

車両群のナビゲーション：群れのモデルとその制御

山本, 薫
九州大学

セメリス, アンドレアス
九州大学

<https://hdl.handle.net/2324/7384481>

出版情報 : Proceedings of the Annual Conference of the Institute of Systems, Control and Information Engineers, 2023. THE INSTITUTE OF SYSTEMS, CONTROL AND INFORMATION ENGINEERS (ISCIE)

バージョン :

権利関係 : © 2023 一般社団法人システム制御情報学会



車両群のナビゲーション：群れのモデルとその制御

Vehicle fleet navigation: flock models and their control

九州大学 ○ 山本 薫, Themelis Andreas

K. Yamamoto and A. Themelis

Kyushu University

Abstract We propose a model predictive control (MPC) approach to solve a flock control problem while incorporating obstacle avoidance capabilities within a leader-follower framework. To achieve this, we utilize the future trajectory prediction calculated by each agent and employ Reynolds' traditional flocking rules (cohesion, separation, and alignment) as a foundation, which we tailor for navigation purposes rather than formation. We introduce several concepts, including the importance and credibility of information gathered from neighbors, dynamic trade-offs between references, and the fact that near-future predictions are more reliable. We also consider the implicit carriers of educated information, the predominance of cohesion or alignment based on an agent's distance from its neighbors. These features are integrated into the MPC formulation, and we discuss their benefits through numerical simulations.

1 はじめに

自然界では、魚の群れや鳥の群れなど、各個体が簡単な原則に従い、局所情報のみを使用して大域的な目的を達成する集団行動がよく見られる。これは、多数の自律移動ロボットを制御する場合に極めて魅力的であり、各ロボットが限られた計算能力しかない場合にも有効である。

1987年、Reynoldsは、群れを形成するために「結合・分離・整列」という3つの簡単なルールに従うエージェントモデル「ボイド」を提案した[7]。Reynoldsの群れのモデルは、そのシンプルさとスケラビリティのために注目を集め、移動ロボット群の協調制御にこのモデルを適用する試みが盛んに行われてきた[1]。初期の研究では、人工ポテンシャル場によって近傍のエージェント間の引力と斥力を表現することで結合と分離を達成し、さらに速度合意制御器を付加することで、整列を達成する手法が主流であった[11, 12, 5]。しかし、ポテンシャル場ベースの方法では、各エージェントが現在の周囲の状態に対して受動的に反応するため、振動的な動作を示す傾向がある。代わりに、各エージェントが数ステップ先の将来の状況を考慮することができれば、より円滑な群れ制御が可能となると考えられる。これはまさにモデル予測制御(MPC)の考え方であり、近年の求解アルゴリズムの急速な進歩(例えば[4, 6, 10, 13, 8])も相まって、MPCを用いた群れ制御に注目が集まっている[15, 16, 17, 18, 19, 2, 9]。これらの手法では、各時刻において種々の制約のもとで群れルールからの逸脱を最小化するような制御入力を求める問題として定式化され、

障害物回避や移動体の運動学モデル等も制約条件として扱えることも利点である。

本稿では、移動体として車輪型ロボットを想定したMPCベースの手法を提案する。特に、障害物の存在する未知環境において、目的地まで群れを効率的に誘導することを目標とする。このとき、Reynoldsの群れモデルに適当な変更を加えることで、複雑な環境下でも群れの誘導が可能であることが、筆者らの先行研究[3]において質点モデルを用いた数値例題により実証されている。本稿では、その概要および課題について述べる。

2 問題設定

d 次元空間を移動する N 体のエージェント群からなるシステムを考える。エージェントのインデックス集合を $\mathcal{N} = \{1, 2, \dots, N\}$ で表す。群れはリーダーとフォロワーに分かれており、リーダーは目的地に到達するための軌道をあらかじめ知っているか、あるいは、リアルタイムでの軌道生成を担当する。一方、フォロワーは、そのときどきの周囲の状況のみに反応し、目的地に関する情報は持たない。本稿では、リーダーが数ステップ先までの軌道や速度の情報をフォロワーに伝達することを前提とした上で、フォロワーエージェントの位置 $p_i^t \in \mathbb{R}^d$ と速度 $v_i^t \in \mathbb{R}^d$ を効率よく制御し、群れを目的地まで誘導することを目標とする。

