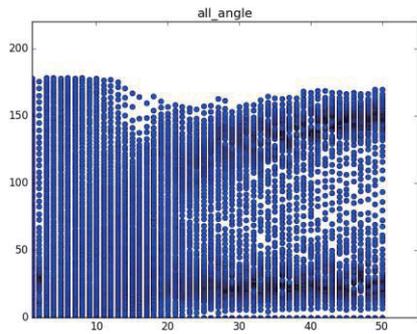


Fig.3-1: All agents' angles in PSO for Shubert function.

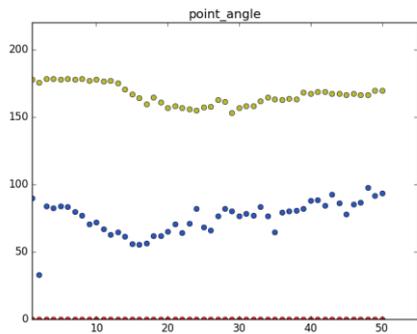


Fig.3-2: Minimum, medium, maximum value of the angles in PSO for Shubert function.

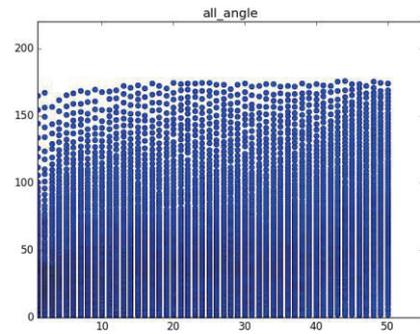


Fig.5-1: All agents' angles in FA for Branin function.

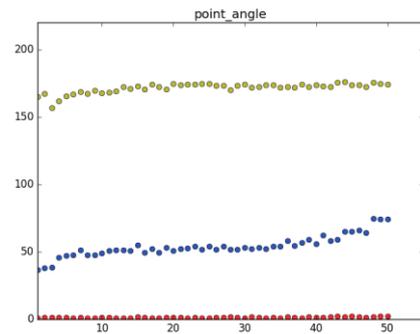


Fig.5-2: Minimum, medium, maximum value of the angles in FA for Branin function.

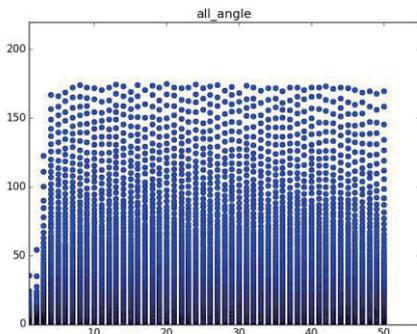


Fig.4-1: All agents' angles in FA for Sphere function.

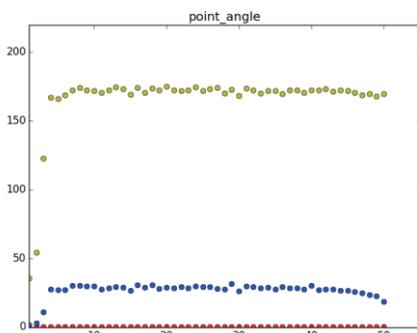


Fig.4-2: Minimum, medium, maximum value of the angles in FA for Sphere function.

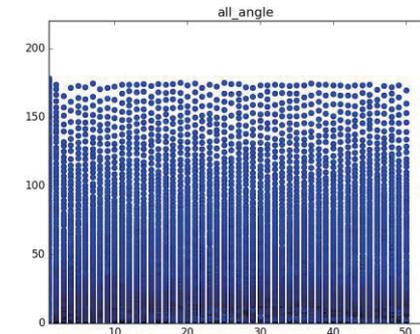


Fig.6-1: All agents' angles in FA for Shubert function.

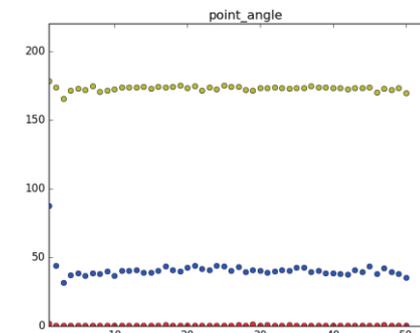


Fig.6-2: Minimum, medium, maximum value of the angles in FA for Shubert function.

dramatic changed moving direction. There can even exist opportunities for the agent to moving with an opposite direction. So in the FA model, agent's moving direction can be changed in a large range. While in the PSO model, agent will moving basing on the personal best position and global best position. So the agent's moving direction will be changed in a limit range. For PSO agents, they would do oscillations while they searching for the optimums. So the agent's angle values be distributed so different.

4 Conclusion

Either PSO or FA are also typical swarm intelligence models. We focus on the property differences between these two algorithms and interested in find some interesting things with debating on the agents' moving behaviors. Gradient method helps us to figure out the differences of agents' moving direction between PSO and FA. Through some tests about the minimum optimization problems, we show the differences between PSO and FA.

In this paper, we showed the differences about the agent's moving direction changing between PSO and FA. But we still need to figure out the specific reasons and provide out thoughts. There are still lots of things that we need to do in the future. Since the differences of the dynamics models, we will try more tests for finding other differences. About our future work, we will try other ways like changing swarm structures to figure out how these the swarm effect the agents' movements. And we also interested in how the different models work with each other.

Acknowledgements

The first author is supported by JPSS Program for Leading Graduate Schools and this work is partially supported by JPSS KAKENHI Grant number 15K00338.

References

- 1) J. C. Bezdek: What is computational intelligence?, *Computational Intelligence Imitating Life*, 1–12, IEEE Press, New York, (1994)
- 2) A. Konar, *Computational Intelligence: Principles, Techniques and Applications*, Springer, 1/35 (2005)
- 3) S.H. Chen, P. Wang, and P.P. Wang: Computational Intelligence in Economics and Finance, *Computational Intelligence in Economics and Finance*, Springer, 3/55 (2006)
- 4) S. Das, A. Abraham, and A. Konar: *Swarm Intelligence Algorithms in Bioinformatics*, Springer, 113/147 (2008)
- 5) B. K. Panigrahi, Y. Shi, and M.-H. Lim (eds.): *Handbook of Swarm Intelligence. Series: Adaptation, Learning, and Optimization*, Springer (2011)
- 6) C. Blum and D. Merkle (eds.): *Swarm Intelligence – Introduction and Applications*, Springer (2008)
- 7) Kennedy, J.; Eberhart, R.: "Particle Swarm Optimization". *Proceedings of IEEE International Conference on Neural Networks*. IV. 1942/1948 (1995)

- 8) Yang X.: Firefly algorithms for multimodal optimization, *Stochastic algorithms: foundations and applications*, Springer 169-178 (2009)
- 9) Tilahun S. and Ong H.: Modified firefly algorithm, *Journal of Applied Mathematics*, 1/12 (2012)
- 10) Y. Shi: "Brain storm optimization algorithm," *Proceedings of 2nd International Conference on Swarm Intelligence*, 303/309 (2011)
- 11) V. Bhargava, S.E.K. Fateen, and A. Bonilla-Petriciolet.: Cuckoo search: A new nature-inspired optimization method for phase equilibrium calculations, *Fluid Phase Equilibria*, 191/200 (2013)
- 12) Xin-She Yang: Bat algorithm: literature review and applications, *International Journal of Bio-Inspired Computation*, Vol. 5, No. 3, 141/149 (2013)
- 13) Du, Z. Y., Liu B.: Image matching using a bat algorithm with mutation, *Applied Mechanics and Materials*, Vol. 203, No. 1, 88–93 (2012)
- 14) B. Basturk, D.Karaboga: An Artificial Bee Colony (ABC) Algorithm for Numeric function Optimization, *Proceedings of IEEE Swarm Intelligence Symposium 2006* (2006)
- 15) C. Xu, and H. Duan: Artificial bee colony (ABC) optimized edge potential function (EPF) approach to target recognition for low-altitude aircraft, *Pattern Recognition Letters*, 1759/1772 (2010)

マルチモーダル深層自己符号化器における モダリティ間パラメータ共有の検討

○佐々木勇人 中田雅也 濱津文哉 濱上知樹 (横浜国立大学)

Investigation of parameter sharing among multimodal deep autoencoders

*H. Sasaki, M. Masaya, F. Hamatsu and T. Hamagami (Yokohama National University)

Abstract— Deep Learning has high potential to learn complicated representation and can be applied to multimodal representation learning. In previous studies of multimodal deep learning, the strategy of sharing neurons among modalities is generally used. However, the neuron sharing strategy is mainly intended to learn common features among modalities and has risk to ignore modality specific features. In this study, we employ the strategy of sharing parameters of deep autoencoders in order to get both common features and modality specific features. Our experiments investigated properties of parameter shared multimodal deep autoencoders.

