

1-2-2019

A deep spatio-temporal RNNs based coordinated operational action recognition

Yi Zhuo

1.Information Engineering University, Zhengzhou 450001, China; ;

Liao Ying

1.Information Engineering University, Zhengzhou 450001, China; ; 2.Department of Information Operation & Command Training, NDU, Beijing 100091, China;

Xiaofeng Hu

2.Department of Information Operation & Command Training, NDU, Beijing 100091, China;

Xuehui Du

1.Information Engineering University, Zhengzhou 450001, 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.

A deep spatio-temporal RNNs based coordinated operational action recognition

Abstract

Abstract: To address the issues of large feature space, numerous model parameters and slow training speed in coordinated operation action recognition, *a coordinated operational action recognition method based on a deep spatio-temporal recurrent neural network is proposed. In this method, a warped region generation mechanism is introduced to divide the whole battlefield into sub-battlefield. Meanwhile, a hierarchical recurrent neural network is constructed using spatio-temporal graph model, which is applied to the generated sub-battlefield to recognize coordinated operational action. Additionally, the recognized coordinated operational actions of sub-battlefields are merged to find out all coordinated operational actions based on the principle of transitivity of coordinated operational actions in local battlefield.* Experiment results suggest that the proposed method possesses higher accuracy.

Keywords

coordinated operation, hierarchical recurrent neural network, coordinated operation action recognition, spatio-temporal graph, situation comprehension

Authors

Yi Zhuo, Liao Ying, Xiaofeng Hu, Xuehui Du, and Zhu Feng

Recommended Citation

Yi Zhuo, Liao Ying, Hu Xiaofeng, Du Xuehui, Zhu Feng. A deep spatio-temporal RNNs based coordinated operational action recognition[J]. Journal of System Simulation, 2018, 30(3): 793-800.

基于深度时空循环神经网络的协同作战行动识别

易卓¹, 廖鹰^{1,2}, 胡晓峰², 杜学绘¹, 朱丰²

(1.信息工程大学, 河南 郑州 450001; 2.国防大学联合作战学院, 北京 100091)

摘要: 针对协同作战行动识别面临的行为特征空间大、模型参数多、训练速度慢等问题, 将时空图模型和时序建模有机结合, 提出基于深度时空循环神经网络的协同作战行动识别方法, 建立战场协同作战行动识别架构, 引入建议窗口生成机制划分战场空间为局部战场集, 利用时空图设计层次循环神经网络模型以识别局部战场协同作战行动, 并结合局部战场协同关系传递性实现整个战场的协同行动识别。实验分析表明, 该方法具有较高的协同作战行动识别准确率。

关键词: 协同作战; 层次循环神经网络; 协同作战行为识别; 时空图; 态势理解

中图分类号: TP183; E919 文献标识码: A 文章编号: 1004-731X (2018) 03-0793-08

DOI: 10.16182/j.issn1004731x.joss.201803004

A deep spatio-temporal RNNs based coordinated operational action recognition

Yi Zhuo¹, Liao Ying^{1,2}, Hu Xiaofeng², Du Xuehui¹, Zhu Feng²

(1.Information Engineering University, Zhengzhou 450001, China;

2.Department of Information Operation & Command Training, NDU, Beijing 100091, China)

Abstract: To address the issues of large feature space, numerous model parameters and slow training speed in coordinated operation action recognition, a coordinated operational action recognition method based on a deep spatio-temporal recurrent neural network is proposed. In this method, a warped region generation mechanism is introduced to divide the whole battlefield into sub-battlefield. Meanwhile, a hierarchical recurrent neural network is constructed using spatio-temporal graph model, which is applied to the generated sub-battlefield to recognize coordinated operational action. Additionally, the recognized coordinated operational actions of sub-battlefields are merged to find out all coordinated operational actions based on the principle of transitivity of coordinated operational actions in local battlefield. Experiment results suggest that the proposed method possesses higher accuracy.

