

災害用運搬ロボットの自律走行の最適化

○菊光美樹男(北見工業大学), 渡辺美知子(北見工業大学),

鈴木育男(北見工業大学), 岩館健司(北見工業大学), 古川正志(北海道情報大学)

要旨

本研究では, 救援物資を運搬する多輪車両ロボットが障害物を回避しながら目的地まで自律走行する行動獲得を目的とする. 自律走行の獲得には, 機械学習と進化計算を融合させた進化学習の手法を用いる. 最後に数値シミュレーション実験で提案手法の有効性を検証する.

1. はじめに

災害発生時には, 建物の倒壊や火災, 洪水などにより被災者の救助やライフラインの整備, または災害後の復興支援が必要になる. 救助活動や支援活動は多くの人員を動員することにより迅速に行うことが出来る. しかし, 救助活動や支援活動を行える人員には限りがあり, 人による救助活動には限界がある. これらの問題を解消するには, 自律型のロボットを導入することが考えられ, 人手不足の解消や救助者の疲労軽減などの効果が期待出来る. 被災者の救助活動の一つとして救援物資の運搬作業があり, この作業を自律型のロボットが支援することにより, 救助活動が効率的に進めることが出来る.

本研究では, 救援物資を運搬する多輪車両ロボットが障害物を回避しながら目的地まで自律走行する行動獲得を目的とする. 自律走行の獲得には, 汎化能力がある人工ニューラルネットワーク(Artificial Neural Network, ANN)を採用し, このANNのニューロンの結合荷重の最適化には遺伝的アルゴリズム Genetic Algorithm, GA)を用いた. この提案手法の有効性を数値シミュレーション実験で検証する.

2. 三次元物理モデリング

三次元空間物理モデリングとは, 物理エンジンを用いてモデルとなるアクターが衝突, 摩擦, 重力などの現象を物理法則に則った数値計算を行うことにより物理運動を再現することができる. 例えば, 球による等速円運動, 反発係数の異なる球の衝突, 慣性の法則, 波動実験など様々な物理現象を再現することが可能である. 本研究で利用する物理エンジンは, NVIDIA社のPhysXを採用した.

3. 災害救助ロボットのモデリング

多輪車両の災害用運搬ロボットは図1の(a)に側面図, (b)に平面図, (c)に正面図を示している. モデルは, 先頭車両となる駆動車と荷物を積むコンテナで構成されている. 駆動車は全輪駆動で車両の操舵は二輪操舵であり, 二輪操舵は図2に示すアッカーマン・ジャント理論²⁾に基づいたステアリング方式を採用する. アッカーマンステアリングとは, 操舵輪の切れ角である内側操舵輪と外側操舵輪と後輪の回転中心が同一点になるように切れ角を式(1)より求めたステアリング方式である. モデルの駆動車の前方と最後尾の車両後方にはそれぞれ2個のセンサーを設置している. このセンサーは障害物と目的地の位置情報を計測するものである. このセンサー範囲は5.0[m]とする. Table.1にモデルの寸法を示す.

$$\frac{1}{\tan\beta} - \frac{1}{\tan\alpha} = \frac{T}{W} \quad (1)$$

β : 外側操舵輪の切れ角, α : 内側操舵輪の切れ角, T : 駆動車のトレッド, W : 駆動車のホイールベース




図1. 運搬用ロボットのモデリング




図2. アッカーマンステアリング

表1. モデルの寸法[m]

駆動車(全長×全幅×全高さ)	3.6×2.4×2.2
キャスター(全長×全幅×全高さ)	2.3×2.4×2.2
車輪(直径×幅)	1.2×0.4
T×W	2×2.8

4. 人工ニューラルネットワーク(ANN)

ANNは, 生物の脳の神経細胞のネットワーク構造を模倣した機械学習の一手法であり高い学習能力を持っている. 本研究では, フィードフォワード型の3層のANNを採用する. 本研究で用いたニューロン数は入力層9, 中間層13, 出力層2である. ANNの入力には式(2)を用いる. 式(2)は障害物と目的地それぞれを正負の光源と仮定し, その光源の光の強さの重ね合わせにより目的地と障害物の位置を認識する手法である. 出力関数には, シグモイド関数を採用した. ここで, シグモイド関数の値は(0≦f(x)≦1)の範囲とし