Key Words: Multimodal, Deep learning, Autoencoder

1 はじめに

IoT 技術の発展に伴い, Cyber Physical System(CPS)¹⁾ に代表されるデータ駆動型社会への期待は年々高まっている。CPS は実世界の振る舞いを最適化することを目的とするが, そのためには観測データからシステムの状態を自律的に推測することが必要不可欠である。本研究では自律的な状態推定のために, 深層自己符号化器 (Deep Autoencoder)²⁾ を利用して観測データの特徴抽出を行う。

システムの状態推定において問題となるのが不完全知覚であり, 本研究では複数種類のセンサから取得したデータ (マルチモーダルデータ) によってこれを回避する。マルチモーダルデータを用いた深層学習としては Multimodal Deep Autoencoder³⁾ や Multimodal Deep Boltzmann Machine⁴⁾ といった手法が研究されてきた。しかしながら, これらの研究はモダリティ間で共通する特徴の抽出に重きが置かれており, 不完全知覚を回避するような相補的な特徴抽出には向いていない。加えてマルチモーダルデータの同期が取れているという前提で学習が行われており, 複数種類のセンサから取得されるデータを用いて特徴を抽出しようとする場合には利用できる状況が限られてしまう。

相補的な特徴抽出および非同期的なマルチモーダルデータを用いて特徴抽出を行う深層学習の手法として, モダリティ間でネットワークの重みパラメータを共有するという方法と, パラメータ共有の有無に基づいて, 獲得された特徴空間の比較検討を行った。

2 関連研究

マルチモーダルデータを用いた深層学習 (マルチモーダル深層学習) の研究では各モダリティに対応するネットワーク間で特徴ベクトルに対応する層を共有する手法が取られている。Ngiam らの研究³⁾ では, 各モダリティに対応する Deep Autoencoder においてエンコーダの最上位層を共有し, Srivastava らの研究⁴⁾ では, 各モダリティに対応する Deep Boltzmann Machine の最上位層を共有するというネットワークが用いられている。

これらの手法はモダリティ間で共通する特徴を抽出

する際には有効であるが, 共通の特徴ばかりが優先的に学習されてモダリティに特有の特徴が獲得されない危険性が Shu らの研究⁵⁾ で指摘されている。観測データから何らかのシステムの状態を推定する場合にはモダリティ毎の観測が不十分であることも考えられ, そうした場合にはモダリティ間で共通する特徴だけでなく, モダリティ特有の特徴も獲得することが求められる。

モダリティ特有の特徴も同時に学習する方法として Ngiam ら³⁾ は訓練データの augmentation を提案している。具体的には元の2つのモダリティ X, Y からなるマルチモーダルデータセット $\{X, Y\}$ に対して, $\{X, 0\}, \{0, Y\}$ を加えたものを訓練データとする方法である。

しかしながら, 以上のようなモダリティ間で層を共有するという手法は, 訓練時もしくはテスト時にマルチモーダルデータが同期のとれた状態で取得できるということを前提にしているため, 利用できる状況が限られてしまう。

マルチモーダル学習と関連性の高い研究分野に転移学習もしくは domain adaptation が挙げられる。これらの研究分野では, ソースドメインで学習した結果をターゲットドメインで効率的に再利用するための方法が研究されている。特にソースドメインとターゲットドメインで特徴空間が異なる, すなわち, モダリティが異なる場合には Heterogeneous domain adaptation と呼ばれ, ソース及びターゲットドメインの特徴空間を共通の潜在空間へ写像する問題に帰着される。

ソースドメインとターゲットドメインを区別せずに考えると, マルチモーダル学習はドメイン間の双方向の転移と捉えることもでき, Heterogeneous domain adaptation の研究から得られる知見はマルチモーダル学習に置いて非常に有用である。

従来の研究では潜在空間への非線形写像としてカーネルを利用することが一般的であったが, 近年では Deep Neural Network(DNN) を利用した非線形写像の学習を扱う研究も増えてきている。Heterogeneous domain adaptation を扱った深層学習の研究で, Shu らはモダリティ間で特定の層のニューロンを共有する “Representation Sharing” な手法に対し, モダリティ間で特定の

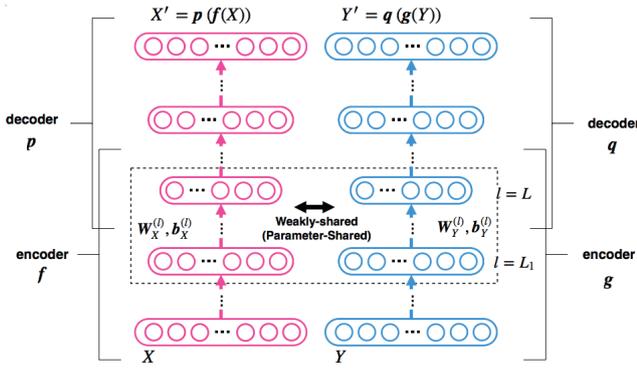


Fig. 1: Weakly-shared Deep Autoencoder. Parameters (such as weights and bias) are shared among networks.

層の学習パラメータを共有する“Parameter Sharing”な手法を提案している⁵⁾。

特に、学習パラメータを完全に共有するのではなく、ある程度の差異を許してパラメータ共有を行う“Weakly Shared”な手法を用いることで、モダリティ間で共通の特徴と各モダリティに特有の特徴の双方を捉えることができ、パラメータを完全に共有する“Strongly Shared”な手法と比べて柔軟な表現が可能になることを実験で示している。

3 提案手法

本研究では、モダリティ間で共通する特徴だけでなく、モダリティ特有の特徴も学習することを目的としている。そこで、本研究では weakly shared な手法に基づいてマルチモーダル深層学習を行い、各モダリティが相補的な役割を担うような特徴抽出を行う。

ただし本研究は教師なし学習により特徴空間を構築する点が、weakly shared な手法を提案している Shu らの研究とは異なっている。Shu らの研究ではラベルが十分に与えられているモダリティからラベル数が不十分なモダリティへとラベルを転移させることを目的としており、特徴抽出に重点を置いた研究ではなかった。

Fig. 1 のモデルは2つのモダリティ X および Y に対応する Deep Autoencoder に Weakly Shared な手法を適用することで各モダリティの特徴空間を学習することを目指しており、次式の目的関数により最適化する。

$$\min_{\Theta} \sum_{i=1}^{N_X} \mathcal{L}(x_i, p(f(x_i))) + \frac{\lambda}{2} \sum_{l=L_1+1}^L \|\theta_X^{(l)} - \theta_Y^{(l)}\|_F^2 \quad (1)$$

$$\min_{\Theta} \sum_{j=1}^{N_Y} \mathcal{L}(y_j, q(g(y_j))) + \frac{\lambda}{2} \sum_{l=L_1+1}^L \|\theta_X^{(l)} - \theta_Y^{(l)}\|_F^2 \quad (2)$$