Keywords: coordinated operation; hierarchical recurrent neural network; coordinated operation action recognition; spatio-temporal graph; situation comprehension

引言

协同作战是信息化条件下联合作战的重要作战形式, 能发挥超出各作战单元力量总和的作战效能。预先识别敌方的协同作战行动, 阻滞或打破敌

方协同作战进程, 是联合作战制胜的关键。协同作战行动识别旨在从有限的战场态势数据中识别出敌方潜在的协同作战行动, 预测未来可能的行为趋势, 为指挥员制定作战方法提供决策依据。

协同作战行动是多主体协同的复杂行为, 协同作战行动识别面临诸多挑战: 1) 协同作战行动特征空间庞大, 一方面, 作战单元属性特征和状态特征维度大, 另一方面, 作战单元数量多, 行动覆盖范围广, 协同作战关系复杂, 使得协同作战特征空间



收稿日期: 2018-01-07 修回日期: 2018-02-22;
基金项目: 国家自然科学基金(61773399, 61374179, 61703412), 军民共用重大研究计划联合基金(U1435218);
作者简介: 易卓(1989-), 男, 湖北京山人, 博士生, 研究方向为人工智能, 作战指挥, 网络安全。

<http://www.china-simulation.com>

庞大, 很难进行有效识别; 2) 作战单元数量及协同作战关系动态变化, 随着作战进程推移, 作战方案调整、兵力重新部署, 都可能导致作战单元数量和协同关系动态变化; 3) 作战任务分配不确定及作战单元的自主性, 同一协同作战任务由 N 个作战单元完成时, 可能出现 $N!$ 种分配情况, 且不同作战单元执行同一任务时情况也不尽相同。此外, “战争迷雾” 进一步加剧协同作战行为识别的挑战。

鉴于协同作战行为通常具有复杂的高层时空特征, 将协同作战行动的高层时空特征及时序建模有机结合, 提出基于深度时空循环神经网络的作战协同行动识别方法。首先, 引入建议窗口生成机制, 将整个战场空间划分成作战单元数量均衡的冗余局部战场集; 其次, 利用时空图模型刻画局部战场协同作战行动的高层时空特征, 构建深度循环神经网络模型识别局部战场的协同作战行动; 然后, 根据协同关系传递性原则, 利用全连接层对冗余局部战场协同关系进行融合; 最后, 利用计算机兵棋数据验证方法的有效性。

1 相关工作

现有关于协同作战行动识别的研究相对较少, 主要针对固定数量的特定作战实体间的协同行为识别。由于协同作战行动是一种具有群体性、时序性和交互性的复杂行为。协同作战行动识别可以借鉴复杂行为识别和时空交互特征识别的相关研究思想。因此, 从协同作战行为识别、复杂行为识别和时空交互特征识别三方面展开。

协同作战行动识别方面, 文献[1]利用多目标隐马尔科夫模型对空中目标的 6 种协同导弹攻击行为进行识别。文献[2]利用双向协同网络(BiCNet)对星际争霸对战数据中大规模智能 Agent 的协同攻击进行识别, 并学习应对敌方协同攻击的策略。文献[3]从全局视角出发, 利用马尔科夫过程和层次属性架构对足球比赛中多人协同进攻或防守进行识别, 但难以识别协同进攻或协同防守的类型。文献[4-5]采用协同树(Coordination trees)刻画 Agents 的协作

关系, 并分别采用协作子集计算和多 Agent 协同强化学习的方法识别 Agents 的协作关系。

复杂行为识别方面, 文献[6]设计了一种基于贝叶斯网络的概率生成框架, 利用 Allen 区间关系网络识别复杂行为的时间依赖关系。文献[7]结合 Granger Causality statistic^[8]时间依赖测量方法、动态贝叶斯网络和 Adaboost 算法, 提出基于 GCDBN 的结构化学习机制, 实现监控视频中复杂行为的分类。文献[9]设计基于原子行为的贝叶斯模型, 利用概率生成法构造 Allen 区间关系网络, 实现复杂行为的类型识别和原子行为关系的识别。

时空交互特征识别方面, 文献[10]采用人体骨架模型描述行为特征, 并利用长短期记忆网络识别行为的协作特征。文献[11]提出基于卷积门限玻尔兹曼机的时空特征学习模型。文献[12]通过扩展的独立子空间分析算法, 以无监督方式识别无标签行为数据中的时空特征。文献[13]提出基于 3D 卷积神经网络的行为识别方法, 从时空维度提取人的运动特征。文献[14]通过在结构化 3D 卷积神经网络模型的每一个卷积层中引入延迟变量, 控制神经网络的激活, 进而识别行为的时空特征。文献[15]提出基于时空深度信度网络(ST-DBN)的行为识别模型来识别视频行为的时空特征。文献[16]针对人体骨架模型的时空交互特征, 引入时空图和 RNN, 设计基于 structural-RNN 的时空特征识别算法, 在人体行为检测、自动驾驶等应用方面取得较好的效果。其中, structural-RNN 所采用的时空图模型是刻画时空特征的常用工具, 且广泛用于描述交互的时空特征^[17-19]。

