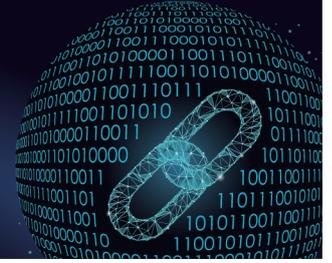




中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于态势图序列的多智能群体意图识别

杜沁龙, 霍鑫, 郑凯, 周典乐

引用本文:

杜沁龙, 霍鑫, 郑凯, 周典乐. 基于态势图序列的多智能群体意图识别[J]. *控制与决策*, 2024, 39(9): 2941–2949.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0526>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进卷积神经网络的动力下肢假肢运动意图识别

Intent recognition of power lower-limb prosthesis based on improved convolutional neural network

控制与决策. 2021, 36(12): 3031–3038 <https://doi.org/10.13195/j.kzyjc.2020.0326>

基于图卷积网络的行为识别方法综述

A survey of action recognition methods based on graph convolutional network

控制与决策. 2021, 36(7): 1537–1546 <https://doi.org/10.13195/j.kzyjc.2020.0514>

基于深度学习的仿生集群运动智能控制

Intelligent control of bionic collective motion based on deep learning

控制与决策. 2021, 36(9): 2195–2202 <https://doi.org/10.13195/j.kzyjc.2020.0071>

基于观测器的网络化多智能体预测控制

Observer-based networked multi-agent predictive control

控制与决策. 2021, 36(9): 2290–2296 <https://doi.org/10.13195/j.kzyjc.2019.1801>

自适应事件触发的马尔科夫跳变多智能体系统一致性

Adaptive event-triggered consensus for Markovian jumping multi-agent systems

控制与决策. 2020, 35(11): 2780–2786 <https://doi.org/10.13195/j.kzyjc.2018.1507>

基于态势图序列的多智能群体意图识别

杜沁龙¹, 霍鑫^{1†}, 郑凯², 周典乐³

(1. 哈尔滨工业大学 控制与仿真中心, 哈尔滨 150080; 2. 大连海事大学 船舶电器工程学院, 辽宁 大连 116026; 3. 国防科技大学 前沿交叉学科学院, 长沙 410073)

摘要: 智能群体的意图识别是多智能体领域的一个热点问题,在自动驾驶、人机交互及国防军事等领域具有广泛应用. 由于智能群体规模及环境内障碍物分布具有不确定性,现有意图识别模型的泛化能力往往有限,鉴于此,提出一种基于态势图序列的意图识别方法,将观测得到的智能群体信息转化为态势图序列,通过态势图序列训练识别模型,从而降低模型对智能体数量的敏感程度. 针对含有障碍物的环境,提出阻碍态势的生成方法,从而提高模型对环境变化的适应能力. 此外,为降低对专家知识的依赖,采用卷积神经网络估计各个智能体的斥力因子. 最后,与其他几种意图识别方法对比并进行消融实验以验证所提出方法的准确性和泛化能力.

关键词: 运动态势图; 意图识别; 多智能体系统; 深度学习; 群体意图; 长短时记忆网络

中图分类号: TP391 文献标志码: A

DOI: 10.13195/j.kzyjc.2023.0526

引用格式: 杜沁龙,霍鑫,郑凯,等. 基于态势图序列的多智能群体意图识别[J]. 控制与决策, 2024, 39(9): 2941-2949.

Intention recognition for multiple agents based on situation map sequence

DU Qin-long¹, HUO Xin^{1†}, ZHENG Kai², ZHOU Dian-le³

(1. Control and Simulation Center, Harbin Institute of Technology, Harbin 150080, China; 2. College of Marine Electrical Engineering, Dalian Maritime University, Dalian 116026, China; 3. College of Advanced Interdisciplinary Studies, National University of Defense Technology, Changsha 410073, China)

Abstract: Intention recognition for multiple agents is an important problem in multi-agent systems, and is widely used in autonomous driving, human-machine interaction and military field. Due to the uncertainty in the scale of multiple agents and the distribution of obstacles, the generalization ability of a current intention recognition model is limited. To reduce the sensitivity of the model to the number of agents, an intention recognition algorithm based on a situation map sequence is proposed. The observed information of multiple agents is converted into the situation map sequence and the model is trained based on the situation map sequence. In order to improve the adaptability of the model, the generating method of the obstructive situation map is proposed for situations with obstacles. In addition, in order to reduce the dependence on expert knowledge, the repulsive field factor is estimated using convolutional neural networks. Finally, the proposed method is compared with other methods and ablation experiments are conducted. The accuracy and generalization ability of the proposed algorithm are verified by the results.

Keywords: situation map; intention recognition; multi-agent systems; deep learning; group intention; long short-term memory

0 引言

近年来,随着人工智能技术的发展,多智能体技术已经逐步被应用于自动驾驶、人机交互及国防军事等领域^[1-3],其中智能群体的意图识别技术是多智能体领域的一项热门研究内容. 对于一个经典BDI (belief-desire-intention) 智能体,智能体意图代表其最终希望实现的目标. 智能群体的意图识别即为

基于智能群体行为及环境信息,实现智能群体期望目标预测的过程^[4]. 在战场态势评估领域,意图识别是将输入信息从信息域转化至认知域的重要一环. 随着科学技术的发展和军事技术的变革,意图识别在辅助指挥及智能装备上逐渐得到应用. 使用意图识别进行智能指挥能够帮助己方及时理解对方的进攻行为,进而指导己方采取相应决策,该项技术在未来的

收稿日期: 2023-04-21; 录用日期: 2023-08-21.

基金项目: 国家自然科学基金项目(62373128); 国家自然科学基金基础科学中心项目(62188101); 黑龙江省自然科学基金项目(LH2021F025).

责任编辑: 方勇纯.

[†]通讯作者. E-mail: huoxin@hit.edu.cn.

战场环境势必发挥巨大作用^[5].

