

2-20-2021

Behavior Modeling for Computer Generated Forces Based on Machine Learning

Zhang Qi

College of Systems Engineering, National University of Defense Technology, Changsha 410073, China;

Junjie Zeng

College of Systems Engineering, National University of Defense Technology, Changsha 410073, China;

Xu Kai

College of Systems Engineering, National University of Defense Technology, Changsha 410073, China;

Qin Long

College of Systems Engineering, National University of Defense Technology, Changsha 410073, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Behavior Modeling for Computer Generated Forces Based on Machine Learning

Abstract

Abstract: With the rapid development of Machine Learning, especially deep learning, it has become an important way of modeling Computer Generated Force (CGF) behavior by ML methods, which can overcome the challenges of traditional methods. The existing research and application of three typical learning methods in CGF behavior modeling are discussed, and the effects of introducing learning into different stages of the typical CGF applications are analyzed, and the function and performance requirements of CGF behavior modeling using machine learning are proposed. Four potential research directions in the field for future are proposed.

Keywords

M&S, computer generated forces, behavior modeling, machine learning, status, trends

Authors

Zhang Qi, Junjie Zeng, Xu Kai, Qin Long, and Quanjun Yin

Recommended Citation

Zhang Qi, Zeng Junjie, Xu Kai, Qin Long, Yin Quanjun. Behavior Modeling for Computer Generated Forces Based on Machine Learning[J]. Journal of System Simulation, 2021, 33(2): 280-287.

基于机器学习的计算机生成兵力行为建模研究综述

张琪, 曾俊杰*, 许凯, 秦龙, 尹全军

(国防科技大学 系统工程学院, 湖南 长沙 410073)

摘要: 随着机器学习特别是深度学习技术的快速发展, 采用学习方法辅助进行军用仿真中计算机生成兵力(Computer Generated Force, CGF)的行为建模, 已成为克服传统有限状态机等基于知识工程方法面临的建模效率低, 自适应差等问题的重要途径和发展方向。本文对采用机器学习进行 CGF 行为建模的应用现状、需求及发展趋势等若干问题进行了系统论述。梳理总结了 CGF 行为建模中三类典型学习方法的应用现状; 分析了三类典型军用仿真系统引入学习的优缺点和带来的影响; 提出 CGF 系统对学习建模方法的功能和性能需求; 提出并探讨了该领域未来四个发展趋势和重点研究方向。

关键词: 建模与仿真; 计算机生成兵力; 行为建模; 机器学习; 现状; 趋势

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X (2021) 02-0280-08

DOI: 10.16182/j.issn1004731x.joss.20-0931

Behavior Modeling for Computer Generated Forces Based on Machine Learning

Zhang Qi, Zeng Junjie*, Xu Kai, Qin Long, Yin Quanjun

(College of Systems Engineering, National University of Defense Technology, Changsha 410073, China)

Abstract: With the rapid development of Machine Learning, especially deep learning, it has become an important way of modeling Computer Generated Force (CGF) behavior by ML methods, which can overcome the challenges of traditional methods. The existing research and application of three typical learning methods in CGF behavior modeling are discussed, and the effects of introducing learning into different stages of the typical CGF applications are analyzed, and the function and performance requirements of CGF behavior modeling using machine learning are proposed. Four potential research directions in the field for future are proposed.

Keywords: M&S; computer generated forces; behavior modeling; machine learning; status; trends

引言

在训练、分析或装备测试等军用仿真系统中, 计算机生成兵力(Computer Generated Force, CGF)是由计算机创建并能对其全部或部分动作和行为实施自主控制或指导的虚拟作战兵力对象^[1]。通过扮演敌我友各方的武器装备或人员, 表现出与现实作战实体一致的复杂战场行为, CGF 能够以计算机程序代替系统中的人员和装备参与仿真运行, 大

量减少对人员和模拟器材的需求, 有助于扩大仿真规模并有效降低成本, 且生成的虚拟兵力灵活多样, 使得对仿真的灵活控制和预测成为可能^[1-2]。

构建 CGF 的核心任务是对战场环境中作战实体的行为进行建模, 目标是提供 CGF 能够根据输入观察态势输出应执行行动或动作的行为模型, 本质是人类行为建模。目前多数商用/军用仿真平台(VR-Force, Flames, VBS 等)和 CGF 系统(OneSAF, EADSIM 等)的行为建模都采用有限状态机、行为