ただし、 $\{x_i\}_{i=1}^{N_X}, \{y_j\}_{j=1}^{N_Y}$ はモダリティ X, Y から取得される訓練データセットであり、 $\theta_X^{(l)}, \theta_Y^{(l)}$ はモダリティ X と Y それぞれのネットワークにおける l 層目の学習パラメータであり、 L_1+1 層から L 層 (エンコーダの最上位層) のパラメータを共有する。また、 f と p がモダリティ X に関する Deep Autoencoder のエンコー

ダ及びデコーダ、 g と q がモダリティ Y に関する DAE のエンコーダ及びデコーダ、そして $\lambda (\geq 0)$ が重み行列の共有度合いを調整するためのハイパーパラメータである。 $\mathcal{L}(a, b)$ は再構築誤差を計算する関数であり、クロスエントロピーや二乗誤差が用いられる。

なお、提案手法の目的関数は各モダリティごとに再構築誤差を最小化しているため、マルチモーダルデータを同期した状態で与える必要性がないモデルになっている。

3.1 パラメータ共有の解釈

ソースドメインで学習した DNN の特定層のニューロンが、ターゲットドメインに対してどの程度転移可能かを調査した Jason らの研究⁶⁾ では、上位層のニューロンがソースドメインに対して特化してしまうことでターゲットドメインでの学習器の性能が低下することが指摘されている。一方で、DNN における上位層のニューロンは下位層のニューロンに比べてより抽象的な概念を表現することが知られている。

したがってマルチモーダルデータを利用して特徴抽出を行う場合には、上位層の学習パラメータをモダリティ間で完全に共有することにより、モダリティ間の差異を吸収した共通の概念の獲得が期待される。この共通概念の獲得は、共通のタスクを達成するために有効である。

本研究では不完全知覚回避のためにモダリティ特有の特徴も学習する必要があるため、Weakly Shared な手法によりモダリティ特有の特徴とモダリティに共通の特徴の双方を表現する。

加えて上位層のパラメータ共有は、各モダリティの特徴空間に形成される低次元多様体の構造を近づける操作と捉えることもできる。

DNN における全結合層の重み行列が正則で、かつ、活性化関数が定義域内で単射である場合、各層は同相写像であり、DNN 全体の表現する写像も同相写像となる。特に、Deep Autoencoder は同相写像を繰り返しながら入力データの低次元表現を獲得することから、高次元空間に埋め込まれた低次元多様体を学習しているといえる。

DNN 各層の同相写像によって、位相を保ちながら多様体の変形を繰り返すことを考えた場合、後半の写像ほど多様体の最終的な構造に与える影響は大きいと予想される。この予想のもと、Deep Autoencoder のエンコーダ上位層の写像を共有することによってモダリティ毎の特徴空間における多様体の構造を互いに近づける。

不完全知覚の影響を受けると各モダリティの成す多様体の位相が崩れてしまうため、多様体の構造を互いに近づけることによって、崩れてしまった位相を修正することを狙っている。

4 実験

本稿ではマルチモーダル深層学習による特徴抽出において、Weakly Shared なパラメータ共有がどの程度有効であるかを確認するために、手書き数字画像を用いた特徴抽出の実験を行った。提案手法が不完全知覚の回避に有効に働くかを確認するため、本実験では手書き数字画像の左半分にはノイズを付加した画像および右半分にはノイズを付加した画像をそれぞれモダリティと

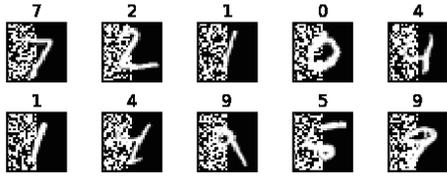


Fig. 2: Examples of modality 1 (left noised images).

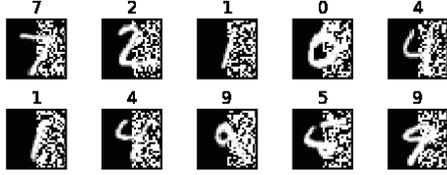


Fig. 3: Examples of modality 2 (right noised images).

みなして特徴抽出を行う。さらに、深層学習によって獲得された特徴空間上で SVM を用いた教師あり学習を行うことで、特徴空間の評価を行った。

4.1 実験設定

手書き数字画像データセットには MNIST を用いた。MNIST の各画像は $28 \times 28 = 784$ 次元であり、画素値は 0~1 の値を取るように正規化されている。その画像に対して左半分、右半分にノイズを付加したものをそれぞれモダリティ1、モダリティ2として使用した。ノイズは各画素に対して 50% の確率で画素値を 1 に置き換えるというもので、実験で使用したマルチモーダルデータは Fig. 2, 3 のとおりである。

DNN を学習する際のデータセットの内訳は、各モダリティに対して、訓練データが 55,000 枚、テストデータが 10,000 枚、学習時の目的関数評価に使う検査用データが 5,000 枚である。

さらに DNN および SVM のハイパーパラメータは Table1, Table2 のとおりである。なお、DNN の各層には Batch Normalization⁷⁾ を適用しており、学習の高速化および学習の安定性の向上を図っている。本稿の実験では、エンコーダの最上位層 (全結合層および Batch Normalization 層) においてパラメータの共有を行った (Fig. 4 参照)。

実験に用いたネットワーク構造は、モダリティごとに $784 \rightarrow 1000 \rightarrow 1000 \rightarrow 1000 \rightarrow 2 \rightarrow 1000 \rightarrow 1000 \rightarrow 1000 \rightarrow 784$ となっており、中間層のニューロン数を入力層より大きく設定することで、ノイズによって混ざり合ってしまった数字を分離することを狙っている。

4.2 実験結果

提案手法により学習した特徴空間における手書き数字分類の正解率は Table 3 のとおりである。モダリティ1, モダリティ2 に対する正解率を見ると、それぞれ $\lambda = 1.0e - 7$, $\lambda = 1.0e - 8$ で最大値となった。モダリ

Table 1: Hyper parameters for DNNs.

learning rate	1.0e-2
mini-batch size	500
epochs	100
activation function(Encoder)	ReLU
activation function (Decoder)	Sigmoid
loss function	Cross Entropy

Table 2: Hyper parameters for SVM.

C (Penalty for error term)	10000
kernel	RBF
γ (Kernel coefficient for RBF)	1.0/num of features

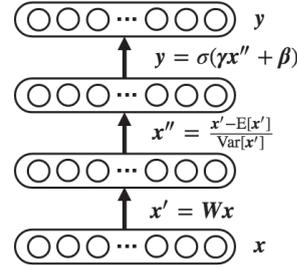


Fig. 4: Encoder unit with Batch Normalization layer. W , γ , β are shared among modalities.