传统的智能体意图识别问题主要使用基于贝叶斯网络 (Bayesian networks, BN) 的推理框架,且集中于单个智能体的意图识别^[6-7]. 贝叶斯推理的方法能够充分利用已有的专家知识库,具有较好的意图识别效果及较高的稳定性. 然而,该类方法对输入数据的形式比较敏感,当智能体数量或环境发生改变时,其识别效果难以保证. 此外,在智能群体的协同与对抗问题中,智能群体中的各个智能体信息往往具有较高的相关性,此时贝叶斯网络的预测能力有限.

近年来,人工智能及深度学习技术已经取得了较大突破,基于深度学习的意图识别方法对时间序列数据具有优秀的处理能力,并逐渐成为当前的研究热点^[8-11]. 文献[12]针对多智能体对抗问题中的复杂场景及欺骗性数据,提出加权对比预测编码的网络结构,以获取环境信息的全局结构,并采用带注意力权重分配的长短时记忆网络 (long short-term memory, LSTM) 结构进行意图识别. 文献[13]将模糊加权与深度学习方法相结合,提高了数据融合的有效性,从而实现不确定、不完全信息下的全局目标识别. 文献[14]则针对意图识别模型的可解释性及时间上的前后依赖性,提出带有条件随机场及时空注意力机制的双向门控神经元结构,并取得了较好的效果.

目前,多智能体意图识别领域的研究主要集中在意图识别模型的改进上,如果能够对输入数据进行合适的预处理,最终的意图识别效果将得到进一步提升. 本文将运动态势图^[15]引入智能群体的意图识别问题中,提出一种基于态势图序列的意图识别方法. 将数量不固定的智能群体信息和环境信息转化为态势图序列,并用于后续模型训练,为解决意图识别中智能体数量的不确定性问题提供了一种新的思路. 本文主要贡献如下:针对意图识别问题中智能体数量不确定的情况,提出将智能体原始信息转化为态势图序列的数据预处理方法;提出障碍物态势图的生成方式,解决存在障碍物环境下多智能群体的意图识别问题;针对先验知识缺乏的情况,提出基于卷积神经网络的斥力因子估计方法,从而降低对于专家知识的依赖;最后将所提出方法与其他几种方法进行对比并进行消融实验,验证了所提出方法在准确率及泛化能力上的优势.

1 智能群体意图识别问题描述

在智能群体的对抗问题中,对方智能群体的意图对己方的决策具有极大的参考价值. 然而,智能群体的意图一般无法直接观测,仅能通过其他可观测的信

息进行推理及预测,这种针对对方智能群体意图的预测行为即为智能群体的意图识别问题.

在智能群体的意图识别问题中,可观测的信息主要包括环境特征、智能体属性和智能体状态3类. 其中:环境特征包括地形和障碍物信息等智能体能够直接或间接观测得到的信息;智能体属性是智能体的固有信息,包括智能体的敌我属性及型号等不随时间变化的信息;智能体状态包括智能体的位置、速度等随时间变化明显的信息.

本文假设对方智能群体的意图包括围捕、拦截、追踪及无关4种,如图1所示. 智能群体的围捕意图如图1(a)所示,智能群体需要限制目标向四周的运动,其目标点分布在以目标为圆心的圆周上;智能群体的拦截意图如图1(b)所示,智能群体需要限制目标向前方的运动,其目标点分布在目标前方一定范围内;智能群体的追踪意图如图1(c)所示,智能群体需要跟随目标运动,其目标点分布在智能体后方一定范围内;智能群体的无关意图如图1(d)所示,此时对方智能群体的运动与己方无关.

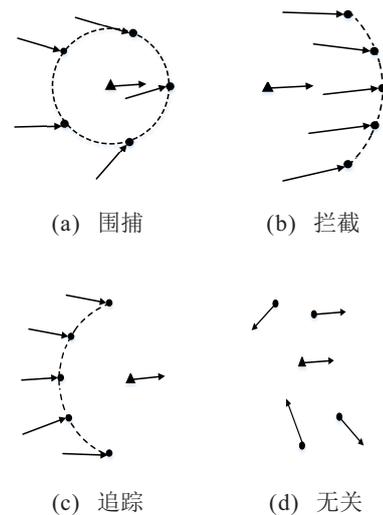


图1 智能群体4种意图

意图识别问题优化目标如下:

$$J = \frac{1}{D} \sum_{i=1}^D \|Y_{(i)} - Y'_{(i)}\|_2. \quad (1)$$

其中: J 为意图识别的优化指标, $Y_{(i)}$ 、 $Y'_{(i)}$ 分别为数据集中第*i*个样本中智能体意图真实值和预测结果, D 为数据集中样本个数,且有

$$Y'_{(i)} = \text{model}(S_{(i)}, P_{(i)}, O_{(i)}; \omega). \quad (2)$$

这里: $\text{model}(\cdot)$ 为意图识别模型, $S_{(i)}$ 、 $P_{(i)}$ 和 $O_{(i)}$ 分别为第*i*个样本中智能体的状态、属性和环境信息, ω 为意图识别模型参数. 最优参数可由下式确定:

$$\Omega^* = \arg \min_{\omega} J(\omega), \quad (3)$$

其中 Ω^* 为模型参数最优值.

2 运动态势图序列

本文在对原始数据的预处理中引入运动态势图的概念,假设双方智能体能够产生符号相反的斥力场,从而将智能群体状态数据转化为固定尺寸的运动态势图. 运动态势图以人工势场法为基础,在空间对虚拟斥力场进行采样和叠加获得其表征.

2.1 人工势场法

人工势场法主要被用于智能体避障路径规划^[16]. 该方法中,智能体的目标点能够对智能体产生引力场,其数学描述如下:

$$U_{att}(q) = \frac{1}{2}\xi(\rho(q, q_{goal}))^2. \quad (4)$$

其中: $U_{att}(q)$ 为目标点产生的引力场, ξ 为引力尺度因子, q 和 q_{goal} 分别为智能体与目标点的位置, $\rho(q, q_{goal})$ 为智能体与目标点之间的距离.