2.1 MPC 表現

各エージェントは測定や通信により近傍のエージェントから情報を取得できるものとする。本稿では、下記のように距離ベースでエージェント i の時刻 t における自

身を含む近傍および含まない近傍を定義する。

$$\begin{aligned} \mathcal{N}_i^t &= \{j \in \mathcal{N} \mid \|p_i^t - p_j^t\| < r_i, i, j \in \mathcal{N}\} \quad (1) \\ \bar{\mathcal{N}}_i^t &= \mathcal{N}_i^t \setminus \{i\}. \end{aligned}$$

また、各時刻 t において、エージェント $i \in \mathcal{N}$ は計測範囲内に存在する障害物集合 \mathcal{O}_i^t を検知できるものとする。

このとき、エージェント i が、各離散時刻 t において解くべき最適化問題を、以下のように設定する。

$$\begin{aligned} &\underset{\mathbf{u}_i^t \in \mathcal{U}_i \times \dots \times \mathcal{U}_i}{\text{minimize}} && J(\mathbf{u}_i^t) \quad (2a) \\ &\text{subject to} && \left[\begin{array}{l} x_i^{t+k+1|t} = f_i(x_i^{t+k|t}, u_i^{t+k|t}) \\ x_i^{t+k+1|t} \in \mathcal{X}_i \\ p_i^{t+k+1|t} \notin \mathcal{O}, \mathcal{O} \in \mathcal{O}_i^t \\ d_{j|i}^{t+k+1|t} \geq d_{i,\text{sep}}, j \in \bar{\mathcal{N}}_i^{t+k+1|t} \end{array} \right] \quad \begin{array}{l} k < T \\ k < T_{\text{sep}} \end{array} \quad (2b) \end{aligned}$$

ここで、 x_i および u_i はエージェント i の状態と制御入力であり、時刻 t から $t+T-1$ までの制御入力 $\mathbf{u}_i^t = u_i^{t|t}, \dots, u_i^{t+T-1|t}$ が最適化されるべき関数である¹。この入力のもと、 $x_i^{t+k|t}$ は時刻 t に $x_i(t)$ から出発する状態の時刻 $t+k$ での予測値を表す。 $f_i: \mathbb{R}^{n_{x_i}} \times \mathbb{R}^{n_{u_i}} \rightarrow \mathbb{R}^{n_{x_i}}$ はエージェント i の離散時間状態方程式を、 $\mathcal{U}_i \subseteq \mathbb{R}^{n_{u_i}}$ および $\mathcal{X}_i \subseteq \mathbb{R}^{n_{x_i}}$ はそれぞれ入力および状態に関する制約集合を表す。 $d_{j|i}^{\tau|t}$ は、時刻 $\tau \in [t+1, t+T]$ における自身を含まない予測近傍エージェント $j \in \bar{\mathcal{N}}_i^{\tau|t}$ との予測二乗距離

$$d_{j|i}^{\tau|t} := \|p_i^{\tau|t} - p_{j|i}^{\tau|t}\|^2$$

を表す。ここで、時刻 t において、エージェント i は近傍エージェント $j \in \bar{\mathcal{N}}_i^t$ から予測位置 $p_{j|i}^{\tau|t}$ および速度 $v_{j|i}^{\tau|t}$ の情報を受け取るものとし、添字 $j|i$ は、異なるエージェントによって取得された同じ情報での不一致の可能性を表す。この予測情報は τ の増加とともに精度が悪化すると考えられるため、 $T_{\text{sep}} < T$ までは回避距離 $d_{i,\text{sep}} > 0$ のハード拘束を設け、それ以降は後述するソフト拘束により衝突回避を考慮する。