ティ1 において $\lambda = 1.0e - 7$ で最大正解率を達成したあとは、 λ の値が大きくなるほど正解率が低下している。特に $\lambda = 1.0e - 5$ における正解率は $\lambda = 0$ の場合と比較して 10 ポイント低下した。モダリティ2 に関しても λ の値を大きくしすぎると正解率が低下した。

Fig. 6, 7, 8 は DNN を学習時にパラメータ W , β , γ の共有度合いがどのように変化していったかを表している。この結果を見ると、どの λ の値に対しても β , γ の共有度合いは強い一方で W の共有度合いは λ の値に対して大きく影響を受けている。 W に注目すると $\lambda = 1.0e - 6$ および $\lambda = 5.0e - 6$ の場合にはモダリティ間のパラメータの差異が徐々に小さくなっている。この場合、 β , γ 含めすべてのパラメータが強力に結びつきながら学習が進んでおり、目的関数最小化の際の解探索が十分に進まない。さらに、Fig. 5 の結果を見ると $\lambda = 1.0e - 5$ においてクロスエントロピーの値が学習途中で上昇を始めていることが確認できる。

以上のことから、パラメータの共有度合いを大きくしすぎることによって獲得される特徴空間に負の影響を与えてしまうことが推測される。パラメータ共有によって不完全知覚の影響を緩和するためには適切に λ の値を調整する事が必要である。

5 おわりに

本稿では各モダリティに対応する Deep Autoencoder に罰則項を追加することで、モダリティ間におけるパラメータ共有を行い、不完全知覚の緩和に有効に働くかを検証した。提案手法のハイパーパラメータである

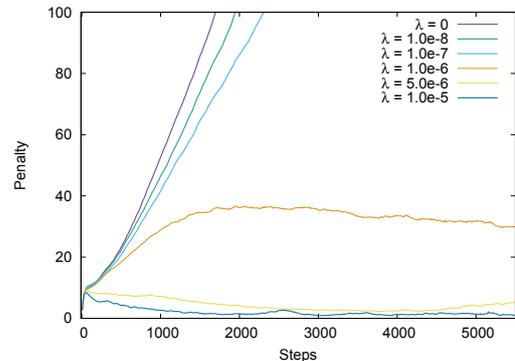


Fig. 6: Regularization term of $\|W_X - W_Y\|_F^2$

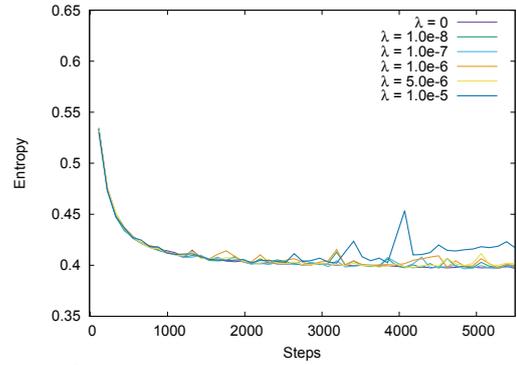
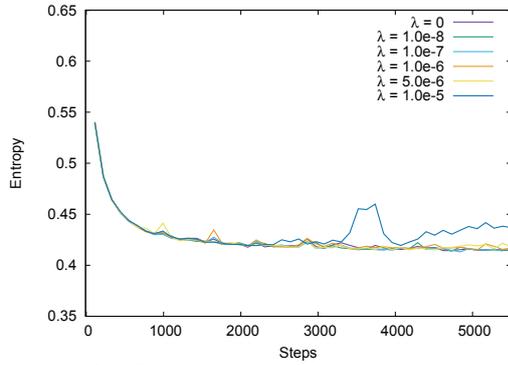


Fig. 5: Left: Cross entropy of modality 1(left images). Right: Cross entropy of modality 2(right images).

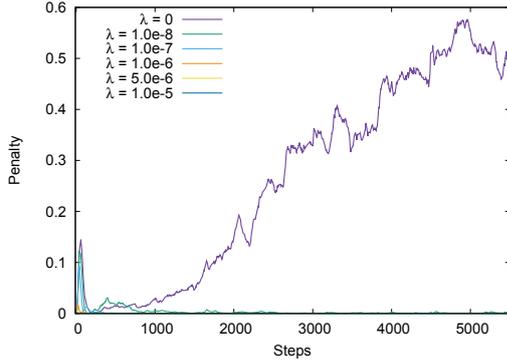


Fig. 7: Regularization term of $\|\beta_X - \beta_Y\|_2^2$

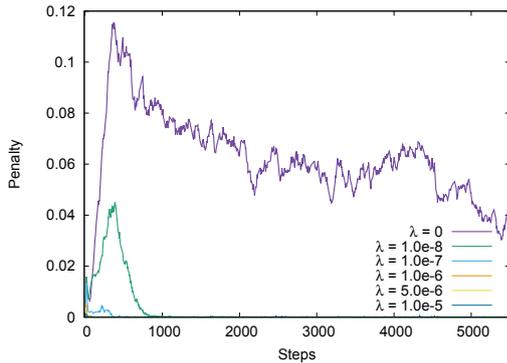


Fig. 8: Regularization term of $\|\gamma_X - \gamma_Y\|_F^2$

λ の値を適切に設定することで不完全知覚の影響を受けたデータの識別性能に向上は見られた一方で、 λ の値が大きくなると Deep Autoencoder における再構築誤差の最小化にまで負の影響を与えることが確認された。今後の研究では、提案手法が各モダリティの多様体の構造にどのような影響を与えるのかを定性的、定量的に解析し、提案手法の更なる改善に取り組む。

Table 3: Accuracy of digits classification with SVM.

Degree of parameter sharing	Accuracy (Left noised)	Accuracy (Right noised)
$\lambda = 0$	0.6938	0.7688
$\lambda = 1.0e - 8$	0.6964	0.7816
$\lambda = 1.0e - 7$	0.7042	0.7796
$\lambda = 1.0e - 6$	0.6954	0.7746
$\lambda = 5.0e - 6$	0.6778	0.7386
$\lambda = 1.0e - 5$	0.5912	0.6710

参考文献

- 1) Baheti, Radhakisan and Gill, Helen: Cyber-physical systems, The impact of control technology, **12**, 161/166 (2011)
- 2) Hinton, Geoffrey E and Salakhutdinov, Ruslan R: Reducing the dimensionality of data with neural networks, *Science*, **313** -5786, 504/507 (2006)
- 3) Ngiam, Jiquan and Khosla, Aditya and Kim, Mingyu and Nam, Juhan and Lee, Honglak and Ng, Andrew Y: Multimodal deep learning, Proceedings of the 28th international conference on machine learning (ICML-11), 689/696 (2011)
- 4) Srivastava, Nitish and Salakhutdinov, Ruslan R: Multimodal Learning with Deep Boltzmann Machines, Advances in neural information processing systems, 2222/2230 (2012)
- 5) Shu, Xiangbo and Qi, Guo-Jun and Tang, Jinhui and Wang, Jingdong: Weakly-Shared Deep Transfer Networks for Heterogeneous-Domain Knowledge Propagation, Proceedings of the 23rd Annual ACM Conference on Multimedia Conference, 35/44 (2015)
- 6) Yosinski, Jason and Clune, Jeff and Bengio, Yoshua and Lipson, Hod: How transferable are features in deep neural networks?, Advances in neural information processing systems, 3320/3328 (2014)
- 7) Ioffe, Sergey and Szegedy, Christian: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, Proceedings of the 32nd International Conference on Machine Learning (ICML-15), 448/456 (2015)

Deep Convolutional Neural Network の転移学習による 乳房 X 線画像上の腫瘍検出

○鈴木真太郎 張暁勇 本間経康 市地慶 魚住洋佑 高根侑美 川住祐介 石橋忠司 吉澤誠
(東北大学)

Detecting Masses in Mammograms Based on Transfer Learning of A Deep Convolutional Neural Network

*S. Suzuki, X. Zhang, N. Homma, K. Ichiji, Y. Uozumi, Y. Takane, Y. Kawasumi,
T. Ishibashi, and M. Yoshizawa (Tohoku University)

Abstract— In recent years, deep convolutional neural networks (DCNNs) have attracted great attention due to their outstanding performance in recognition of natural images. However, their performance for medical image recognition is still uncertain because collecting a large-scale medical training data is difficult. To solve the problem, we propose a transfer learning strategy for mass detection in mammograms. A DCNN that includes five convolutional layers was used in this study. We firstly train the DCNN using a large-scale natural image dataset for classification of 1,000 classes. Then, we modify a fully-connected output layer of the DCNN and subsequently train the DCNN using a relatively small-scale mammogram dataset for two classes classification: mass and normal. The experimental results showed that sensitivity of the mass detection was about 90% and false positive was 20%. In addition, we generated class model images numerically and verified the validity of mass feature extraction. These results demonstrated that the DCNN trained by transfer learning has a potential for mammographic mass detection.