与之对应,环境中的障碍物能够对智能体产生斥力场,其数学描述如下:

$$U_{rep}(q) = \begin{cases} \frac{1}{2}\eta\left(\frac{1}{\rho(q, q_{obs})} - \frac{1}{\rho_0}\right)^2, & \rho(q, q_{obs}) \leq \rho_0; \\ 0, & \rho(q, q_{obs}) > \rho_0. \end{cases} \quad (5)$$

其中: $U_{rep}(q)$ 为障碍物产生的斥力场, η 为斥力尺度因子, q_{obs} 为障碍物的位置, $\rho(q, q_{obs})$ 为智能体与障碍物之间的距离, ρ_0 为障碍物影响的最大范围.

对环境内所有虚拟力场进行叠加即可获得合力场,智能体沿合力场的梯度方向运动,合力场的叠加公式如下:

$$U(q) = U_{att}(q) + \sum_{i=1}^M U_{rep}^i(q). \quad (6)$$

其中: $U(q)$ 为叠加后的态势, $U_{rep}^i(q)$ 为第 i 个障碍物产生的斥力场, M 为环境内障碍物总数.

2.2 智能体运动态势图生成

2.2.1 单个智能体运动态势生成

传统人工势场法的斥力场计算中,斥力场大小在智能体位置附近趋于无穷. 在运动态势图生成的采样过程中,这些无穷点可能被采样用作态势图的运动态势,从而导致态势图归一化后出现空间梯度信息损失甚至奇异,因此需要为智能体的运动态势设置阈值. 本文通过改写斥力场计算公式实现阈值的设置,斥力场计算如下:

$$U_i(q) = \eta_i[1 - \tanh(\rho(q, q_a))]. \quad (7)$$

其中: $U_i(q)$ 为第 i 个智能体单独产生的虚拟斥力场, η_i 为第 i 个智能体的斥力场尺度因子, q 与 q_a 分别为待求点与智能体的位置, $\rho(q, q_a)$ 为待求位置到智能体的距离. 这样计算得到的智能体斥力场幅值被限制在 $(0, \eta_i]$ 内,且避免了态势图中梯度信息损失,更适合作为意图识别模型的输入.

式(7)中的斥力场因子由当前时刻所有智能体的状态与属性及障碍物信息共同决定,即

$$\eta_i = \alpha(P, S_i, O), \quad (8)$$

其中 $\alpha(\cdot, \cdot, \cdot)$ 为智能体属性与状态及障碍物信息到尺度因子的映射,需要依据专家知识构建.

基于得出的斥力场,在给定位态势图尺寸 $[l_x, l_y]$ 和空间采样间隔 l_s 在空间上采样,生成的二维图像数据即为单个智能体的运动态势图.

2.2.2 智能群体运动态势合成

环境的总态势图可由环境内单个智能体的态势图叠加得到. 本文中,由于环境内双方智能群体数量相差较大,直接叠加态势图分量可能导致数量较少一方的智能体信息无法在态势图中体现. 针对此问题,在双方智能体态势图叠加前分组归一化,即

$$\begin{aligned} \Theta_p^t &= \frac{\sum_{i=1}^M \theta_i^t}{\sum_{i=1}^M \eta_i}, \\ \Theta_n^t &= \frac{\sum_{i=M+1}^{M+N} \theta_j^t}{\sum_{i=M+1}^{M+N} \eta_j}, \\ \Theta^t &= \frac{\Theta_p^t}{\max(\Theta_p^t)} + \frac{\Theta_n^t}{\max(\Theta_n^t)}. \end{aligned} \quad (9)$$

其中: Θ^t 为最终态势图, θ_i^t 为第 i 个智能体单独作用时产生的态势图, Θ_p^t 和 Θ_n^t 分别为双方智能体的叠加态势图, M 和 N 分别为双方智能体的总数量.

图2展示了分组归一化对最终态势图的影响. 当环境内双方智能群体规模差距较大时,如果不分组归一化,则数量较少一方智能群体的态势信息会被掩盖,而分组归一化后的态势图能够避免这一问题.

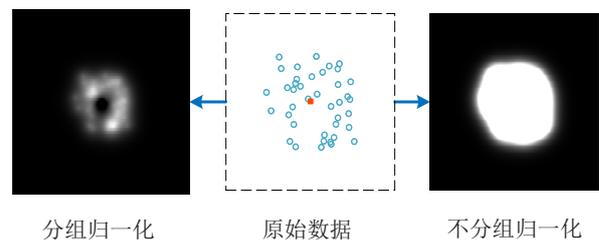


图2 是否分组归一化得到的态势图对比

2.3 障碍物阻碍态势生成

当环境中存在障碍物时,双方智能群体的运动趋势不仅与己方意图及对方位置相关,还受到障碍物位置的影响.针对存在障碍物的情况,需要额外生成包含障碍物信息的阻碍态势图.相较于智能体,障碍物一般尺寸更大且形状不规则,其形状可以采用栅格法描述.在栅格描述下,障碍物由若干矩形组成,此时将单个障碍物栅格的态势描述如下:

$$U_{rep}(q) = \begin{cases} \frac{1}{2}\beta\left(\frac{1}{l_o} - \frac{1}{\rho_1}\right)^2, & r(q, q_{obs}) \leq l_o; \\ \frac{1}{2}\beta\left(\frac{1}{r(q, q_{obs})} - \frac{1}{\rho_1}\right)^2, & l_o < r(q, q_{obs}) \leq \rho_1; \\ 0, & r(q, q_{obs}) > \rho_1. \end{cases} \quad (10)$$

其中: $r(q, q_{obs})$ 为待求点与障碍物之间的曼哈顿距离, l_o 为障碍物最小栅格的边长, ρ_1 为障碍物态势影响的最大范围, β 为障碍物对应的斥力场影响因子.

为实现对障碍物更精确的描述,使用以下方法合成障碍物的阻碍势场:

$$U(q) = \max_{i=1}^{n_o} U_i^o(q). \quad (11)$$

其中: n_o 为障碍物栅格的数量, $U_i^o(q)$ 为第 i 个障碍物栅格产生的势场.将生成的态势图进一步在空间上采样,即可获得障碍物的阻碍态势图 θ_o .