た. T は温度係数であり 0.1 とした. 出力値は操舵角と駆動車の角速度としている.

$$L = \sum_{t=0}^n \frac{B \cos \theta}{\gamma d^2} \quad (2)$$

n : 目的地と障害物の個数の合計, B : 光度, $\cos \theta$: モデルの各センサーと目的地, 障害物とのなす角の \cos 値, γ : 光の減衰率, d : センサーから目的地と障害物までの距離

5. 遺伝的アルゴリズム(GA)

GA は生物の進化を模倣した最適化手法の一つであり, ANN の重み係数を最適化するのに採用した. GA の個体は ANN の重み係数を実数値表現し, その個体に交叉, 突然変異, 選択, 淘汰の遺伝子操作を行い最適化する. また, 重み係数の初期値はランダムに発生させた数値を代入し, 範囲を $(-1 \leq w \leq 1)$ とする. 1step 数は 1/120s とする. 表 2 に GA の実験条件を示す.

表 2. GA の実験条件

個体数	100
世代数	200
ステップ数	3600
交叉率	0.2
突然変異率	0.1
淘汰率	0.2

6. 評価関数

評価関数は, 式(3)よりステップ毎にモデルの速度ベクトルと目的地方向のベクトルの内積の総和を求める. この内積の総和が大きいほど良い評価値とする. ここで, モデルがより障害物を回避する ANN の生成のためにモデルが障害物に近いほどペナルティを乗算する. また, 評価値 e は 3ヶ所の目的地それぞれで式(3)より計算された内, 最小の値を評価値とした. 図 3 は, モデルと障害物, 目的地との位置関係を示す.

$$R_i = \sum_{t=0}^n |\vec{v}_t| \cdot |\vec{a}_t| \cos \theta \cdot \prod_{i=0}^j \left(1 - \frac{1}{1 + \mu d_o^2}\right) \quad (3)$$

$$e = \min(R_i) \quad (4)$$

n : ステップ数, j : モデルに近い障害物の個数, μ : ウェイト, d_o : 障害物とモデルの距離,




図 3. モデルと目的地の関係

図 3 に示すように, ANN が多くのパターンを学習するために目的地を複数設定した. それらの中から式(3)より最小の値を NN の評価値とし学習させることで, 環境に適した NN を生成することが出来る. また, 障害物の個数は 30 個で位置は固定にした.

7. 数値シミュレーション実験

数値シミュレーション実験では, 複数の目的地と障害物をランダムに三次元物理内に生成する. モデルの初期位置は原点であり, 障害物の寸法は $(1.0 \times 1.2 \times 1.0)$ であり, モデルは初期位置から障害物を回避しながら目的地まで自律的に走行する行動の獲得を試みる.

8. 実験結果

図 4 は, GA による評価値の収束状況を示し, 縦軸に評価値と横軸に世代数を示している. 約 60 世代で収束していることが分かる. 図 5 は, 多輪車両の災害用運搬ロボットが右上の初期位置から左下の目的地方向に向かう走行軌跡を示している.

数値シミュレーション実験の結果, モデルは初期位置から目的地までランダムに設置された障害物を回避しながら自律的に到達することが確認された. 目的地に到達した後は, 目的地を任意の位置に発生した場合にもモデルは自律的に走行し目的地に到達したことも確認された.




図 4. GA による評価値の収束状況




図 5. モデルの自律走行の軌跡

9. おわりに

本研究では, 三次元物理空間内に災害用運搬ロボットをモデリングし, シミュレーション環境の整地内に設置された複数の障害物を回避しながら初期地点から目的地まで自律走行する行動獲得を行った. その結果, 以下のことが得られた.

1. モデルは機械学習の ANN と, 進化計算の GA を用い, 初期位置から目的地までの自律走行を確認した.
2. 目的地到達後, 新たな目的地を与えた場合にも, モデルは再び自律的に走行し目的地で停止することを確認した.

参考文献

- 1) 徳田 献一, レスキューロボットに見る災害対応の取り組み, pp21-26, 2015
- 2) 江村 超, 荒川 章, 非円型歯車を用いたステアリング機構の研究*(第 1 報, 機構の提案と解析), 日本機械学会論文集(C 編), 57 巻 533 号, p154~p155, 1991