評価関数 $J(\mathbf{u}_i^t)$ は、過大な制御入力を避けつつ、「結合・整列・分離」を達成するようなものである必要がある。本稿では、次式の評価関数を採用する。

$$\begin{aligned} J(\mathbf{u}_i^t) &= \|\mathbf{u}_i^t\|_{R_i}^2 + \sum_{k=0}^{T-1} \gamma_i^k \|y_i^{t+k+1|t} - \bar{y}_i^{t+k|t}\|_{Q_i^t}^2 \\ &\quad + \rho_{i,\text{sep}} \sum_{k>T_{\text{sep}}} \gamma_i^k \sum_{j \in \bar{\mathcal{N}}_i^{t+k|t}} d_{j|i}^{t+k|t} \quad (3) \end{aligned}$$

¹本稿では簡単のためすべてのエージェントにおいて有限時間区間 T を同一とする。エージェントごとに時間区間が異なる場合の取り扱いについては、[3] を参照いただきたい。

ここで、 $y_i^{\tau|t}$ は、エージェント i の予測位置および予測速度よりなる出力ベクトルであり、 $\bar{y}_i^{\tau|t}$ は、次式で表される、予測近傍 $\mathcal{N}_i^{\tau|t}$ に属するエージェント群の予測位置と予測速度の重み付き平均を要素に持つ出力である。

$$\bar{p}_i^{\tau|t} := \sum_{j \in \mathcal{N}_i^{\tau|t}} w_{j|i}^{\tau|t} \cdot p_{j|i}^{\tau|t}, \quad \bar{v}_i^{\tau|t} := \sum_{j \in \mathcal{N}_i^{\tau|t}} \omega_{j|i}^{\tau|t} \cdot v_{j|i}^{\tau|t}. \quad (4)$$

ここで、 $w_{j|i}^{\tau|t}$ および $\omega_{j|i}^{\tau|t}$ はそれぞれ結合と整列のための重みであり、Reynolds の群れ規則においては、いずれも $1/|\mathcal{N}_i^{\tau|t}|$ と表すことができる。本稿では、群れ誘導により適した時変の重みを採用する。詳細は第3.2節に述べる。 τ の増加による $y_i^{\tau|t}$ および $\bar{y}_i^{\tau|t}$ の予測精度の悪化を、ディスカウント・ファクター $\gamma_i \in (0, 1]$ により考慮している。 $Q_i^t \in \mathbb{R}^{2d \times 2d}$, $R_i \in \mathbb{R}^{n_{u_i} T \times n_{u_i} T}$ は重み行列であり、 $\rho_{i,\text{sep}} \geq 0$ は T_{sep} ステップ以降でソフト拘束により衝突回避を考慮するためのペナルティパラメタである。

3 誘導のための群れモデル

本節では、従来の「結合・分離・整列」のルールを基本としつつ、未知環境での群れの誘導という目的をよりよく反映する新たな群れモデルを提案する。特に、つぎの3つの要素を導入する。

1. リーダー・フォロワー間グラフ距離に基づく時変階層的重み
2. 結合および整列のための参照値バイアス
3. 結合・整列ルール間の動的トレードオフ

3.1 リーダー・フォロワー間グラフ距離に基づく時変階層的重み

リーダーは障害物を回避しながら目的地に到達する軌道を生成する役割を担うことから、各エージェントが未知環境を移動する際に、リーダーから受け取る情報をその他のエージェントからの情報よりも重視することは合理的である。同様に、リーダーと近接しており直接情報を受け取るフォロワーは、そうでないフォロワーよりも精度の高い予測が可能であるといえ、これらのフォロワーエージェントから発信される情報も、より重視されるべきである。この階層的な情報優先度をモデル化する手法として、最も近いリーダーからのグラフ距離に基づく重みを導入する。各リーダー l は時不変の階層レベル $\pi_l^0 \equiv 0$ を有する一方で、各フォロワー i は、規定の上限值 $\pi_i^0 = \bar{\pi} \in \mathbb{N}_{\geq 1}$ からスタートし、次式により値を更新