收稿日期: 2020-11-27

修回日期: 2020-12-24

第一作者: 张琪(1988-), 男, 博士, 讲师, 研究方向为作战仿真、智能行为建模等。E-mail: zhangqiy123@nudt.edu.cn

通讯作者: 曾俊杰(1995-), 男, 硕士, 助教, 研究方向为作战仿真、深度强化学习等。E-mail: zjjnudt@foxmail.com

树、规则脚本等知识工程方法^[3]。军事专家提供领域相关的军事条令等专业知识,通过建模人员与军事专家反复交互形成直接描述仿真对象行为逻辑的模型。该类方法通常具有模型可解释、易校核验证(Verification & Validation)的优势^[4]。然而对于日趋复杂的仿真想定过程,存在领域知识获取困难,建模工作量大、效率低的缺点,且生成的行为固定、缺乏适应性。

为此,近年来越来越多研究者尝试采用机器学习方法,进行 CGF 复杂行为模型的自动生成和优化。基于机器学习的方法,如神经网络、强化学习、进化算法等,能很大程度缓解人工编码带来的知识工程挑战,同时所生成的行为自主性、适应性更强^[5-6]。然而,由于学习方法自身还存在学习效率、效果评估等问题,且多数学习算法获取的模型可解释性差、校验困难、不可控。因此,在军用仿真中采用学习方法进行 CGF 行为建模,在仿真应用需求、学习效应、方法要求等方面仍是开放、值得研究的问题。

本文通过全面梳理已有基于机器学习方法的 CGF 行为建模研究现状,深入探讨分析学习建模带来效应、提出仿真系统对学习方法的需求以及未来的发展趋势,对该问题进行系统研究和综述。

1 研究现状

通常采用 CGF 的军用仿真系统可以分为训练仿真、分析仿真和装备测试仿真三类,应用涉及各军兵种仿真应用。通过文献调研,本文梳理和分析了已有基于机器学习技术的 CGF 建模研究和应用。按照学习方法类别的差异,可以分为采用经验学习、模仿学习(又称示例学习、观察学习等)和混合学习的 CGF 行为建模。

1.1 经验学习

采用经验学习进行行为建模,将人类行为视为理性的智能决策过程,如图 1 所示,其无需大量的示例数据,仅依赖于专家提供的行为评估函数来优

化获取 CGF 行为建模,在装备论证、研制等测试仿真的应用成果较多。

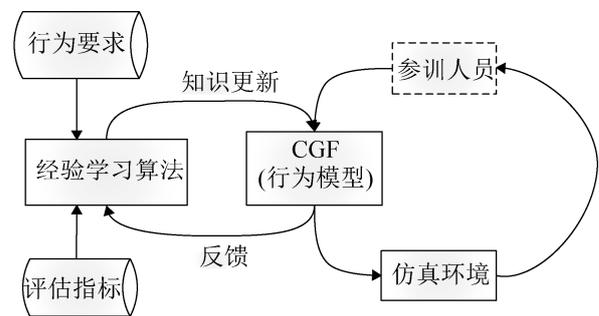


图 1 经验学习行为建模框架

Fig. 1 Behavior modeling framework of experiential learning

(1) 基于进化算法的经验学习行为建模

进化算法是通过模拟生物界种群进化过程在问题空间中搜索最优解的一类优化技术,主要方法包括遗传算法、遗传编程等,是 CGF 行为建模中应用最广的方法。基于进化算法的经验学习行为建模主要依赖专家提供的行为评估指标来优化决策过程。

Taylor^[7]采用进化算法对军事训练和测试仿真中的 CGF 行为生成进行研究。Luotsinen 等^[8]研究了采用遗传编程生成捕食者游戏中的猎捕者 CGF 的行为模型。针对空战仿真中 CGF 行为建模,Ernest 提出了遗传模糊树(Genetic Fuzzy Tree, GFT),采用树结构将复杂问题层次化,大幅降低遗传算法的计算量,并基于此方法开发了 ALPHA 空战模拟系统^[9]。姚剑^[10]采用文法演化生成行为树表示的 CGF 行为模型。