Key Words: Deep convolutional neural network (DCNN), Computer-aided diagnosis (CAD), Mammography

1 Introduction

For years, breast cancer is the most common cancer and one of the leading causes of death among women in Japan¹⁾. In order to reduce breast cancer mortality, it is important to detect and treat breast cancer in its early stages. As the one of the most effective tools for early detection, mammography has widely been used for routine breast cancer screening.

However, due to the increase of the number of examinee, reading a large number of mammograms became a burden for doctors and it might cause misdiagnosis that leads to unnecessary biopsies or mastectomies.

For reducing the work burden of doctors and improving their detection accuracy, computer-aided diagnosis (CAD) systems that use computer technologies to detect abnormalities in mammograms have been developed²⁾. The CAD systems are almost focus on detecting three typical abnormalities in mammograms: microcalcification cluster (MCC), mass, and architectural distortion (AD). In this paper, our focus is on detection of mass because the mass is one of the most important signs of malignancy³⁾. In mammograms, mass usually has a circular shape and it has tendency to be denser in the middle compared to its edge.

Conventional mass detection methods^{4, 5, 6, 7)} are based on the following three phases: 1) mass candidate or region of interest (ROI) detection using image processing techniques; 2) extracting feature vectors of the ROI based on special knowledge; 3) classifying the

ROI into normal or mass classes. However, it is difficult to design the features sufficiently representing the characteristics of masses for distinguishing them from others.

In recent years, deep learning technologies has attracted great attention in artificial intelligence (AI) due to its successes in various research fields, such as pattern recognition, computer vision and big-data analysis. As one of the most successful techniques in deep learning, deep convolutional neural networks (DCNNs) achieved outstanding performance in recognition of natural images⁸⁾. The DCNN can obtain feature representation and classification rules from training data automatically without hand-designed feature extraction. However, the DCNN performance for mammographic CAD is still uncertain because collecting a large amount of training data is difficult. In addition, due to the difference of patterns between the natural image and the mammogram image, the performance of the DCNN in obtaining the feature representation is also uncertain.

In this paper, we present a transfer learning strategy to solve the above training problem of the DCNN for a mammographic CAD application. In this strategy, a large-scale natural image dataset is firstly used for pre-training of the DCNN, and then a relatively small-scale mammogram dataset is used to retrain it for transfer learning.

In addition, in order to verify the mass feature extraction performance of the DCNN, we employ a class model visualization technique^{9, 10)} to numerically generate a mass image which is representative

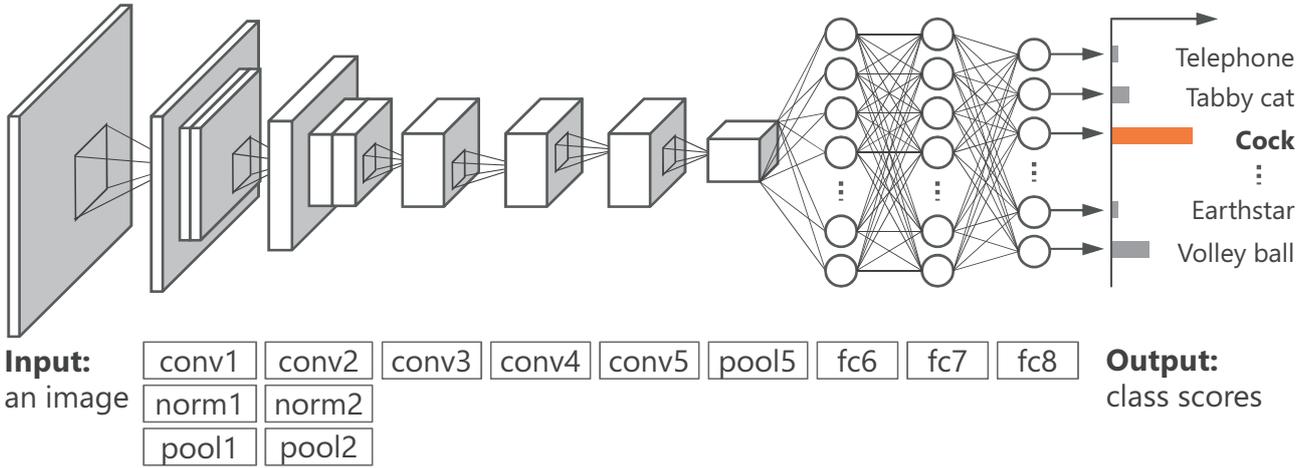


Fig. 1: Architecture of the *AlexNet*

of the mass in terms of the DCNN class scoring model.

Experimental results showed that the proposed DCNN is capable of perceiving the difference between the mass and normal regions.

2 Proposed Method

In this study, we adopt a DCNN, called *AlexNet*⁸⁾, for our application.

2.1 Architecture of the *AlexNet*

As shown in Fig.1, the DCNN contains eight layers with weights including five convolutional layers and three fully-connected layers. The input of the DCNN is a three-dimensional (3-D) intensity volume (R,G,B) of an image. The outputs of the DCNN are class scores over 1,000 classes for *ImageNet* classification¹¹⁾.

Here, we briefly describe each layer of the DCNN, and the details can be found in⁸⁾.

The layers of *conv1-5* in Fig. 1 are the convolution layers. The weights of the convolution layers consist of a set of learnable filters. Each filter is convolved across the width and height of the input volume, producing two-dimensional (2-D) activation map of the filter. Adjusting the parameters (weights and biases) by training, the DCNN will learn filters that are activated when they see some specific visual feature at some spatial position.

Suppose that a convolutional layer is the l -th layer of the DCNN, $l = 1, 4, 7, 8, 9$. The input of the layer is the output of the $(l-1)$ -th layer, where the output of the 0-th layer implies the input image itself. Each neuron consisting of the convolutional layer is connected to the local region $(p = 1, \dots, H, q = 1, \dots, H)$ in the input. Let z_{ijk}^{l-1} , $k = 1, \dots, K$ be the input volume of the convolution layer that has K channels. Using M distinct filters h_{pqkm} and bias b_m ($m = 1, \dots, M$), the convolution is given by

$$u_{ijm} = \sum_{k=1}^K \sum_{p=1}^H \sum_{q=1}^H z_{i+p,j+q,k}^{(l-1)} h_{pqkm} + b_m \quad (1)$$

where h_{pqkm} is a filter consisting of weights of each neuron.

Subsequently, we apply an element-wise activation function called rectified-linear (ReL) function to ignore meaningless negative activation and reduce the amount of computation, given by

$$u'_{ijm} = f(u_{ijm}) = \max[0, u_{ijm}] \quad (2)$$

where u'_{ijm} is the output of the convolution layer.

The layers of *pool1*, *pool2*, and *pool5* in Fig. 1 are the pooling layers. The pooling layer performs a down-sampling operation along the spatial dimensions to reduce the amount of computation and improve the robustness against position variation. Let x_{pqk} be an input of the pooling layer in the local region P_{ij} , the max pooling is written as follows.

$$z_{ijk} = \max_{(p,q) \in P_{ij}} x_{pqk} \quad (3)$$

The layers of *norm1* and *norm2* in Fig. 1 are the normalization layers. We used a local response normalization (LRN) layer⁸⁾ in this study. Its function is to encourage competition for too large activation.