上述研究为协同作战行动识别提供思路, 但存在几点不足: 1) 多针对类型相同的实体, 未考虑协同行为实体的异质性和自主性, 不符合联合作战条件下作战实体多样性和实体决策自主性的实际情况; 2) 难以适应战场环境中作战单元动态变化的情形; 3) 大规模作战单元同时作战情况下的协同行动识别模型, 通常具有模型参数多、训练效率低的特点。

2 协同作战行为识别

2.1 协同作战行动的时空图模型

协同作战行动依时空图模型可描述为 $G=(v, \varepsilon_s, \varepsilon_t)$, 其中 v 代表战场作战单元集, 时空边 ε_s 表示作战单元协同的交互关系, 时序边 ε_t 代表作战单元自身行为的时序关系, 协同作战行动的时空图示意如图 1(a)所示。假设作战单元 $u, v \in v$, t 时刻, 令 $x_{u,v}^t$ 表示 u 与 v 的协同交互关系, $x_{u,u}^t$ 表示作战单元自身与上一时刻的时序关系, x_u^t 表示作战单元的自身属性。随着作战进程推进, 节点 v 及边 $e \in \varepsilon_s \cup \varepsilon_t$ 随时间演化, 图 1(a)按时间展开为图 1(b)。


分析图 1 可知, 协同作战行动识别既依赖于作战单元 $u, v \in v$ 的属性及行为特征, 同时也取决于作战单元间的交互特征。因此, 定义作战单元的属性特征函数 $\Psi_v(y_v, x_v)$ 、行为特征函数 $\Psi_v(y_v, x_{v,t-1}, x_{v,t})$ 和交互特征函数 $\Psi_e(y_v, y_u, x_e)$ 。针对每一个特征函数, 采用一个循环神经网络 (RNN) 学习其函数参数。因此, 可以建立如图 2 所示的层次循环神经网络模型。其中: R_v 为节点属性

RNN, 表征作战单元属性; R_{e1} 为节点行为 RNN, 刻画节点的时序行为; R_{e2} 为交互行为 RNN, 描述作战单元协同行为。

给定战场态势数据, 协同作战行为识别的目标即预测当前战场存在的协同作战行为标签 y^t 。由于战场空间同时存在大量作战单元, 协同作战行为标签 y^t 可能包含多个协同作战行为。假设任意两个作战单元之间的协同行为 $y_{u,v}^t (u, v \in v, u \neq v)$, 则