(2) 基于强化学习的经验学习行为建模

强化学习方法,由领域专家提供简单的行为奖励函数反馈,通过与环境的不断交互“试错”获取样本数据,目标是获取能够最大化期望折扣累积奖励的策略^[11]。通过与其他行为表示模型的结合,强化学习在测试仿真和部分获取最优 CGF 行为模型的训练仿真的研究中得到了应用。

Aihe 和 Gonzalez^[12]研究了在 CxBR 框架(Context Base Reasoning, 是由 Gonzalez 所提出的人类行为表示框架)上引入 Q 学习(Q-Learning, 一

种经典的强化学习算法), 修正纯粹依靠专家获得的知识, 保持模型的动态适应性。Teng 等^[13]采用 Q 学习对基于自组织神经网络 FALCON 表示的空战战术机动模型的参数进行学习。Junges 和 Klugl^[14]研究了分别采用进化算法 Q 学习进行仿真系统中的智能体行为构建, 将最终生成的模型以决策树的形式表示。

(3) 基于动态脚本的经验学习行为建模

动态脚本(Dynamic Scripting, DS)是一种基于规则的强化学习技术, 能通过与环境的交互数据来优化规则的权重系数, 由 Spronck 等^[15]提出用于游戏中虚拟对象脚本规则的自动学习。针对空战战术仿真问题, Toubman^[16-17]先后研究了基于动态脚本的空战个体对抗战术自适应问题, 以及分布式协调编队对抗问题, 应用于 NATO 的“智能蓝军”项目。

1.2 模仿学习

CGF 的行为建模本质是人类行为建模, 因此相比经验学习, 依托被仿真对象示例轨迹数据进行模仿学习, 可以获得更逼真且可信的模型^[18], 如图 2 所示。但由于作战行为和仿真训练数据获取和积累困难, 目前围绕 CGF 模仿学习行为建模的实际工作仍然较少。

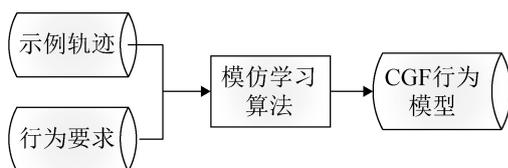


图 2 模仿学习行为建模框架

Fig. 2 Behavior modeling framework of imitation learning

(1) 基于进化算法的模仿学习行为建模

不同于经验学习建模, 基于进化算法的模仿学习将 CGF 行为建模视为一个非线性回归分析问题, 其进化过程中的评估函数不再是专家提供的行为最优指标, 而是学习生成模型的行为输出与模仿对象示例轨迹的相似度, 学习的目标是与模仿对象的行为最像, 而不是理性最优。进化算法已经被证

明了可以用于分类和回归问题^[19]。

在人类行为表示框架 CxBR 基础上, Gonzalez 及其团队对模仿学习行为建模进行大量研究。Fernlund 和 Gonzalez^[19]采集了不同个体进行驾驶的行为数据, 采用遗传编程方法构建出能够在模拟城市环境中进行自动驾驶的智能体。此后, Moriarty 和 Gonzalez^[20]采用人工神经网络, 通过观察学习获得了基于 CxBR 框架的虚拟智能体模型。Johnson 和 Gonzalez^[21]基于该框架进一步研究了通过观察学习人类群组的行为策略, 并在经典的追逃对抗游戏中进行了验证。依托行为树作为可解释的模型表示, Berthling Hansen 等^[22]研究了基于遗传编程进行行为树表示的 CGF 战术机动模型的生成。

(2) 基于案例推理的模仿学习行为建模

基于案例的推理(Case Based Reasoning, CBR), 无需事先进行策略学习, 而通过构建历史经验案例库, 在策略运用时采用相似类比的思想, 从过去经验案例库中寻找解决当前类似问题的解。Floyd^[23]基于 CBR 给出在复杂领域应用观察学习的通用框架。Ontan 等^[24]采用基于案例的规划(Case Based Planning, CBP)从观察的示例中学习即时战略游戏的对抗规划策略。Robertson 和 Watson^[25]基于 CBR 构建从观察记录的专家回放数据中学习生成星际争霸的 AI, 用于降低 AI 开发的难度, 以获得与专家类似水平的智能性。