The layers of *fc6*, *fc7*, and *fc8* in Fig. 1 are the fully-connected layers. Neurons in the fully-connected layer have full connections to all neurons in the previous layer. By letting x_i ($i = 1, \dots, I$) be the output of the i -th neuron in previous layer, the total input of the j -th neuron in the current fully connected layer is written as follows.

$$u_j = \sum_{i=1}^I w_{ji} x_i + b_j \quad (4)$$

where w_{ji} is the connection weight from the i -th neuron in the previous layer to the j -th neuron in the current layer, and b_j is the bias of j -th neuron.

The output of the fully-connected layer is calculated by applying activation function to u_j . In layer *fc6* and *fc7* in Fig. 1, the activation function is ReL given as Eq. (2). In the layer *fc8* in Fig1, the final layer of the DCNN, the activation function is the softmax

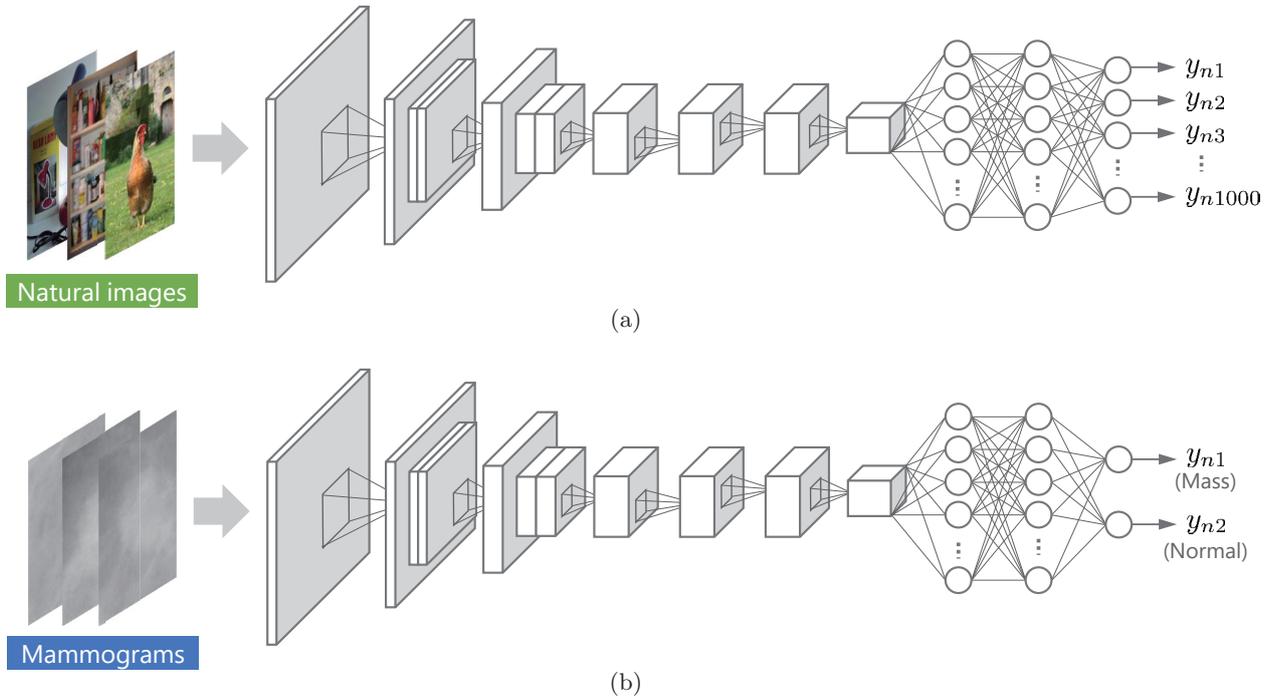


Fig. 2: The fine-tuning transfer learning for mass detection in mammograms. (a) The DCNN is pre-trained by using a large-scale image dataset for 1,000 classes. (b) We modify the last layer into two neurons, corresponding mass and normal classes respectively, and subsequently retrain the DCNN using a small-scale mammogram dataset.

function which produces class scores over K classes for the classification task, given by

$$y_k \equiv z_k^{(L)} = \frac{\exp(u_k^{(L)})}{\sum_{j=1}^K \exp(u_j^{(L)})} \quad (5)$$

The total sum of outputs y_k , $k = 1, \dots, K$, is always 1, and each output y_k corresponds to the predicted probability that the input belongs to the class c_k .

The layer of *fc8* consists of 1,000 neurons, and each neuron outputs the class scores that represent the predicted probability that the input belongs to each class of *ImageNet* classification¹¹⁾.

2.2 Transfer Learning

Transfer learning is a machine learning technique which aims to extract the knowledge from one or more source tasks and applies the knowledge to a target task¹²⁾. In many cases, it is expensive or impossible to collect enough amount of training data for the target task. In such cases, the performance can be improved by transferring the knowledge from source tasks that have sufficiently enough amount of training data, to the target task of interest.

In this study, it is difficult to collect a large-scale mammographic training data to train the DCNN. Therefore, we used a *fine-tuning* strategy that is a type of transfer learning techniques to train the DCNN.

As shown in Fig. 2(a), the DCNN is firstly pre-trained by using *ImageNet* dataset¹¹⁾ for classification of 1,000 classes. Then, the last fully-connected

layer is replaced by a new layer for classification of 2 classes: mass and normal. The modified DCNN is subsequently retrained by a small-scale mammographic image dataset, as shown in Fig. 2(b),

2.3 Class Model Visualization

Class model visualization method^{9, 10)} is one of visualization methods that gives insight into the feature extraction of the DCNN. The class model is an input image of the DCNN which maximizes the output of a neuron of interest. The class model image I can be numerically generated by iteratively optimizing intensities to maximize an objective function as follows.

$$I = \arg \max_I \{S_c(I) - \lambda_{l2} \|I\|_2^2 - \lambda_{tv} \|\nabla I\|_2^2\} \quad (6)$$

The first term $S_c(I)$ is a class score of class c , computed by the last fully-connected layer of the DCNN for a mean-subtracted input image I .

The terms $\lambda_{l2} \|I\|_2^2$ and $\lambda_{tv} \|\nabla I\|_2^2$ are image regularizers. $\|I\|_2$ denotes *L2-norm* that restrains image intensities from being too large, given by

$$\|I\|_2 = \sum_{i,j} \sqrt{x_{ij}^2} \quad (7)$$

where x_{ij} is a pixel intensity at position (i, j) in the input image. $\|\nabla I\|_2$ is *total variation (TV)* which smooths the image by reducing unnecessary intensity changes, while maintaining meaningful edges, as follows.

$$\|\nabla I\|_2 = \sum_{i,j} \sqrt{(x_{i,j+1} - x_{ij})^2 + (x_{i+1,j} - x_{ij})^2} \quad (8)$$

In Eq. (6), λ_{l2} and λ_{tv} are coefficients adjusting the effectiveness of regularizers.

By maximizing the objective function in E. (6), we obtain a interpretable image I which maximizes class score S_c .

In this study, we employed this class model visualization technique to verify feature extraction performance of the DCNN trained by using the proposed method. We generated class model images which maximize class scores of mass and normal, respectively, and investigate how the DCNN recognize masses from normal images.

3 Experimental Results

3.1 Transfer Learning and Classification Test

The transfer training and test experiments are conducted on the *Digital Database for Screening Mammography* (DDSM) ¹³. The training and test image data consist of two groups of ROI images cropped from the original mammograms. The first group ROI contains the mass area and the other is the normal area. Both ROIs are size of 454×454 pixels. In the transfer training, 1,656 ROI images including 786 mass images and 870 normal images are used to retrain the DCNN. After each training epoch, the test experiment was then conducted on 198 mammographic ROI images including 99 mass images and 99 normal images.