$$y^t = \phi \left(\bigcup_{u,v \in v} y_{u,v}^t \right) \quad (1)$$

其中, 协同作战行为聚合函数 ϕ 将协同的作战单元映射到相同域并传递作战单元间的协同关系。



(a) Spatio-temporal Graph (b) Unfolded S-T Graph

图 1 协同作战行动的时空图

Fig. 1 Spatio-temporal graph for coordinated operational action

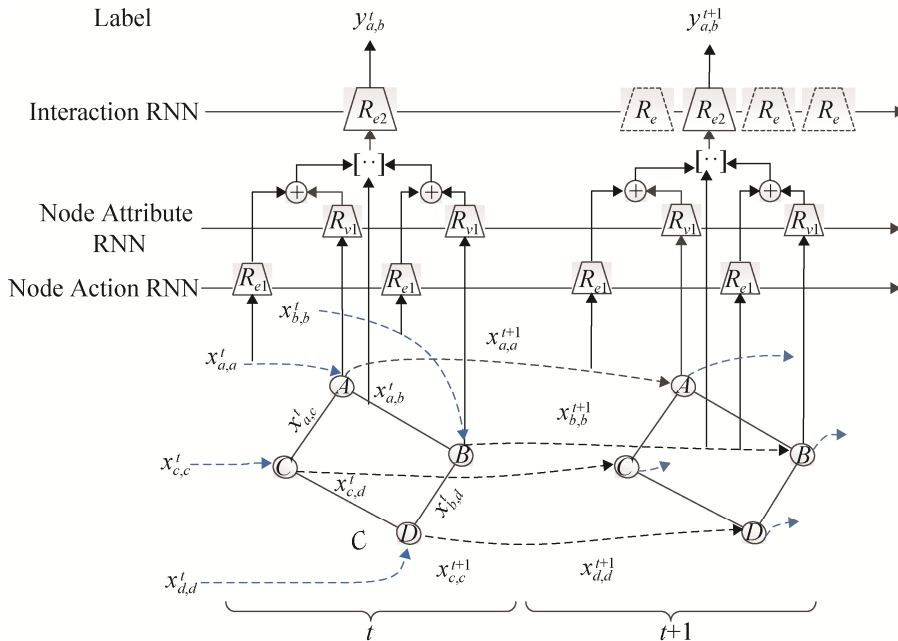


图 2 局部协同作战行动识别模型

Fig. 2 Local coordinated operational action recognition model

2.2 战场协同作战行为识别架构

公理 局部战场协同关系的传递性：假设作战单元 A, B, C 同属于某一局部战场，且不能同时执行两种及以上作战任务，若 A 与 B 存在协同关系，A 与 C 存在协同关系时，则 A 与 C 具有协同关系。

证明：略。

为降低模型参数总量，加速协同作战行动识别过程，基于局域战场协同关系的传递性，构建战场协同作战行为识别架构，将战场空间划分为作战单元数量相对固定的冗余局部战场集，采用局部协同作战行动识别模型进行识别，再进行协同关系的融合，具体如图 3 所示。

2.2.1 建议窗口生成

源于 Selective Search^[20]建议窗口生成过程的启发，协同行动识别的建议窗口生成利用精心构造的卷积核对战空间进行卷积操作，将整个战场空间划分成作战单元数量相对均匀的冗余局部战场集。

令 $n_A \times m_A$ 矩阵 A_t 表示 t 时刻作战单元分布用，则 $t_0 \sim t_{T-1}$ 时刻作战单元分布分别为 $A_{t_0}, A_{t_1}, \dots, A_{t_{T-1}}$ ，建议窗口生成过程如下：

1) 构造 $n_{A'} \times m_{A'}$ 矩阵 A' ，满足

$$A' = \begin{bmatrix} C & & \\ & D & \\ & & C \end{bmatrix} \quad (2)$$

式中： $D = A_{t_0} \oplus A_{t_1} \oplus \dots \oplus A_{t_{T-1}}$ ；矩阵 C 为 $n_C \times n_C$ 零矩阵，且存在 $n_{A'} = n_A + n_B - 1$ ， $m_{A'} = m_A + n_B - 1$ ， $n_C = (n_B - 1)/2$ ， \oplus 为矩阵的布尔加运算。

矩阵 A' 旨在实现不同时刻战场作战单元分布矩阵的战场叠加和边界填充，保证生成的建议窗口集合覆盖战场空间的所有作战单元。

2) 构造 $n_B \times n_B$ 过滤器 B 作为滑动窗口，满足 n_B 为奇数， $n_A, m_A \geq n_B$ ， B 中元素仅取 0 或 1，且元素值等于 1 的元素数量不超过 θ 。

过滤器 B 构建旨在构造局部战场作战单元服从一定分布特征的过滤器。过滤器的设计需要保证在特定卷积后生成的所有建议窗口能依协同关系传递性准则覆盖所有可能的协同关系，且保证每个建议窗口内的作战单元数量不超过阈值 θ 。过滤器的一个示例如图 4 所示 3×3 过滤器 B 。

3) 按步长为 l ，利用过滤器 B ，对矩阵 A' 进行卷积操作，生成建议窗口集 Z 。

图 4 说明了建议窗口的生成过程，假设战场空间作战单元分布的扩展矩阵 A' 和过滤器 B 如图，经过卷积操作，生成建议窗口集合 S ，由图可以看出每个局部战场作战单元数量均不超过 5，即过滤器 B 中元素值为 1 的元素个数。

2.2.2 局部协同作战行动识别模型

建议窗口的生成将整个战场空间划分为局部战场集 Z 。对给定任意局部战场 $s_i \in Z (0 < i \leq |Z|)$ ，其中 $|Z|$ 表示局部战场集 Z 的大小，其包含的作战单元数量均不超过 θ 。因此，设置局部战场作战单元数量恒定为 θ ，并按 2.1 节方法构造局部战场协同行动识别的层次 RNN 模型。图 5 给出 $\theta=5$ 时的局部战场协同行动识别模型。