几种不同方法生成的阻碍态势图如图3所示.图3(a)使用本文的态势图生成方法,这样生成的阻碍态势图能够较好地保留障碍物的边缘信息;图3(b)使用

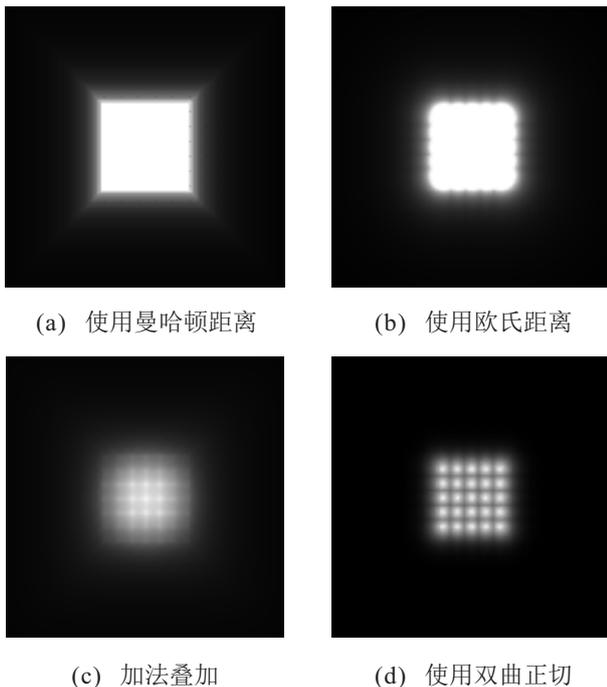


图3 不同方法生成的阻碍态势图对比

欧氏距离计算阻碍态势图,障碍物的部分边缘信息被破坏;图3(c)直接对障碍物态势进行叠加得到态势图,障碍物栅格交接处的态势被放大;图3(d)使用智能体运动态势的方法得到态势图,障碍物的栅格被明显分开,不适用于对障碍物的描述.

3 基于态势图序列的群体意图识别

在智能群体及障碍物态势图生成的基础上,综合当前时刻态势图与过去的智能体运动态势即可实现对智能群体意图的预测.本文采用深度学习的方法估计各个智能体的斥力因子并实现意图识别.

3.1 斥力因子估计

在运动态势图的生成过程中,智能体的斥力场大小受到其斥力因子的影响,斥力因子一般由经验公式确定.为降低方法对专家知识的依赖,本文使用神经网络对斥力因子进行估计.

在神经网络训练过程中,为保证梯度能够正常反向传播,计算生成各个智能体对应的临时态势图作为斥力因子估计输入,并使用卷积神经网络对其进行处理.斥力因子估计及运动态势图生成过程如图4所示.

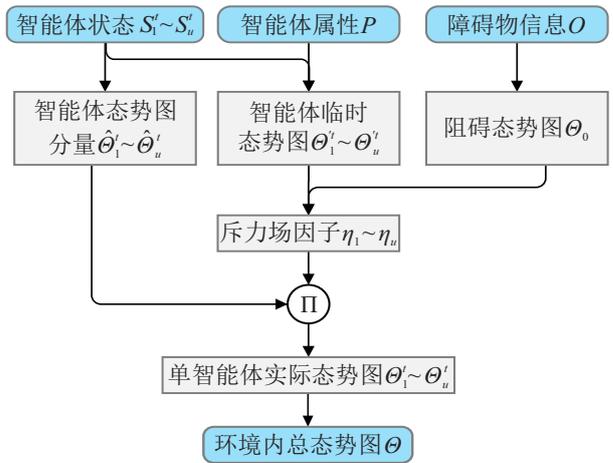


图4 斥力因子估计及态势图生成流程

令各个智能体的斥力因子为1,计算 t 时刻各个智能体单独作用的运动态势图,并按下式进行叠加,得到临时运动态势图:

$$\theta_i^t = \begin{cases} \frac{\sum_{j=N+1}^{N+M} \hat{\theta}_j^t}{M}, & 1 \leq i \leq N; \\ \frac{\sum_{j=1}^N \hat{\theta}_j^t}{N}, & i \geq N + 1. \end{cases} \quad (12)$$

其中: $\hat{\theta}_i^t$ 为斥力因子为1时第 i 个智能体的运动态势图, θ_i^t 为第 i 个智能体的临时运动态势图.

为得到期望的斥力场因子,训练卷积神经网络估

计斥力场因子,优化目标如下:

$$J' = \sum_{i=1}^u (\hat{\eta}_i - \eta_i)^2. \quad (13)$$

其中: J' 为该部分模型优化指标, $\hat{\eta}_i$ 为估计的第 i 个智能体的引力因子, u 为双方智能体数量和, 且有

$$\hat{\eta}_i = \text{convnet}(\Theta_i^t, \Theta_o), \quad (14)$$

这里 $\text{convnet}(\cdot, \cdot)$ 为卷积神经网络的运算. 理想的引力场因子可由下式确定:

$$\eta^* = \arg \min_{\eta} J'(\eta), \quad (15)$$

其中 η^* 为理想的引力场因子.

在本问题中, 当模型意图识别效果最好时, 对应的引力场因子计算方法最优, 式(1)与(13)的优化方向一致, 因此本部分模型可以与后续意图识别模型同时训练. 最后综合斥力场因子及单智能体的运动态势图, 依据式(9)叠加生成最终的环境运动态势图.

注1 使用神经网络进行斥力因子估计时, 最终估计结果取值无界则可能导致训练难以收敛. 考虑到态势图的实际意义, 将神经网络的输出经 Sigmoid 函数处理后再用于态势图叠加, 从而避免无法收敛的问题.

3.2 意图识别模型结构

基于深度学习方法设计意图识别模型, 使用卷积神经网络与循环神经元结合的模型预测智能群体意图, 结构如图5所示.