していくことで、局所的な情報のみを用いて自身の正しい階層レベルを数サンプリング時間のうちに求めることができる（証明は [3] を参照）。

$$\pi_i^t = \min\{\pi, 1 + \min_{i \neq j \in \mathcal{N}_i^t} \pi_j^{t-1}\}. \quad (5)$$

3.2 結合および整列のための参照値バイアス

従来の結合のルールは、自身を含む近傍 \mathcal{N}_i^t の重心位置を参照位置とし、そこへ向かって移動するというものであった。上述の階層レベルを導入することで、リーダー方向への動きを促進するよう参照位置にバイアスをかけることができる。例えば、(4) 式の結合のための重みを次式のように設定することが考えられる。

$$w_{j|i}^{\tau|t} = \frac{2^{-\pi_j}}{\sum_{\ell \in \mathcal{N}_i^{\tau|t}} 2^{-\pi_\ell}} \quad (6)$$

ここで、 $j = i$ の場合は $\pi_j := \pi_i^t$ 、それ以外の場合は $\pi_j := \pi_j^{t-1}$ と表記した。整列のための重み $\omega_{j|i}^{\tau|t}$ にも同様のバイアスをかけることができるが、障害物が存在する未知環境においての群れ誘導問題においては、さらに、進行方向の前方・後方どちらに位置するエージェントかによっても重みを変化させることが望ましい。例えば、自身の前方を移動するエージェントが障害物回避のために進行方向を変えたとすると、自身もそれに合わせる事が自然である。一方で、後方を移動するエージェントの方向転換に従う必要性は一般に低い。ここで、各フォロワーエージェントは群れ全体の進行方向を把握することはできないため、自身の速度を基準として前方か後方かを判断することとなる。本稿では、つぎのように時刻 t におけるエージェント i にとっての前方か後方かを判断することとする。

- $\langle v_i^{t|t}, p_{j|i}^{t-1|t-1} - p_i^{t|t} \rangle \geq 0$ のとき $j \in \mathcal{N}_i^{t|t}$ はエージェント i の**前方**に位置する。
- その他の場合、 $j \in \mathcal{N}_i^{t|t}$ はエージェント i の**後方**に位置する。

このとき、(4) 式における整列のための重みを、ある定数 $\omega_{i,b} \in [0, 1]$ を用いて、つぎのように与える。

$$\omega_{j|i}^t := \begin{cases} 1 & j \text{ が } i \text{ の前方に位置するとき} \\ \omega_{i,b} & \text{それ以外の場合.} \end{cases} \quad (7)$$

3.3 結合・整列ルール間の動的トレードオフ

ここまで、参照位置および参照速度の設定について述べた。本節では、そのどちらをより重視して追従する

べきかについて述べる。もしエージェント i が参照位置 $\bar{p}_i^{t|t}$ から遠い場合は、遠くのエージェント群と進行方向を揃える必要性は低く、結合をより重視すべきといえる。一方で、エージェント i が参照位置 $\bar{p}_i^{t|t}$ に近い場合は、結合はすでに十分に達成されているといえ、近傍のエージェントと同様の動きをする整列ルールをより重視するのが合理的である。このような結合・整列ルール間のトレードオフは、(3) 式の評価関数 J における重み Q_i^t を適切に設定することで達成することができ、本稿ではつぎの重みを用いる。

$$Q_i^t := \begin{pmatrix} 1 - q_i^t & & & \\ & 1 - q_i^t & & \\ & & q_i^t & \\ & & & q_i^t \end{pmatrix}, \quad q_i^t := \frac{q_{i,st}}{1 + c_i \|p_i^{t|t} - \bar{p}_i^{t|t}\|^2}. \quad (8)$$

