

## 階層的自動グループ構成手法による船舶の位置予測

工藤理人†

長尾智晴†

†横浜国立大学大学院環境情報研究院

## 1 はじめに

海運業界では多数の船会社が多数の船舶を運航している。船会社が利益を得るためには、事前に船舶の動向を予測し、船舶の数が少ないエリアや需要の高い場所を知ることが重要になる。そして、船舶の移動には数週間の時間が必要であるため、長期的な船舶の位置予測が求められている。従来研究では、過去の航海情報に基づいた予測を行うことで、高い精度を示すことができていた [1, 2]。しかし、航海エリアが限定的であったり、単一の船舶の位置予測のみであったりとなっている。そこで、本稿では全世界に存在する船舶の位置予測のための手法を提案する。モデルとして、自動グループ構成手法 (Automatically Defined Groups; ADG) [3] を採用する。ADG は問題に応じて適切なグループ数と各グループの行動規則を最適化する手法である。また、ADG は GP によって構築されているため、作成されたモデルの解析も容易に行うことができる。各グループの行動規則が全世界の船舶の行動パターンを近似できるものと仮定し、それによって船舶の位置を予測する。

## 2 自動グループ構成手法 ADG

ADG は、マルチエージェントモデルにおける Homogeneous モデルと Heterogeneous モデルを混在させたモデルである。つまり、モデルが複数の木を有しており、各エージェントは参照する木をグループと定義し、エージェントと木が多対一の関係を持っている。これによって、Homogeneous モデルの欠点である表現力を柔軟にすることができ、かつ Heterogeneous モデルの欠点である探索空間を抑えることが可能となっている。また、最適なグループ数を進化的に自動で獲得することができる。本稿では、ADG の各プログラムを GP から GNP へ拡張した手法 [4] を利用する。

## 3 提案手法

図 1 に提案手法の構造例を示す。従来の ADG では、各プログラムが 1 つの GP もしくは GNP の構造しか持




図 1: 提案手法の構造例

つことができなため、表現力に限界があるのが問題点として挙げられる。そのため、各プログラムを多層構造にすることで、より柔軟な表現力を獲得する。また、これによって、出力も階層的になることで、グループ間の違いの表現だけでなく、グループ内の表現も段階的に表現することが可能となる。従来の GNP では、開始ノード、条件ノード、判定ノードの 3 種類しかなく、上層の GNP は下層の GNP を選択する必要があるため、新たに選択ノードを設ける。選択ノードは、どの下層の GNP を参照するかという参照 id を出力し、id に応じた GNP を選択して新たに行動分類を行う。そのため、選択ノード数が 1 層下の GNP の個数となる。

また、従来の ADG では、扱うエージェント数が高々数十個のものであったが、本稿で扱うエージェント数は 4 桁にも及ぶ。これによって、進化の過程でグループ数が肥大化し、グループの解析が困難になることが想定される。そのため、学習を 2 段階に分けることで、グループ数の肥大化を避けることを行う。1 段階目では、予測精度の向上を目的とした学習を行う。このときグループ数は考慮しない。2 段階目では、グループ数の削減を目的とした学習を行う。具体的には、1 段階目で獲得したエリート個体を、2 段階目の学習の初期個体として再度学習をし直す。その際に、遺伝操作として、グループ数が小さくなることに圧をかけた進化を行う。また、適応度関数は 1 段階目と共通だが、エリート個体の更新方法として、グループ数が下がった場合に更新することとする。これによって、グループ数が小さいかつ高精度な予測モデルの構築を目指す。

Location Prediction of Cargos Using Hierarchical Automatically Defined Groups

†Masato Kudo †Tomoharu Nagao

†Graduate School of Environment and Information Sciences, Yokohama National University

表 1: 実験パラメータ

パラメータ	値
世代数 (1 段階目)	200000
世代数 (2 段階目)	100000
世代交代モデル	MGG[5]
親個体数	100
子個体数	10
交叉率	0.9
突然変異率	0.001
グループ突然変異率	0.01
親判定ノード数	2
子判定ノード数	5
親選択ノード数	5
処理ノード数 (共通)	48