在智能群体意图识别问题中, 智能群体队形的形成需要一定时间, 对其意图的判断与一段时间内的数据相关. 因此本文使用智能群体运动态势图序列及障碍物阻碍态势图作为意图识别输入. 卷积神经网络具有局部感知与权值共享的特点, 其在处理空间特征上具有一定优势, 因此本文用其对运动态势图及阻碍态势图的空间特征进行处理. 循环神经网络中的 LSTM 对时间特征具有较好的处理能力, 且能够防止

梯度消失与梯度爆炸的产生, 因此使用 LSTM 进一步对运动态势图序列的时间特征进行处理. 最后将两个通道得到的特征融合, 并通过全连接层处理得到最终预测结果.

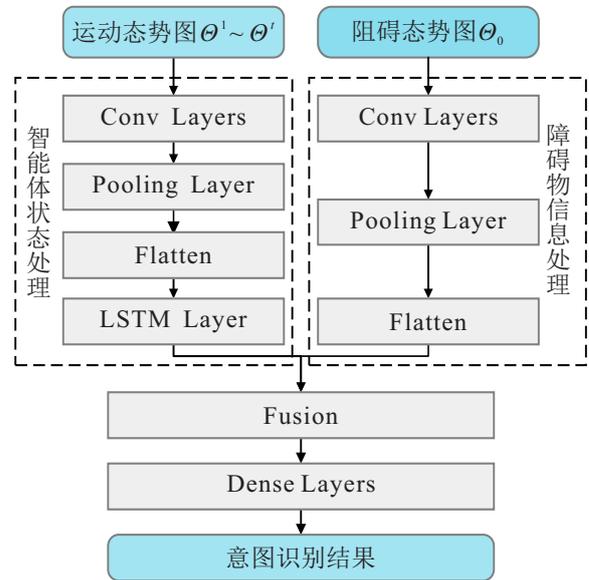


图5 意图识别模型结构

3.3 多智能体群体意图识别算法流程

基于态势图序列的多智能体意图识别在线算法流程如图6所示, 具体步骤如下.

step 1: 确定环境尺寸 $[l_x, l_y]$ 、空间采样间隔 l_s 及障碍物态势的最大影响范围 ρ_1 .

step 2: 观测智能体的敌我属性 $P_1 \sim P_u$ 及环境内障碍物分布 O , 按照式(10)和(11)求取障碍物的阻碍态势图 Θ_o .

step 3: 观测 t 时刻智能体的位置信息 $S_1^t \sim S_u^t$, 生成单智能体运动态势图 $\hat{\Theta}_1^t \sim \hat{\Theta}_u^t$.

step 4: 基于单智能体态势图, 使用卷积神经网络估计智能体的斥力场因子 $\eta_1 \sim \eta_u$.

step 5: 基于单智能体态势图及斥力场因子, 分组归一化并合成得到当前时刻运动态势图 Θ^t .

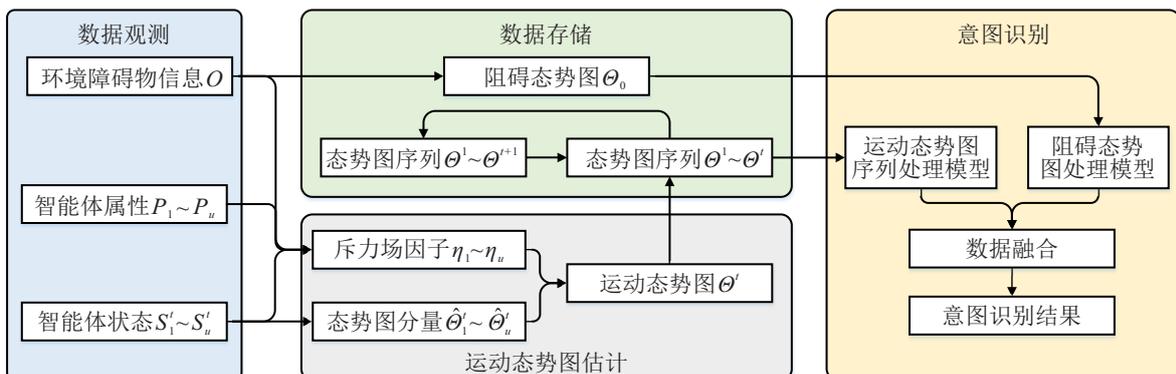


图6 本文意图识别算法流程

step 6: 采用卷积神经网络提取阻碍态势图特征, 并采用卷积神经网络与循环神经网络结合方法提取运动态势图特征, 最后融合两个通道的特征得出意图识别结果.

step 7: 若已经完成识别, 则识别结束, 转至智能群体的决策算法; 若未完成识别, 则转至 step 2.

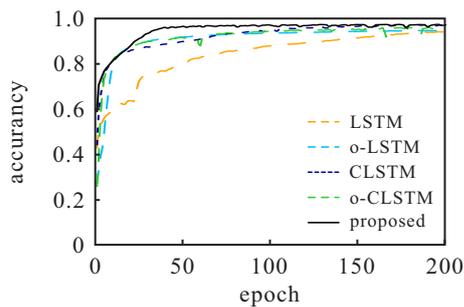
4 仿真算例

本文选用计算机仿真数据作为数据集, 在仿真过程中随机初始化智能体意图、初始位置、路径规划方法及队形参数等条件. 其中训练集中智能体数量固定, 测试集根据智能体数量是否与训练集一致分为两部分. 模型的效果以更具一般性的测试集上的 $\text{macro-}f_1$ 指标^[17]及仿真实验过程中的误报率作为评价标准.

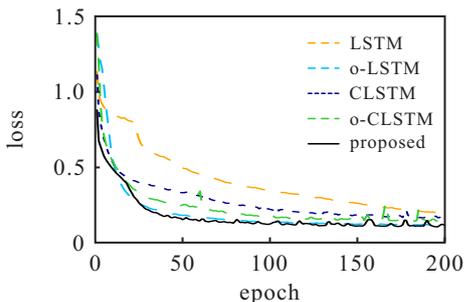
实验环境: Intel Core i9-11900H CPU, NVIDIA RTX 3060 GPU. 软件环境: 运行环境 Python 3.9.7, 操作系统为 Windows 10. 本文使用几种处理时间序列的常用方法与本文方法进行对比, 其中 LSTM^[18]为长短时神经网络模型, CLSTM^[19]为卷积层与 LSTM 结合方法, diff-为差分得到速度训练的模型, o-为考虑障碍物信息的模型, proposed 为本文提出的模型.