(3) 基于对抗生成网络的模仿学习行为建模

生成对抗网络(Generative Adversarial Networks, GAN)^[26]是一种深度神经网络模型, 在计算机视觉, 自然语言等领域取得了巨大的成功。GAN 将行为建模视为分布拟合问题, 即以收集的专家数据作为输入, 获取能够输出近似专家轨迹分布的策略, 用于驱动 CGF 的行为。为解决传统模仿学习的计算代价过高, 训练效率低的问题, Jonathan 和 Stefano^[27]提出了生成对抗模仿学习算法(Generative Adversarial Imitation Learning, GAIL)。该算法基于生成对抗框架, 以收集到的专

家示例数据作为输入,采用强化学习方法构建生成模型,来高效地生成拟合专家数据分布的行为模型,且能够解决传统模仿学习算法——行为克隆(Behavior cloning)面临的误差积累的问题。

1.3 混合学习

此外,还有专家致力于采用混合学习方法生成行为模型,充分利用模仿学习和经验学习的优势。

Stein 和 Gonzalez^[28]基于 CxBR 框架提出了综合观察学习和经验学习的两阶段战术行为建模算法 PIGEON-Alternate。Luotsinen 和 Lovlid^[29]开发了一种数据驱动的 CGF 行为建模原型,并在进一步的研究中,在 VBS3 仿真平台中对步兵常见的 Bounding Overwatch 问题进行了观察学习研究^[30]。

1.4 小结

根据经验数据来源差异,已有机器学习行为建模主要分为通过试错优化专家评估指标的经验学习、根据专家示例数据的模仿学习和混合学习,如表 1 所示。

表 1 已有基于机器学习的 CGF 行为建模研究分类对比
Tab. 1 Category of existing CGF behavior modeling methods based machine learning

学习类别	常用算法	模型表示
经验	进化计算	规则 ^[7] 、树结构 ^[8-9] 、行为树 ^[10]
	强化学习	基于情境的推理 ^[12] 、神经网络 ^[13] 、决策树 ^[14]
模仿	动态脚本	规则 ^[16] 、有限状态机 ^[17]
	进化计算	基于情境的推理 ^[19-21] 、行为树 ^[22]
	案例推理	案例 ^[24] 、行为树 ^[25]
混合	NEAT+粒子群	基于情境的推理 ^[28]
	神经网络、决策树+进化计算	神经网络/决策树 ^[29-30]

经验学习强调理性行动,更多用于测试或武器装备论证仿真中的战术探索,而模仿学习强调像人一样行动,在训练仿真中应用较多。另外由于可解释、可控性方面的潜在要求,模型表示是另一个关注点,已有方法更侧重于依托传统知识工程方法的

一些模型表示作为学习基础,如 CxBR、决策树、行为树、规则等,更容易支撑开展仿真模型的可信性评估。

2 学习效应分析

根据前文现状分析,多数文献都认可在 CGF 中引入学习的必要性^[31]。但在实际应用中,由于可控性、可解释、模型校验方面的挑战和对行为适应的不同需求,CGF 系统在学习方面非常谨慎,如常用的 VR-Forces, STAGE, VBS3, FLAMES^[4]等都不具备学习能力。下面将对训练、分析和装备测试三类典型仿真系统在离线和在线两种模式下引入学习的效应进行分析。

2.1 训练仿真

训练仿真,主要用于装备的操作技能训练、参谋作业训练和各级指挥员进行战场态势感知、决策和指挥训练等。典型的装备操作技能训练如飞行器仿真训练。训练仿真系统相较其他类别的仿真系统而言,具有灵活丰富的数据来源,一方面可以采集军事专家演习或操控仿真系统的行为轨迹数据作为 CGF 模型离线学习的对象;另一方面确定专家期望的 CGF 行为评估指标,进行模型的理性优化或自适应,如击败职业飞行员的著名人工智能 Alpha^[9]。离线或在线的学习能够发现领域专家未意识到的错误或不完备知识,为训练过程提供更合理、丰富多样的经验。在线学习还能为 CGF 提供对未知环境的自适应能力,避免受训者利用传统脚本行为的固定模式作弊,但系统计算代价通常较大。