图 3 战场协同作战行动识别架构

Fig. 3 Architecture for coordinated operational action recognition




图 4 建议窗口生成的计算过程
Fig. 4 Procedure for warped region generation

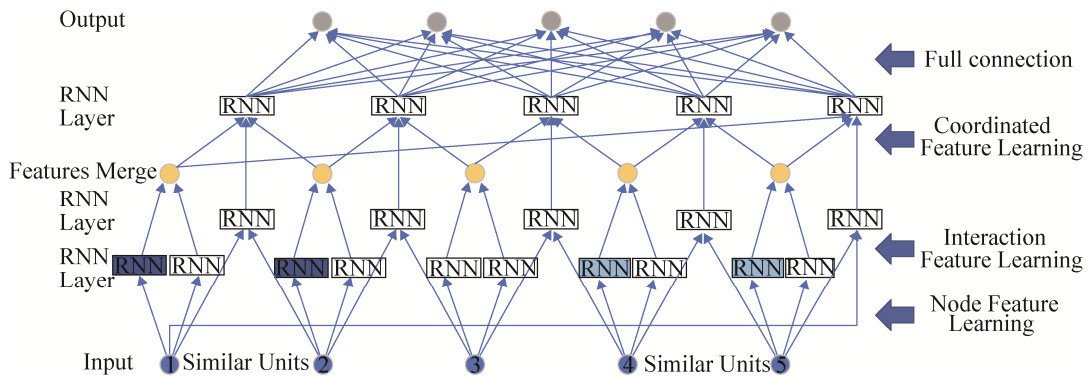


图 5 局部协同作战的层次循环神经网络($\theta=5$)
Fig. 5 Hierarchical recurrent neural network for local coordinated operational action recognition ($\theta=5$)

由于模型中所有 RNN 的参数均通过训练学习, 为加速模型的训练速度, 引入参数共享机制, 即相同类别的作战单元采用参数相同的 RNN 来学习其属性。如图 5 所示, 由于作战单元 1 与作战单元 2 类别相同、作战单元 4 与作战单元 5 类别相同, 因此, 作战单元属性特征采用相同的 RNN, 即用相同颜色填充的 RNN 模块表示。参数共享机制一方面降低模型的数量, 另一方面增加模型的扩展性。

2.2.3 协同关系融合

图 3 所示战场协同行动识别架构最后是两个全连接层。层次循环神经网络从局部战场的时序态势中识别协同作战行动, 并将其映射为特征向量。每一个协同作战特征向量作为全相连第一层节点的输入, 假设第 i 个协同作战行动特征向量可记作 $co_i = (u_1^i, \dots, u_n^i, c_1, c_2, \dots, c_m)$, 其中 u_1^i, \dots, u_n^i 是该协同作战行动参与的作战单元。当且仅当两个神经元

节点输入的 co_i 和 co_j 之间满足如下条件时对调整其神经元权重, 即

$$\{u_1^i, \dots, u_n^i\} \cap \{u_1^j, \dots, u_n^j\} \neq \Phi \quad (3)$$

公式(3)即利用作战协同行动的局部传递性对局部战场中的协同行为进行聚类, 进而实现整个战场空间的协同行为识别。

3 实验分析

3.1 实验设置

3.1.1 数据准备

实验以计算机兵棋 Command Chains of War 的游戏数据为数据来源, 采用某游戏脚本为作战想定和兵力编成, 通过多人多次实际推演, 并按照实际速度的 20 倍, 从中随机抽取 N=6 000 个实际作战片段, 每个作战片段采用时间窗 M=12 帧的实际作战态势数据(每帧信息包括战场地理环境、作战单元

属性、作战单元状态等 24 维的态势信息)。经过归一化和预编码处理,建立互不重叠的训练样本集(包括 4 000 个作战片段)、校验样本集(包括 1 000 个作战片段)和测试样本集(包括 1 000 个作战片段)。

实验分析重点关注协同攻击、掩护撤离、战斗支援、战斗集结等协同作战行动的识别。由于协同作战行动由指挥人员下达,故采用指挥人员手工标注、计算机按照预设规则自动生成后由指挥人员修订相结合的方式标注样本标签。

3.1.2 数据编码

协同作战行动识别依赖于战场环境、作战单元属性及作战单元作战状态等战场态势数据的采集、预处理和编码。采集的样本数据主要由战场地理环境、作战单元属性、作战单元作战状态等信息构成。