4.1 意图识别模型训练结果

本文的意图识别模型与其他对比方法的训练结果如图 7 所示. 通过准确率和损失曲线可以看出, 本文在准确率及损失上比其他对比方法能更快地收敛至较优值, 其中准确率收敛至 96%, 损失收敛至 0.11, 此时限制模型损失进一步下降的主要因素为数据集



(a) 训练过程中的准确率



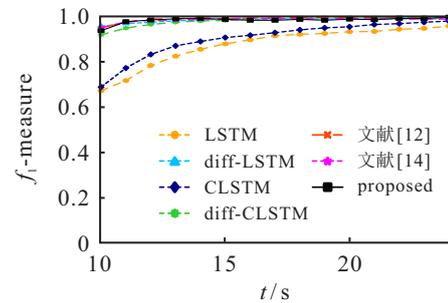
(b) 训练过程中的损失

图 7 训练过程中准确率及损失

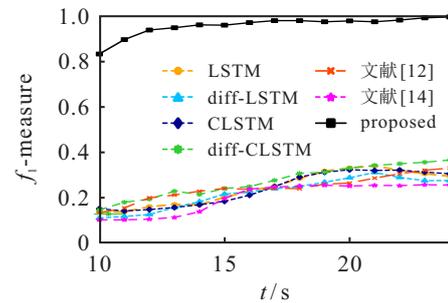
中包含部分特征不明显数据.

4.2 无障碍物环境下的识别结果

为验证本文模型的识别能力, 首先在不存在障碍物且智能群体规模固定的环境下测试, 结果如图 8(a) 所示. 直接使用 LSTM 或 CLSTM 方法进行意图识别, 识别耗时较长; 对轨迹信息差分的模型以及文献 [12] 和文献 [14] 方法效果与本文基于态势图序列的方法相近. 然而, 当测试集中智能体数量发生变化时, 其他几种方法 f_1 指标大幅下降, 如图 8(b) 所示. 本文方法的 f_1 指标虽然较智能体数量不变时稍有下降, 但仍远高于其他几种方法. 表明本文将智能体轨迹信息转化为态势图序列后, 意图识别模型对于智能体数量变化的敏感性明显降低.



(a) 智能体数量不变时测试结果

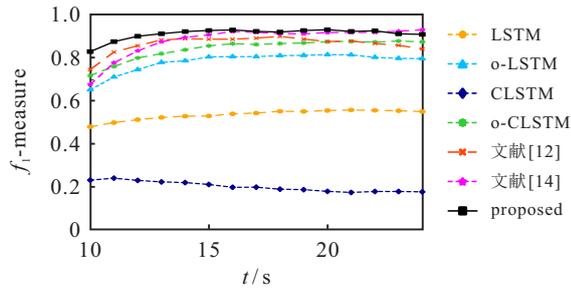


(b) 智能体数量变化时测试结果

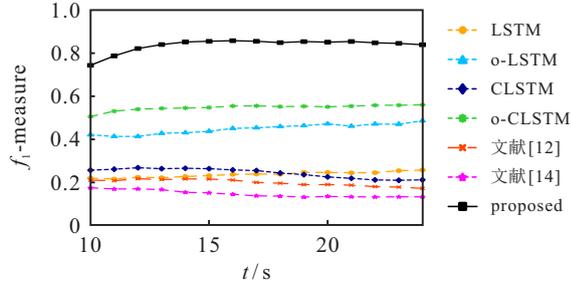
图 8 无障碍物时测试结果

4.3 有障碍物环境下的识别结果

当环境内存在障碍物时, 测试结果如图 9(a) 所示. 不考虑障碍物信息的模型无法完成识别, 考虑障碍物且使用 LSTM 及 CLSTM 的模型 f_1 指标较低, 文献 [12] 与文献 [14] 方法在智能体数量不变时效果与本文相近. 改变测试集中智能体的数量, 测试结果如图 9(b) 所示. 不考虑障碍物的模型仍然无法有效识别智能体意图, 考虑障碍物的 LSTM 及 CLSTM 模型的 f_1 指标发生大幅下降, 文献 [12] 与文献 [14] 的方法在这种情况下也几乎失去识别能力. 本文方法的 f_1 指标虽然略有下降, 但效果明显优于其他几种方法. 表明本文将障碍物信息转化为阻碍态势图的方法能够有效应对存在障碍物的情况, 且能够保证意图识别方法在存在障碍物时对智能体数量不敏感.