2.2 分析仿真

分析仿真,主要用于武器系统、部队战斗力或条令评估、作战方案与计划的评估和改进等。分析仿真需要客观回答关于武器装备、兵力结构、条令战法等的效能,通常要求 CGF 行为严格受控,按照预定的行为逻辑执行,相同配置条件下仿真

结果可重复展现。分析仿真系统对具有学习能力的 CGF 模型需求不高,学习虽能够改善原有不合理行为,但也会产生不同于预期(条令、专家经验等)的行为,丢失分析对象实验的可重复性,难以达到分析评估目标。

2.3 测试仿真

测试仿真,用于武器装备体系论证、武器装备鉴定定型和新概念武器先期技术演示。其所论证回答的问题更具开放性和探索性,更重视在开放问题环境下的组合方案尝试,为操作人员和分析人员提供发现新事物(如新概念武器的战术条令)的环境和工具。因此,引入学习,特别是探索性的经验学习,能够为测试仿真实验带来丰富的探索环境,对各种手工无法完成的复杂方案组合空间进行尝试,获得

改进的方案或新的知识。同样,学习可能增加仿真实验结果的分析难度,增加系统的运算代价。

2.4 小结

如表 2 所示,在常用的仿真系统应用中,分析仿真不适合引入学习,而训练仿真和测试仿真对离线和在线的学习都具有较强需求,潜在效益大,但学习会增加系统的计算代价,降低模型和仿真的可控性。采用离线学习自动获取训练和测试仿真中的 CGF 行为模型,能够缓解传统建模方法领域知识获取困难,效率低的问题,但需要保持模型的可解释性,与其他建模方法兼容。在训练和测试仿真进行在线学习,应该遵循条令、专家或训练人员约束,定制裁剪期望的行为,确保学习能够灵活可控、快速适应。

表 2 典型 CGF 应用引入不同学习方式的优缺点
Tab. 2 Advantages and disadvantages of different learning methods for typical CGF applications

学习方式	CGF 应用		
	训练仿真	分析仿真	测试仿真
离线	①提高知识获取便捷性和效率; ②改善行为自主性,表现更逼真; ③提高模型适应性,提供多样可变训练经验	①提高知识获取便捷性和效率; ②改善行为自主性,模型更逼真	①提高知识获取便捷性和效率; ②改善行为自主性,模型更逼真; ③提高模型适应性,提供丰富测试环境
	训练可控性降低	丢失分析可重复性	出现混乱测试结果
在线	提高行为对可变环境的适应性, 提供多样可变训练经验	/	提高行为对可变环境的适应性, 提供丰富的测试环境
	①训练可控性降低; ②计算代价增加	①丢失分析可重复性; ②计算代价增加	①出现混乱测试结果; ②计算代价增加

3 学习方法需求

基于仿真应用引入学习的效应分析,本节提出 CGF 行为建模对机器学习算法及学习所生成模型的需求。借鉴 Spronck 等^[15]对游戏中采用学习方法构建自适应虚拟智能体的需求,考虑游戏和仿真之间的相似性和差异,本文提出 CGF 行为建模对学习算法和效果的功能和性能需求如表 3 所示。

此外,为支撑领域专家、建模人员以及可能的 CGF 操控人员对行为模型的开发、控制,模型表示和开发工具还应满足以下需求:

- (1) 行为模型的部署运用便捷、代价低;
- (2) 行为模型必须可重用;
- (3) 行为模型必须易测试、调试和校验;
- (4) 领域专家、建模人员应能够灵活直观地对所生成的行为添加不同的约束和目标。

总体而言,所用学习算法应避免耗费大量计算资源,效率高、鲁棒性强;学习所产生的行为应不比现有脚本式开发的行为表现差,兼容性强,行为更完备多样,易理解、测试;学习框架应基于可读性强、可重用、易上手的模型表示方法,可扩展性强,易与其他方法相结合。上述需