ただし、 $c_i > 0$ 、 $q_{i,st} \in (0, 1)$ とする。


4 数値例題

本節では数値例題により提案手法の有効性を検証する。MPC ホライズンを $T = 8$ 、衝突回避のハード制約を課するステップ数を $T_{\text{sep}} = 4$ とし、これ以降は (3) 式で $\rho_{i,\text{sep}} = 100$ 、 $\forall i$ と設定し、ソフト制約により衝突回避を考慮する。(7) 式の整列のための定数重みを $\omega_{i,b} = 0.2$ 、結合・整列のトレードオフのための (8) 式における定数を $q_{i,st} = 0.5$ 、 $c_i = 2$ とする。また、(5) 式の階層レベルの上限値を $\bar{\pi} = 10$ とし、ディスカウント・ファクターを $\gamma_i = 0.5$ 、サンプル時間を $\Delta t = \frac{1}{40}$ 秒とする。

リーダーは、他のエージェント同様、自身の予測位置及び速度を発信するが、それ以外においては他のエージェントの影響を受けないものとする。(1) 式における検知範囲 r_i は全エージェントで同一とする。これらの設定のもと、障害物が存在する狭い通路の通り抜けの数値シミュレーション結果を図 1 に示す。ここで、星印はリーダーエージェントを、丸印はフォロワーエージェントを表し、エージェントを中心とする円は検知範囲を表す。ひとつめの障害物をリーダーが通り抜けているが、これは、フォロワーが受け取る情報が不正確である場合を模擬している。このような場合にも、提案手法により群れの誘導が達成されている。

5 おわりに

未知環境において移動ロボット群を効率よく誘導するための群れモデルと、MPC を用いた分散制御手法を提案した。本手法を用いることで、複雑な環境下でも群れの誘導が可能となることを数値例題により確認した。しかしながら、本手法の実装にあたっては、座標系の取り



(a) 提案手法による群れ誘導結果。すべてのエージェントが滞りなく目的地に到着している。
 (b) 動的トレードオフを採用しない場合。ふたつめの障害物付近で結合をより重視しなかったために停止してしまっている。
 (c) 整列のための前方・後方バイアスを採用しない場合。特に障害物のある環境下においては後方のエージェントの影響により停止する状況が発生しやすい。
 (d) 階層レベルを導入しない場合。この場合も後方のエージェントの影響により取り残されるエージェントが発生しやすい。

図 1: 障害物が存在する狭い通路において不正確な仮想参照軌道を追従する場合。リーダー（星印）は不正確な仮想参照軌道とし、その結果としてひとつめの障害物を通過している。このような難しい状況においても、提案手法によりすべてのフォロワー（丸印）が目的地に到達し、群れの誘導が達成されている。

扱いに注意を要する。ここまでの議論は、全エージェントに共通の絶対座標系 Σ における位置や速度を用いて展開してきた。しかし、移動体群の制御においては、各エージェントはそれぞれ個別の相対座標系 $\Sigma_i(t)$ を持ち、各エージェントが GPS を搭載している場合などを除き、一般に、絶対位置と絶対方位を特定することができない [20]。本手法において、絶対位置および絶対方位は必ずしも必要ではないが、エージェントに搭載するセンサの種類によっては、エージェント間での予測軌道情報の共有の際に、適切な座標変換を施す必要がある。今後は、センサから得られる情報が限定的である場合や不正確である場合、また、通信遅延がある場合などを考慮した、より詳細な定式化に取り組む。また、静的な階層グラフの情報伝達構造を持つ移動体群制御におけるエージェント離脱時の性能解析手法 [14] を本稿で提案した動的階層構造への適用に拡張することにより、情報伝達構造のスパース化も期待される。