## 4 実験設定

### 4.1 実験パラメータ

表 1 に、実験パラメータについて示す。本稿では、提案モデルの層数を 2 として、親子関係による表現を行う。予測対象としては、大型船舶の 1 週間後の位置を予測する。学習期間は 2015/7/8~2016/11/4 の 187 日 (件)、テスト期間は 2016/11/7~2017/3/3 の 47 日 (件) とする。各プログラムは入力に各船舶の位置情報、出力に 48 か所いづれかの予測位置を出力する。

### 4.2 適応度関数

本稿の目的は単一の船舶の位置予測ではなく一度に複数の船舶の位置を予測し、その分布を把握することである。そのため、適応度関数を式 (1) で計算する。

$$f = \frac{1}{|d|} \sum_i \sum_j |\hat{y}_{d_i,j} - y_{d_i,j}| \quad (1)$$

$d$  はデータ日数 (件数) ベクトル、 $\hat{y}_{d_i,j}, y_{d_i,j}$  はそれぞれ  $d_i$  日、エリア  $j$  の隻数の予測値および実測値を表す。つまり、各エリアの隻数の誤差を集計し、その 1 日ごとの平均値を適応度として評価する。

## 5 実験結果

表 2 に提案手法と比較手法の適応度およびグループ数を示す。提案手法として、それぞれ 1 段階目と 2 段階目の結果を示す。比較手法として、文献 [4] の階層構造を有しない ADG を用いた。この結果から、提案手法の方が比較手法よりも精度において良好な結果が得られていることが分かった。また、提案手法の 1 段階目では比較手法に比べてグループ数が多くなってしまった。

表 2: 実験結果 (3 試行平均)

method	fitness(trian)	fitness(test)	group num
ADG[4]	133.12 ± 1.30	146.35 ± 1.53	63.7 ± 1.7
ADG(step 1)	120.98 ± 0.76	<b>144.85</b> ± 1.25	129.0 ± 4.2
ADG(step 2)	<b>120.61</b> ± 0.73	145.08 ± 1.63	<b>37.7</b> ± 3.9

しかし、2 段階の学習を行うことで、精度を維持したままグループ数を約 1/3 に削減することができ、比較手法よりも少ないグループ数を獲得することができた。しかし、従来の ADG と比較して精度の差があまりないため、今後さらなる精度向上を行う必要がある。

## 6 まとめ

本稿では船舶の位置予測モデルとして、階層構造を有する ADG を提案した。実験結果により、従来の ADG と比較して精度およびグループ数の両方において良好な結果を示した。しかし、まだ十分な精度を獲得することができていないため、今後は更なる精度向上を行う。また、グループ数においても、数が多く解析が十分に行うことができていないため、よりグループ数を少なくすることで、解析のしやすいモデル構築を目指す。

## 参考文献

- [1] Pallotta G., Vespe M. and Bryan K., Vessel pattern knowledge discovery from AIS data: A framework for anomaly detection and route prediction, *Entropy*, vol.15, no.6, pp.2218-2245, (2013).
- [2] Duca A. L., Bacciu C., and Marchetti A., A K-nearest neighbor classifier for ship route prediction., In *OCEANS 2017-Aberdeen*. IEEE, pp.1-6, (2017).
- [3] 原章, 長尾智晴, 自動グループ構成手法 ADG によるマルチエージェントの行動制御, *情報処理学会論文誌*, vol.41, no.4, pp.1063-1072, (2000).
- [4] 中村貴志, 村田忠彦, 自動グループ構成手法を用いた遺伝的ネットワークプログラミングによるマルチエージェントの役割分担獲得, *情報処理学会論文誌*, vol.47, no.5, pp.1493-1501, (2006).
- [5] 佐藤浩, 小野功, 小林重信, 遺伝的アルゴリズムにおける世代交代モデルの提案と評価, *人工知能学会誌*, vol.12, no.5, pp.734-744, (1997).