求也是当前制约机器学习技术应用于 CGF 实际开发的主要原因。

表 3 引入学习的 CGF 行为建模需要满足的功能性能需求
Tab. 3 Function and performance requirements of CGF behavior modeling using machine learning

类别	需求	描述
功能	清晰性	所产生的行为易被建模人员或用户理解
	多样性	所产生的行为满足基本行为要求且完备多样
	一致性	有限时间内学习适应到的行为应保持一致, 与用户活动无关
	可扩展性	所产生的行为可按照用户的应用需求进行灵活扩展
	可定制性	允许建模人员根据条令、规则等对 CGF 行为进行不同程度地定制约束, 保持行为与条令原则的一致性
性能	高效	学习应尽可能运算速度快、运算量小, 特别是在线学习
	有效性	所产生的行为必须始终是有用的, 包括在线学习中
	鲁棒性	所产生的行为具备对随机突发状况适应性
	快速性	由于人在环训练往往只能进行有限周期, 因此学习方法应能在较少交互中, 迅速收敛

4 发展趋势分析

当前军用仿真中基于机器学习的 CGF 行为建模还处在早期快速发展阶段, 呈现出两个显著特点: (1) 由于作战和仿真应用数据获取的困难, 依托模仿学习的 CGF 行为建模应用仍然较少, 多数应用集中在测试实验或训练环境离线开发阶段的经验学习 CGF 行为建模^[7-9]; (2) 当前基于机器学习的 CGF 行为建模都非常关注学习算法的模型可解释。随着机器学习技术在其他产业应用中的成熟落地, 以及军用仿真系统大规模运用的数据积累、体系建设的生态成熟, 未来一段时间内该领域的研究和应用必将受到更多重视, 核心关注点包括:

(1) 基于模仿学习的 CGF 行为建模

CGF 行为建模的本质是对人类行为的模拟, 考虑人类行为本身的非理性因素和差异性特点, 根

据仿真对象的行为轨迹进行模仿学习相比经验学习应该更客观真实。在模仿学习的研究中, 解决上述问题的过程通常分为示例数据收集和策略学习两个阶段。在军用仿真研究中, 由于战场要素的复杂性和动态性, 战术行为数据往往是基于时间的、连续的、有噪声的, 因此对示例的特征提取是一个研究重点。另一方面, 在策略学习中如何针对上述特点的复杂数据进行合理地效果评估也是一个开放的问题。

(2) 对深度学习、深度强化学习方法的探索

随着深度学习、深度强化学习在围棋、星际争霸等军事背景对抗游戏中的巨大成功, 研究深度学习、深度强化学习在 CGF 行为建模中的应用已受到广泛关注, 其不仅能够获得泛化能力很强的任务策略, 同时自动提取战术行为特征的优点对建模人员也有极大的吸引力。瑞典国防研究局^[32]、国内国防科技大学的研究人员已经对一些简单的 CGF 战术机动、路径规划问题进行探索研究。

(3) 基于多智能体学习的 CGF 群组建模需求

在面向训练等军用仿真系统中, CGF 的活动通常以有组织目标约束下的群组形态展开, 但同时由于“网络中心战”和个体作战能力的不断增强, 底层作战实体的分布式自主决策能力也愈发重要。因此, 综合考虑群组的集中战术约束和实体分布式自主特性, 基于多智能体强化学习、多智能体模仿学习等方法开展 CGF 群组协作策略的学习和协调问题的处理, 需要进一步研究。

(4) 重视模型的可解释性及可信性评估研究

对行为建模的 VV&A 相较于其他模型数据的可信性评估更为困难, 需要对 CGF 行为模型可信性评估框架和学习产生的行为模型进行定量性的综合评估研究。从研究现状分析来看, 当前研究人员更倾向于可解释的模型表示作为学习的基础, 以更好支持军事领域专家、仿真建模人员、编程人员以及用户之间的协同。越来越多研究人员关注深度神经网络的可解释研究^[33], 探索神经