参考文献

- [1] L.E. Beaver and A.A. Malikopoulos. An overview on optimal flocking. *Annual Reviews in Control*, 51:88–99, 2021.
- [2] Y. Lyu, J. Hu, B.M. Chen, C. Zhao, and Q. Pan. Multivehicle flocking with collision avoidance via distributed model predictive control. *IEEE Transactions on Cybernetics*, 51(5):2651–2662, 2021.
- [3] A. Nag, S. Huang, A. Themelis, and K. Yamamoto. Flock navigation with dynamic hierarchy and subjective weights using nonlinear MPC. In *2022 IEEE Conference on Control Technology and Applications (CCTA)*, pages 1135–1140, 2022.
- [4] T. Ohtsuka. A continuation/GMRES method for fast computation of nonlinear receding horizon control. *Automatica*, 40(4):563–574, 2004.
- [5] R. Olfati-Saber. Flocking for multi-agent dynamic systems: algorithms and theory. *IEEE Transactions on Automatic Control*, 51(3):401–420, 2006.
- [6] P. Patrinos and A. Bemporad. An accelerated dual gradient-projection algorithm for embedded linear model predictive control. *IEEE Transactions on Automatic Control*, 59(1):18–33, 2014.
- [7] C.W. Reynolds. Flocks, herds and schools: A distributed behavioral model. *SIGGRAPH Comput. Graph.*, 21(4):25–34, 1987.
- [8] P. Sotasakis, E. Fresk, and P. Patrinos. OpEn: Code generation for embedded nonconvex optimization. *IFAC-PapersOnLine*, 53(2):6548–6554, 2020. 21st IFAC World Congress.
- [9] E. Soria, F. Schiano, and D. Floreano. Distributed predictive drone swarms in cluttered en-

- vironments. *IEEE Robotics and Automation Letters*, 7(1):73–80, 2022.
- [10] L. Stella, A. Themelis, P. Sopasakis, and P. Patrinos. A simple and efficient algorithm for non-linear model predictive control. In *2017 IEEE 56th Conference on Decision and Control (CDC)*, pages 1939–1944, 2017.
- [11] H.G. Tanner, A. Jadbabaie, and G.J. Pappas. Stable flocking of mobile agents, part I: fixed topology. In *2003 IEEE 42nd Conference on Decision and Control (CDC)*, volume 2, pages 2010–2015 Vol.2, 2003.
- [12] H.G. Tanner, A. Jadbabaie, and G.J. Pappas. Stable flocking of mobile agents part II: dynamic topology. In *2003 IEEE 42nd Conference on Decision and Control (CDC)*, volume 2, pages 2016–2021 Vol.2, 2003.
- [13] A. Themelis. *Proximal Algorithms for Structured Nonconvex Optimization*. PhD thesis, KU Leuven, 2018.
- [14] R. Yoshise and K. Yamamoto. Algebraic connectivity of layered path graphs under node deletion. In *2022 IEEE 61st Conference on Decision and Control (CDC)*, pages 975–980, 2022.
- [15] J. Zhan and X. Li. Flocking of discrete-time multi-agent systems with predictive mechanisms. *IFAC Proceedings Volumes*, 44(1):5669–5674, 2011. 18th IFAC World Congress.
- [16] J. Zhan and X. Li. Flocking of multi-agent systems via model predictive control based on position-only measurements. *IEEE Transactions on Industrial Informatics*, 9(1):377–385, 2013.
- [17] H. Zhang, Z. Cheng, G. Chen, and C. Li. Model predictive flocking control for second-order multi-agent systems with input constraints. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 62(6):1599–1606, 2015.
- [18] H. Zhang, B. Liu, Z. Cheng, and G. Chen. Model predictive flocking control of the Cucker-Smale multi-agent model with input constraints. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 63(8):1265–1275, 2016.
- [19] L. Zhou and S. Li. Distributed model predictive control for multi-agent flocking via neighbor screening optimization. *International Journal of Robust and Nonlinear Control*, 27(9):1690–1705, 2017.
- [20] 櫻間一徳, 小蔵正輝. 移動体の群制御への誘い:なぜ今群制御か. *システム/制御/情報*, 67(2):87–94, 2023.