假设 $U=\{u_1, u_2, \dots, u_{|U|}\}$ 为作战单元集,定义战场环境矩阵集 E^T 、作战单元属性集 $A^U = \{A^{u_1}, A^{u_2}, \dots, A^{u_{|U|}}\}$ 和实时作战状态矩阵集 $S^{U \times T} = \{S^{1,T}, S^{2,T}, \dots, S^{|U|,T}\}$, 其中, T 表示态势数据的时间序列集, L 表示战场坐标集, $\forall u_i \in U$, A^{u_i} 表示作战单元 u_i 的属性向量, $S^{u_i, T}$ 表示作战单元 u_i 在 T 时间段的作战状态矩阵, 且

$$E^T = \begin{bmatrix} e_1^1 & e_2^1 & \dots & e_{|E|}^1 \\ e_1^2 & e_2^2 & \dots & e_{|E|}^2 \\ \vdots & \vdots & \ddots & \vdots \\ e_1^T & e_2^T & \dots & e_{|E|}^T \end{bmatrix} \quad (4)$$

$$A^{u_i} = (a_1^{u_i}, a_2^{u_i}, \dots, a_{|A|}^{u_i}) \quad (5)$$

$$S^{u_i, T} = \begin{bmatrix} s_1^{u_i, 1} & s_2^{u_i, 1} & \dots & s_{|S|}^{u_i, 1} \\ s_1^{u_i, 2} & s_2^{u_i, 2} & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ s_1^{u_i, T} & s_2^{u_i, T} & \dots & s_{|S|}^{u_i, T} \end{bmatrix} \quad (6)$$

式中: $|U|$ 表示作战单元集的规模, $|E|, |A|, |S|$ 分别战场环境、作战单元属性、作战状态的特征数量, n, m 表示 L 的维度, 即战场空间维度。 $e_{ij, k}^{t_h} \in E_L^T$ 表示 t_h 时刻坐标 ij 处战场环境的第 k 种环境特征, $a_j^{u_i} \in A^{u_i}$ 表示作战单元 u_i 的第 j 种静态属性,

$s_k^{u_i, j} \in S^{u_i, T}$ 表示 t_j 时刻作战单元 u_i 的第 k 种作战状态特征。

经过数据采集、归一化等预处理后,借鉴文献[21]的编码思路对战场时序数据进行编码。定义整个战场空间态势矩阵 X 为

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (7)$$

$\forall x_{ij} \in X$ 表示 t_k 时刻战场位置 $l_{ij} \in L$ 样本特征向量, 且

$$x_{ij} = (x_E^1, x_E^2, \dots, x_E^T, x_A, x_S^1, x_S^2, \dots, x_S^T) \quad (8)$$

式中: $x_E^1, x_E^2, \dots, x_E^T$ 为环境特征矩阵归一化的结果, x_A 为作战单元属性归一化的结果; $x_S^1, x_S^2, \dots, x_S^T$ 为作战单元作战状态归一化的结果。采用上述编码后, 每一个战场空间编码长度为 $n \times m \times (|E| + |A| + |S|)$ 。

3.2 性能分析

3.2.1 收敛性分析

收敛性分析重点分析协同作战识别模型主体个数对模型收敛性的影响。实验采用基于 AdaGrad 的模型学习算法,对本文提出的 HRNNs 进行训练,训练参数按如下设置: 隐含层 LSTM 记忆单元数量为 24, 初始学习因子为 0.04, 分批大小为 100, 训练迭代次数为 100。并令协同作战识别模型主体个数分别取值为 $N=3, 5, 7, 11$, 统计 HRNNs 的训练误差和校验误差, 如图 6 所示。

从图 6 中可以看出, 当 $N=5$ 时收敛速度最快, $N=3$ 时精度最高。分析可知, 当 N 越小时, 时空循环神经网络结构越简单, 训练参数越少, 因此收敛速度更快; 且 N 越小, 主体数量越少, 越接近识别两个单元的协同行动, 因此误差也越来越低。此外, 当 $N=3$ 时, 由于战场空间划分粒度太小, 进而一定程度迟缓收敛过程, 考虑到局部战场空间协同识别的并行特性, 可采用并行训练策略加快收敛速度。