网络决策的可视化解释, 以及深度神经网络与决策树的转化结合, 也是基于学习的 CGF 行为建模的关注重点。

5 结论

本文对基于机器学习的 CGF 行为建模进行了较为广泛和深入的调研和分析, 从研究现状、引入学习的效应分析、对学习的功能与性能需求、未来发展趋势等方面对此问题进行深刻阐述。通过对现有相关研究和应用现状的梳理, 分析了训练、分析、测试 3 类典型 CGF 应用系统在离线开发和在线仿真阶段引入学习的效应, 提出了 CGF 系统对采用学习方法进行行为建模的功能和性能需求; 最后, 论文提出该领域未来一段时间内的四个重点研究方向, 更好地促进领域内有关研究的开展和学习在仿真系统中的应用落地。

参考文献:

- [1] 郭齐胜. 计算机生成兵力导论[M]. 北京: 国防工业出版社, 2006.
Guo Qisheng. An Introduction of Computer Generated Forces[M]. Beijing: National Defence Industry Press, 2006.
- [2] 黄柯棣, 刘宝宏, 黄健, 等. 作战仿真技术综述[J]. 系统仿真学报, 2004, 16(9):1887-1895.
Huang Kedi, Liu Baohong, Huang Jian, et al. A Survey of Military Simulation Technologies[J]. Journal of System Simulation, 2004, 16(9):1887-1895.
- [3] 张琪. 学习驱动的 CGF 决策行为建模方法研究[D]. 长沙: 国防科技大学, 2019.
Zhang Qi. Learning Driven Behavior Modeling Methods for Decision Making of CGFs [D]. Changsha: National University of Defense Technology, 2019.
- [4] Toubman A, Poppinga G, Roessingh J J, et al. Modeling CGF Behavior with Machine Learning Techniques: Requirements and Future Directions[C]. 2015 Interservice/Industry Training, Simulation, and Education Conference. Orlando, USA: IITSEC, 2015: 2637-2647.
- [5] 高昂, 段莉, 张国辉, 等. 计算机生成兵力行为建模发展现状[J]. 计算机工程与应用, 2019, 55(19): 43-51.
Gao Ang, Duan Li, Zhang Guohui, et al. Development Status of Computer Generated Force Behavior Modeling[J]. Computer Engineering and Applications, 2019, 55(19): 43-51.
- [6] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
Zhou Zhihua. Machine Learning[M]. Beijing: Tsinghua University Press, 2016.
- [7] Taylor A. Designing Controllers for Computer Generated Forces with Evolutionary Computing: Experiments in a Simple Synthetic Environment[R]. Ottawa Canada: DRDC, 2013.
- [8] Luotsinen L J, Kamrani F, Hammar P, et al. Evolved Creative Intelligence for Computer Generated Forces [C]. Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on. Budapest: IEEE, 2016: 003063-003070.
- [9] Ernest N D. Genetic Fuzzy Trees for Intelligent Control of Unmanned Combat Aerial Vehicles [D]. USA: Dissertations & Thesis – Gradworks, 2015.
- [10] 姚剑. 面向装备效能仿真的战术探索方法研究[D]. 长沙: 国防科技大学, 2018.
Yao Jian. Study on Tactics Exploration Method for Equipment Effectiveness Simulation[D]. Changsha: National University of Defense Technology, 2018.
- [11] 高阳, 陈世福, 陆鑫. 强化学习研究综述[J]. 自动化学报, 2004, 30(1): 86-100.
Gao Yang, Chen Shifu, Lu Xin. Research on Reinforcement Learning Technology: A Review[J]. Automatica Sinica, 2004, 30 (1):86-100.
- [12] Aihe D O, Gonzalez A J. Correcting Flawed Expert Knowledge Through Reinforcement Learning[J]. Expert Systems with Applications (S0957-4174), 2015, 42(17): 6457-6471.
- [13] Teng T H, Tan A H, Teow L N. Adaptive Computer Generated Forces for Simulator-based Training[J]. Expert Systems with Applications (S0957-4174), 2013, 40(18): 7341-7353.
- [14] Junges R, Klugl F. Modeling Agent Behavior Through Online Evolutionary and Reinforcement Learning[C]. Federated Conference on Computer Science and Information Systems. USA: IEEE, 2011: 643-650.
- [15] Spronck P, Ponsen M, Sprink Huizen-Kuyper I, et al. Adaptive Game AI with Dynamic Scripting[J]. Machine Learning (S0885-6125), 2006, 63(3): 217-248.
- [16] Toubman A. Calculated Moves: Generating Air Combat Behaviour[D]. Netherlands: Dissertations & Thesis, Leiden University, 2020.
- [17] Toubman A, Roessingh J J M, Spronck P, et al.