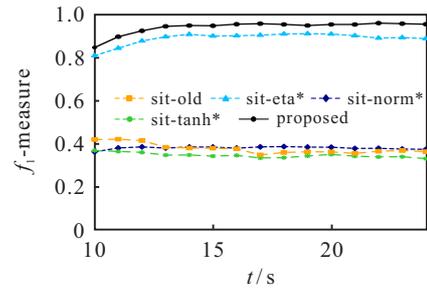


(a) 智能体数量不变时测试结果

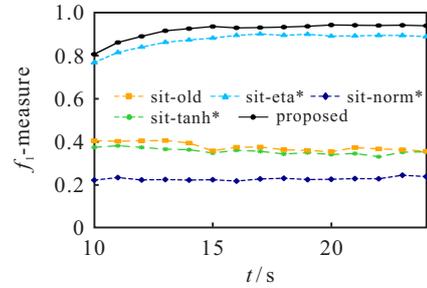


(b) 智能体数量变化时测试结果

图9 有障碍物时测试结果



(a) 智能体数量不变时消融实验



(b) 智能体数量变化时消融实验

图10 消融实验结果

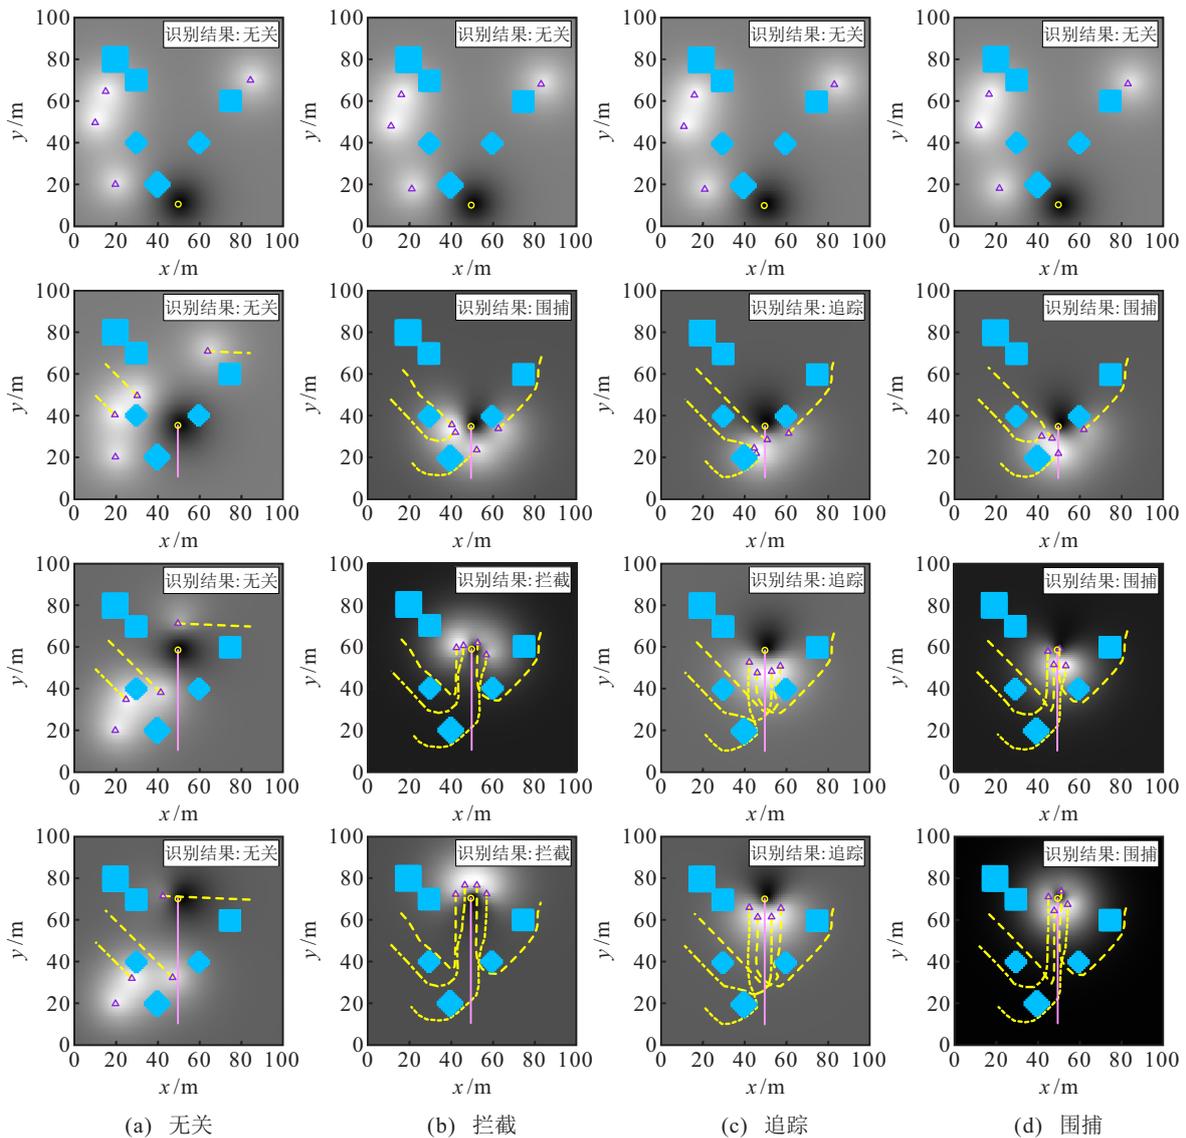


图11 智能体意图识别仿真算例

4.4 消融实验

为验证本文方法各部分的作用,设计消融实验进行测试,结果如图10所示.其中: η^* 表示不进行斥力因子估计, norm^* 表示不分组归一化, tanh^* 表示使用传统斥力场公式,old为原始方法.

本文的分组归一化及斥力场计算方法同时使用能够大幅提升意图识别模型的效果;此外,斥力因子估计对意图识别模型的 f_1 指标在两种情况下有5%~10%的提升,能够进一步提升意图识别模型效果.

4.5 有障碍物环境下的仿真算例

选取几种典型的多智能体对抗场景对意图识别模型进行测试,结果如图11所示.图11(a)为智能群体无关意图的识别结果,意图识别模型没有检测到攻击意图;图11(b)为智能群体拦截意图的识别结果,模型经一段时间误判后成功识别对方意图,此处误判主要是由于在智能群体队形形成过程中,实验早期智能群体意图特征还未显现,难以通过智能体运动状态在此时进行识别;图11(c)和图11(d)分别为智能群体追踪、围捕意图的识别结果,模型能够在对方进攻态势形成前正确识别.

进一步添加10组40次实验,其中5组实验智能体数量与训练集一致,其余5组实验智能体数量与训练集不同,几种意图识别方法误报率如表1所示.与其他几种方法相比,本文方法在智能体变化的情况下具有较大优势.