Fig. 3 shows that the error rate of mass detection for training data (solid line) gradually decreased with the training epoch, and the error rate for test data (broken line) also decreased and reached about 15% after 50 training epochs of the transfer learning. As summarized in Table 1, the DCNN finally achieved 89.9% sensitivity and false positive rate, which is the percentage of false positive detections to all negative (normal) cases, was 19.2% in mass detection after 50 training epochs. These results demonstrated that the DCNN is capable of classifying the mass from normal

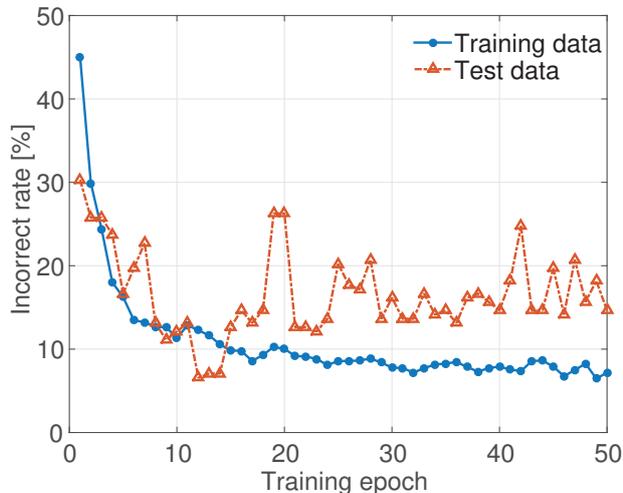


Fig. 3: Changes of classification error rate. The error rate for test data decreased and finally reached about 15%.

Table 1: Confusion matrix for mass classification after 50 training epochs. The DCNN achieved 89.9% sensitivity and 19.2% false positive in mass detection.

		Actual class		
		Mass	Normal	Total
Predicted class	Mass	89	19	108
	Normal	10	80	90
	Total	99	99	198

ROI in some extent.

Fig. 4(a) shows the top 28 images which are classified into mass in the test experiment. The number under each image is the class score corresponding to a predicted probability that the input is a mass image. On the other hand, Fig 4(b) shows the images which are classified into normal.

Fig. 5(a) shows the normal images that were misclassified into mass (false positive). In these images, we can find a high brightness pattern of healthy tissue, which is similar to the typical pattern of mass. Fig. 5(b) shows the overlooked mass images. Some of these masses are indistinct and others are too large and protruded from the ROI.

3.2 Class Model Visualization

Fig. 6 shows a mass model which consists of three channels (R, G, B) generated by using the class model visualization technique. From this image, we can find circular bright area which looks like a mass in mammogram. And we can see linear patterns radiating out from the circular bright area. Similar patterns can be seen around mass in mammograms, which called *spicula*, and it is one of important image features of malignant mass.

Fig. 7 shows a normal model image. We can see some linear patterns in random directions that are similar to normal mammary glands in mammograms.

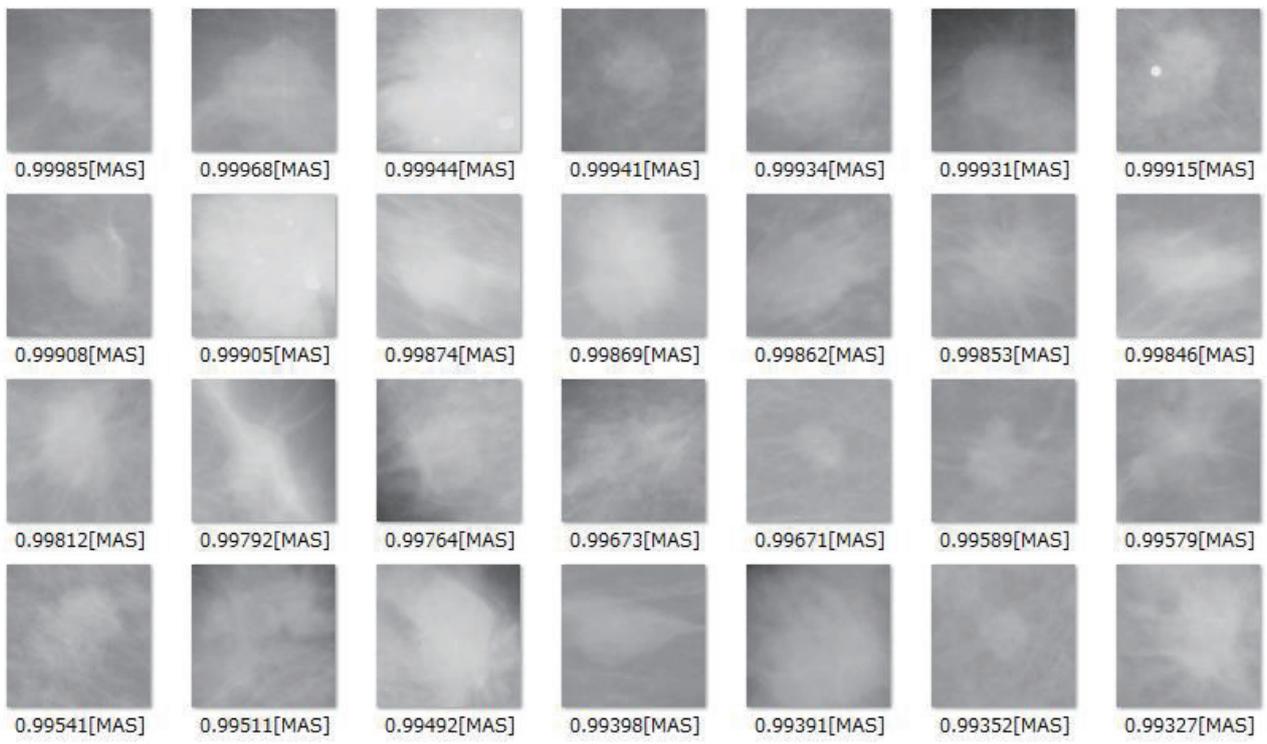
These results demonstrated that the DCNN is capable of extracting the mass features automatically by using transfer learning.

4 Conclusion

In this study, we presented a transfer learning of the DCNN for mass detection in mammogram images. The experimental results demonstrated that the DCNN retrained by transfer learning strategy have a promise potential for mammographic CAD system even the number of training data is limited.

5 Acknowledgement

This work was partially supported by JSPS KAKENHI Grant No.15K20852 and No.26540112.



(a)



(b)

Fig. 4: The classified images with class scores. (a) The mass classification with class score ranking, (b) The normal classification with class score ranking.