- Improving Air-to-Air Combat Behavior Through Transparent Machine Learning[C]. Interservice/Industry Training, Simulation, and Education Conference. Orlando, USA: IITSEC, 2014: 1-11.
- [18] Fernlund H K G, Gonzalez A J, Georgiopoulos M, et al. Learning Tactical Human Behavior Through Observation of Human Performance[J]. IEEE Transactions on Systems Man & Cybernetics Part B Cybernetics (S1083-4419), 2006, 36(1): 128.
- [19] Argall B D, Chernova S, Veloso M, et al. A Survey of Robot Learning from Demonstration[J]. Robotics & Autonomous Systems (S0921-8890), 2009, 57(5): 469-483.
- [20] Moriarty C L, Gonzalez A J. Learning Human Behavior from Observation for Gaming Applications[C]. International Florida Artificial Intelligence Research Society Conference, May 19-21, 2009. Sanibel Island, Florida, USA: DBLP, 2009.
- [21] Johnson C L, Avelino J G. Learning Collaborative Team Behavior from Observation[J]. Expert Systems with Applications (S0957-4174), 2014, 41(5): 2316-2328.
- [22] Berthling-Hansen G, Morch E, Lovlid R A, et al. Automating Behavior Tree Generation for Simulating Troop Movements (Poster)[C]. 2018 IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA). USA: IEEE, 2018: 147-153.
- [23] Floyd M W. A General-Purpose Framework for Learning by Observation[D]. Ottawa, Ontario, Canada: University of Carleton, 2013.
- [24] Ontan S, Mishra K, Sugandh N, et al. Case-Based Planning and Execution for Real-Time Strategy Games [C]. International Conference on Case-Based Reasoning: Case-Based Reasoning Research and Development. UK: Springer-Verlag, 2007: 164-178.
- [25] Robertson G, Watson I. Building Behavior Trees from Observations in Real-time Strategy Games[C]. International Symposium on Innovations in Intelligent Systems and Applications. Madrid: IEEE, 2015: 1-7.
- [26] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Nets[C]. NIPS. USA: MIT, 2014: 2672-2680.
- [27] Jonathan H, Stefano E. Generative adversarial Imitation Learning[C]. Advances in Neural Information Processing Systems. New York, NY: Curran Associates, 2016: 4565-4573.
- [28] Stein G, Gonzalez A J. Building High-Performing Human-Like Tactical Agents Through Observation and Experience[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B Cybernetics (S1083-4419), 2011, 41(3):792-804.
- [29] Luotsinen L J, Lovlid R A. Data-driven Behavior Modeling for Computer Generated Forces[C]. NATO Modeling and Simulation Group Symp. M&S Support to Operational Tasks including War-gaming, Logistics, Cyber Defence (MSG-133). Germany: NATO, 2015: 1-13.
- [30] Kamrani F, Luotsinen L J, Lovlid R A. Learning Objective Agent Behavior using a Data-driven Modeling Approach[C]. IEEE International Conference on Systems, Man, and Cybernetics. Budapest: IEEE, 2016: 002175-002181.
- [31] Petty M D. Benefits and Consequences of Automated Learning in Computer Generated Forces Systems [J]. Information & Security: An International Journal (S0861-5160), 2003, 12(1): 63-74.
- [32] Babak Toghiani-Rizi. Evaluation of Deep Learning Methods for Creating Synthetic Actors[D]. Netherlands: Dissertations & Thesis, 2017.
- [33] Oana-Maria Camburu. Explaining Deep Neural Networks[D]. Oxford, England: Dissertations & Thesis, University of Oxford, 2020.