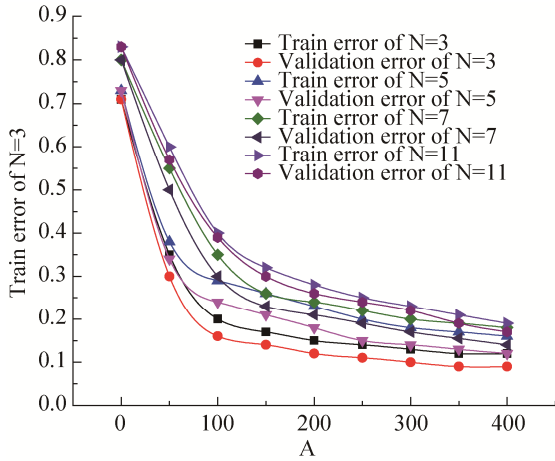


图 6 时空循环神经网络主体个数对收敛性的影响
Fig. 6 Influences of objects number in HRNNs on convergence

3.2.2 识别准确性分析

协同行动识别的准确性分析对比 ST-RNNs(本文算法), Multi-Markov^[1], Multi-agent^[5], 3DConv^[12], ST-DBN^[15]等 5 种行为识别算法, 如表 1 所示。对比实验采用包含 1 000 个作战片段的训练样本集, 其中包括协同攻击、掩护撤离、战斗支援、战斗集结及其他, 共 5 类协同作战行动, 且每类包含 200 个作战片段。作战协同行为识别的准确性从协同行动设计的单元和协同的类别两方面进行统计。

表 1 协同作战行动识别准确性对比
Tab. 1 Accuracy comparison for coordinated operational action recognition %

算法	协同类别	协同单元
ST-RNNs	92.3	91.6
ST-DBN	90.1	88.4
3DConv	87.3	86.8
Multi-Markov	80.5	82.4
Multi-agent	82.3	84.7

从表 1 可以看出, 本文提出的深度时空循环神经网络在协同行动识别方面具有较高的准确性。由于 ST-RNNs、ST-DBN 及 3DConv 在算法中引入了时空要素, 能有效识别协同行为中的时空特征, 因此再识别协同行为方面具有较好的精确性。而 ST-RNNs 不仅引入时空维度特征, 还利用协同行动的局部传递性实现协同行为单元的准确识别。

4 结论

针对联合作战中协同作战行动识别问题, 提出基于深度时空卷积神经网络的协同作战行动识别方法, 构建灵活可扩展的战场协同作战行为识别模型, 设计了建议窗口生成机制、局部战场协同作战行动识别的层次循环神经网络, 有效地减轻了战场协同作战行动识别面临的特征空间大、模型参数多、训练速度慢的问题。

参考文献:

- [1] 宋元, 王永春. 海上防空作战态势估计理论及应用[M]. 北京: 国防工业出版社, 2014.
Song Yuan, Wang Yongchun. The theory and application of sea air defense combat situation estimation[M]. Beijing: National Defense Industry Press, 2014.
- [2] Peng P, Wen Y, Yang Y, et al. Multiagent Bidirectionally-Coordinated Nets: Emergence of Human-level Coordination in Learning to Play StarCraft Combat Games[J]. 2017.
- [3] Blunsden S, Fisher R, Andrade E. Recognition of coordinated multi agent activities, the individual vs the group[J]. Language Culture & Curriculum (S0790-8318), 2006, 22(2): 157-174.
- [4] Min F, Groen F C A, Hao L. Dynamic Partition of Collaborative Multiagent Based on Coordination Trees[C]. Intelligent autonomous systems 12: proceedings of the 12th International Conference IAS-12, held June 26-29, 2012 Jeju Island, Korea. Springer, 2013, 2: 503-510.
- [5] Fang M, Groen F C A, Li H, et al. Collaborative multi-agent reinforcement learning based on a novel coordination tree frame with dynamic partition[J]. Engineering Applications of Artificial Intelligence (S0952-1976), 2014, 27(1): 191-198.
- [6] Liu L, Wang S, Su G, et al. Towards complex activity recognition using a Bayesian network-based probabilistic generative framework[J]. Pattern Recognition (S0031-3203), 2017, 68(C): 295-309.
- [7] Swears E, Hoogs A, Ji Q, et al. Complex Activity Recognition Using Granger Constrained DBN (GCDBN) in Sports and Surveillance Video[C]. IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2014: 788-795.
- [8] Diks C, Panchenko V. A new statistic and practical guidelines for nonparametric Granger causality testing[J].