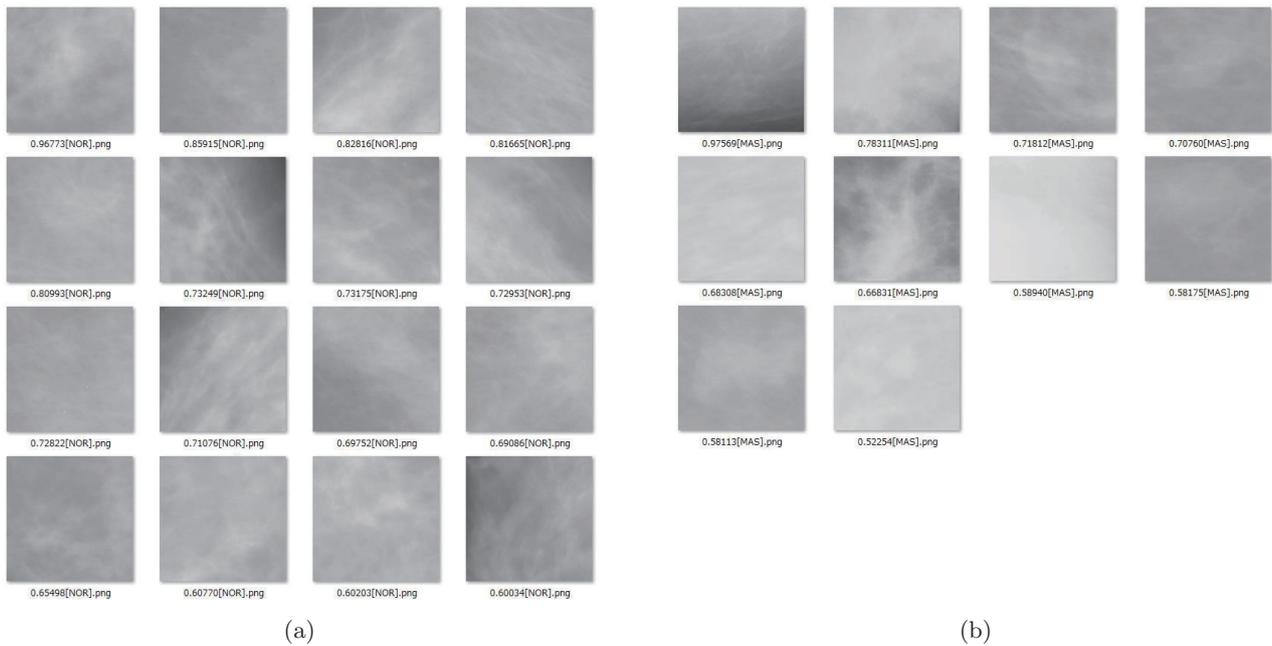


Fig. 5: The misclassified images. (a) False positive in mass classification, (b) False negative in mass classification.

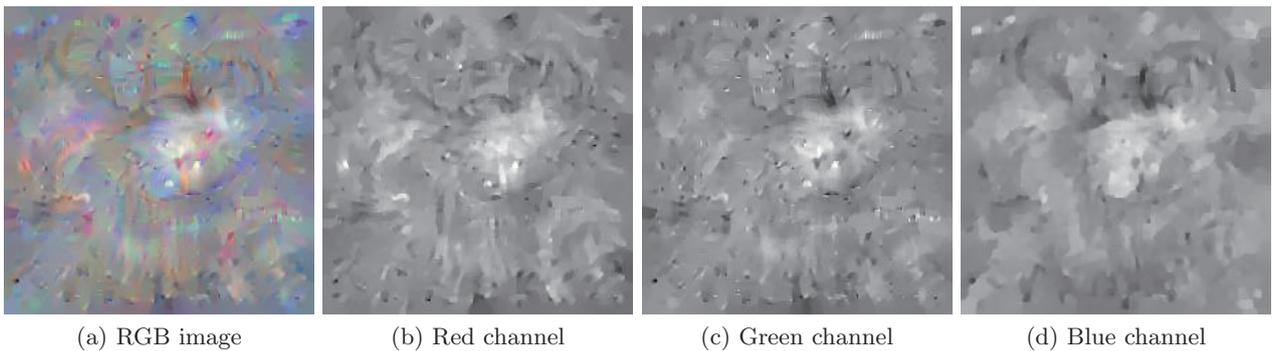


Fig. 6: The mass class model generated by the class model visualization

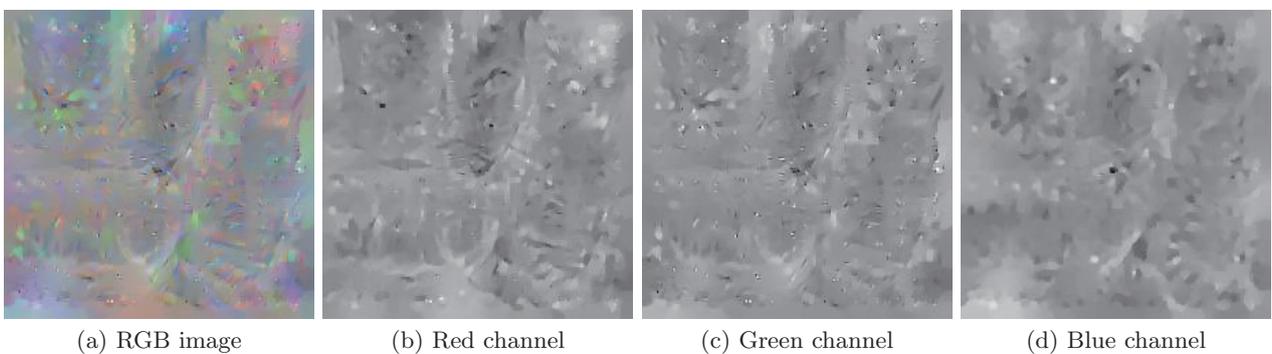


Fig. 7: The normal class model generated by the class model visualization

References

- 1) A. Matsuda, T. Matsuda, A. Shibata, K. Katanoda, T. Sobue, H. Nishimoto and The Japan Cancer Surveillance Research Group: Cancer Incidence and Incidence Rates in Japan in 2008: A Study of 25 Population-based Cancer Registries for the Monitoring of Cancer Incidence in Japan (MCIJ) Project, *Japanese Journal of Clinical Oncology*, **44-4**, 388/396, (2013).
- 2) J. Tang, R. M. Rangayyan, J. Xu, I. E. Naqa, and Y. Yang: Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography: Recent Advances, *IEEE Trans. Inf. Technol. Biomed*, **13-2**, 236/251, (2009).
- 3) B. Sahiner, N. Petrick, H. P. Chan, L. M. Hadjiiski, C. Paramagui, M. A. Helvie, and M. N. Gurcan: Computer-Aided Characterization of Mammographic Masses: Accuracy of Mass Segmentation and Its Effects on Characterization, *IEEE Trans. Med. Img*, **20-12**, 1275/1284, (2001).
- 4) H. P. Chan, D. Wei, M. A. Helvie, B. Sahiner, D. D. Adler, M. M. Goodsitt, and N. Petrick: Computer-aided classification of mammographic masses and normal tissue: Linear discriminant analysis in texture feature space, *Phys. Med. Biol.*, **40-5**, 857/876, (1995).
- 5) B. Sahiner, H. P. Chan, N. Petrick, D. Wei, M. A. Helvie, D. D. Adler, and M. M. Goodsitt: Classification of mass and normal breast tissue: A convolutional neural network classifier with spatial domain and texture images, *IEEE Trans. Med. Imag.*, **15-5**, 598/610, (1996).
- 6) N. R. Mudigonda, R. M. Rangayyan, and J. E. L. Desautels: Gradient and texture analysis for the classification of mammographic masses, *IEEE Trans. Med. Imag.*, **19-10**, 1032/1043, (2000).
- 7) J. Wei, B. Sahiner, L. Hadjiiski, H. Chan, N. Petrick, M. Helvie, M. Roubidoux, J. Ge, and C. Zhou: Computer aided detection of breast masses on full field digital mammograms, *Med. Phys.*, **32-9**, 2827/2837, (2005).
- 8) A. Krizhevski, I. Sutskever, and G. E. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, In *Proc. NIPS*, (2012).
- 9) A. Mahendran, and A. Vedaldi: Understanding Deep Image Representations by Inverting Them, *CVPR*, (2015).
- 10) K. Simonyan, A. Vedaldi, and A. Zisserman: Deep Inside Convolutional Networks: Visualizing Image Classification Models and Saliency Maps, *ICLR*, (2014).
- 11) J. Deng, W. Dong, R. Socher, L. J. Li, K. Li, and L. Fei-Fei: ImageNet: A Large-Scale Hierarchical Image Database, In *CVPR09*, 248/255, (2009).
- 12) S. J. Pan and Q. Yang: A Survey on Transfer Learning, *Knowledge and Data Engineering, IEEE Transaction on*, **22-10**, 1345/1359, (2010).
- 13) M. Heath, K. Bowyer, D. Kopans, R. Moore and W. P. Kegelmeyer: The Digital Database for Screening Mammography, *Proceedings of the Fifth International Workshop on Digital Mammography*, 212/218, (2001).