表1 各种意图识别模型的误报率 %

t/s	proposed	LSTM	CLSTM	文献[12]	文献[14]
10	27.5	47.5	45.0	40.0	52.5
15	12.5	40.0	37.5	30.0	47.5
20	5.0	37.5	32.5	27.5	42.5
25	5.0	37.5	32.5	27.5	45.0

5 结论

本文提出了一种基于态势图序列的智能群体意图识别方法,该方法在存在障碍物的环境下意图识别准确率较高,且泛化能力更强.针对意图识别问题的特点,设计了智能体运动态势图的生成过程,并提供了阻碍态势图的生成方法;为降低对专家知识的依赖性,采用卷积神经网络估计智能体的斥力场因子;最后进行仿真实验,结果验证了所提出方法具有较高的意图识别准确率及较好的泛化能力.通过将智能体及障碍物信息转化为态势图,为解决智能群体意

图识别中智能体数量的不确定性问题提供了一种新的思路.所提出方法在多智能体意图识别领域具有一定理论研究价值,对战场态势评估领域具有指导作用,并能够在智能装备的决策过程发挥关键作用.本文目前考虑的情况中,环境内所需信息均能被完整观测,后续将对观测信息不完全、不完备情况下的意图识别问题开展研究.

参考文献(References)

- [1] Schlenoff C, Kootbally Z, Pietromartire A, et al. Intention recognition in manufacturing applications[J]. *Robotics and Computer-Integrated Manufacturing*, 2015, 33: 29-41.
- [2] 盛敏, 夏安琦, 王可林, 等. 基于几何与物理特征融合的智能下肢假肢运动意图识别[J]. *控制与决策*, 2022, 37(4): 953-961.
(Sheng M, Xia A Q, Wang K L, et al. Movement intention recognition of intelligent lower limb prosthesis based on the fusion of geometric and physical features[J]. *Control and Decision*, 2022, 37(4): 953-961.)
- [3] 苏本跃, 倪钰, 盛敏, 等. 基于改进卷积神经网络的动力下肢假肢运动意图识别[J]. *控制与决策*, 2021, 36(12): 3031-3038.
(Su B Y, Ni Y, Sheng M, et al. Intent recognition of power lower-limb prosthesis based on improved convolutional neural network[J]. *Control and Decision*, 2021, 36(12): 3031-3038.)
- [4] Zhang Z, Zeng Y F, Jiang W H, et al. Intention recognition for multiple agents[J]. *Information Sciences*, 2023, 628(5): 360-376.
- [5] Sun Z X, Piao H Y, Yang Z, et al. Multi-agent hierarchical policy gradient for air combat tactics emergence via self-play[J]. *Engineering Applications of Artificial Intelligence*, 2021, 98(2): 104112.
- [6] 高巍, 罗俊仁, 袁唯淋, 等. 面向对手建模的意图识别方法综述[J]. *网络与信息安全学报*, 2021, 7(4): 86-100.
(Gao W, Luo J R, Yuan W L, et al. Survey of intention recognition for opponent modeling[J]. *Chinese Journal of Network and Information Security*, 2021, 7(4): 86-100.)
- [7] 乔殿峰, 梁彦, 马超雄, 等. 多域作战下的群目标意图识别与预测[J]. *系统工程与电子技术*, 2022, 44(11): 3403-3412.
(Qiao D F, Liang Y, Ma C X, et al. Recognition and prediction of group target intention in multi-domain operations[J]. *Systems Engineering and Electronics*, 2022, 44(11): 3403-3412.)
- [8] Sun T Y, Hu Q, Gulati P, et al. Temporal dilation of deep LSTM for agile decoding of sEMG: Application

- in prediction of upper-limb motor intention in neuro robotics[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 6212-6219.
- [9] 王昊冉, 老松杨, 白亮, 等. 基于MEBN的战术级空中目标意图识别[J]. 火力与指挥控制, 2012, 37(10): 133-138.
(Wang H R, Lao S Y, Bai L, et al. Tactical air target intention recognition based on multi-entities Bayesian network[J]. Fire Control & Command Control, 2012, 37(10): 133-138.)
- [10] 周旺旺, 姚佩阳, 张杰勇, 等. 基于深度神经网络的空中目标作战意图识别[J]. 航空学报, 2018, 39(11): 195-203.
(Zhou W W, Yao P Y, Zhang J Y, et al. Combat intention recognition for aerial targets based on deep neural network[J]. Acta Aeronautica et Astronautica Sinica, 2018, 39(11): 195-203.)
- [11] Wang X Y, Yang Z, Zhan G, et al. Tactical intention recognition method of air combat target based on BiLSTM network[C]. IEEE International Conference on Unmanned Systems. Guangzhou, 2022: 63-67.
- [12] Chen L, Liang X X, Feng Y H, et al. Online intention recognition with incomplete information based on a weighted contrastive predictive coding model in wargame[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022(99): 1-14.
- [13] Zhang Z, Wang H F, Geng J, et al. An information fusion method based on deep learning and fuzzy discount-weighting for target intention recognition[J]. Engineering Applications of Artificial Intelligence, 2022, 109: 104610.
- [14] Wang S Y, Wang G, Fu Q, et al. STABC-IR: An air target intention recognition method based on bidirectional gated recurrent unit and conditional random field with space-time attention mechanism[J]. Chinese Journal of Aeronautics, 2023, 36(3): 316-334.
- [15] Gao Q Q, Zheng K, Jiang Y, et al. An optimal path planning algorithm for cooperative USVs situation control[C]. The 5th CAA International Conference on Vehicular Control and Intelligence. Tianjin, 2022: 1-5.
- [16] Khatib O. Real-time obstacle avoidance for manipulators and mobile robots[J]. International Journal of Robotics Research, 1986, 5(1): 90-98.
- [17] Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks[J]. Information Processing & Management, 2009, 45(4): 427-437.
- [18] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [19] Zhao J F, Mao X, Chen L J. Speech emotion recognition using deep 1D & 2D CNN LSTM networks[J]. Biomedical Signal Processing and Control, 2019, 47(1): 312-323.

作者简介

杜沁龙(2000—), 男, 硕士生, 从事智能群体意图识别的研究, E-mail: 22S104194@stu.hit.edu.cn;

霍鑫(1981—), 男, 教授, 博士, 从事模式识别与无人系统的研究, E-mail: huoxin@hit.edu.cn;

郑凯(1981—), 男, 教授, 博士, 从事船舶自动化、非线性控制理论及应用等研究, E-mail: kzh@dlnu.edu.cn;

周典乐(1983—), 男, 讲师, 博士, 从事军事智能与无人系统的研究, E-mail: laffiche@163.com.