- Journal of Economic Dynamics & Control (S0165-1889), 2006, 30(9): 1647-1669.
- [9] Liu L, Yang Y, Govindarajan L N, et al. An Interval-Based Bayesian Generative Model for Human Complex Activity Recognition[J]. arXiv: 1701.00903, 2017.
- [10] Zhu W, Lan C, Xing J, et al. Co-occurrence feature learning for skeleton based action recognition using regularized deep LSTM networks[C]. Thirtieth AAAI Conference on Artificial Intelligence. AAAI Press, 2016: 3697-3703.
- [11] Taylor G W, Fergus R, Lecun Y, et al. Convolutional learning of spatio-temporal features[C]. European Conference on Computer Vision. Springer-Verlag, 2010: 140-153.
- [12] Le Q V, Zou W Y, Yeung S Y, et al. Learning hierarchical invariant spatio-temporal features for action recognition with independent subspace analysis[C]. Computer Vision and Pattern Recognition. IEEE, 2011: 3361-3368.
- [13] Ji S, Xu W, Yang M, et al. 3D Convolutional Neural Networks for Human Action Recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence (S0162-8828), 2013, 35(1): 221.
- [14] Wang Keze, Wang Xiaolong, Lin Liang, et al. 3D Human Activity Recognition with Reconfigurable Convolutional Neural Networks[C]. Proceedings of the 2014 ACM Conference on Multimedia, 2014: 97-106.
- [15] Chen B. Deep Learning of Invariant Spatio-Temporal Features from Video[J]. University of British Columbia, 2010.
- [16] Jain A, Zamir A R, Savarese S, et al. Structural-RNN: Deep Learning on Spatio-Temporal Graphs[C]. Computer Vision and Pattern Recognition. IEEE, 2016: 5308-5317.
- [17] Von L T, Brodkorb F, Roskosch P, et al. MobilityGraphs: Visual Analysis of Mass Mobility Dynamics via Spatio-Temporal Graphs and Clustering[J]. IEEE Transactions on Visualization & Computer Graphics (S1077-2626), 2016, 22(1): 11-20.
- [18] Mondo G D, Rodríguez M A, Claramunt C, et al. Modeling consistency of spatio-temporal graphs[J]. Data & Knowledge Engineering (S0169-023X), 2013, 84(3): 59-80.
- [19] Yu B, Yin H, Zhu Z. Spatio-temporal Graph Convolutional Neural Network: A Deep Learning Framework for Traffic Forecasting[J]. arXiv: 1709.04875, 2017.
- [20] Uijlings J R, Sande K E, Gevers T, et al. Selective Search for Object Recognition[J]. International Journal of Computer Vision (S0920-5691), 2013, 104(2): 154-171.
- [21] 欧微, 柳少军, 贺筱媛, 等. 基于时序特征编码的目标战术意图识别算法[J]. 指挥控制与仿真, 2016, 38(6): 36-41.
- OU Wei, Liu Shaojun, He Xiaoyuan, et al. Tactical intention recognition algorithm based on encoded temporal features[J]. Command Control & Simulation, 2016, 38(6): 36-41.
-
- (上接第 784 页)
- [28] Girvan M, Newman M E J. Community structure in social and biological networks[J]. Proceedings of the National Academy of Sciences, 2002, 99(12): 7821-7826.
- [29] Martinez A M, Kak A C. PCA versus LDA[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence (S0162-8828), 2002, 23(2): 228-233.
- [30] Meng L, Ding S, Zhang N, et al. Research of stacked denoising sparse autoencoder[J]. Neural Computing & Applications (S0941-0643), 2016: 1-18.
- [31] BENGIO Y. Deep learning tutorial. <http://deeplearning.net>, LISA lab, University of Montreal, 2014.
- [32] Zhou X, Guo J, Wang S. Motion Recognition by Using a Stacked Autoencoder-Based Deep Learning Algorithm with Smart Phones[C]. International Conference on Wireless Algorithms, Systems, and Applications. Springer, Cham, 2015: 778-787.
- [33] Wu W, Hu X, Guo S, et al. Methods of Analyzing Combat SoS Coordination Pattern Based on Temporal Motif[C]. Asian Simulation Conference. Springer Singapore, 2016: 544-554.