

1-2-2019

A 3D Convolution Neural Network for Operational Aggregation Behavior Prediction

Liao Ying

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

Yi Zhuo

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

Xiaofeng Hu

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

Tian Yuan

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 3D Convolution Neural Network for Operational Aggregation Behavior Prediction

Abstract

Abstract: Operational aggregation behavior prediction has encountered the challenges of large feature space, dynamic changes of related combat units and large behavior noise, etc. To address these issues, a *operational aggregation behavior prediction method based on a 3D convolution neural network is proposed. In this method, a three-dimension convolution neural network is constructed by introducing the time dimension into the two-dimension convolution so as to recognize the operational aggregation behaviors. After that, a reconfigurable hierarchical long short-term memory (LSTM) network is adopted to analyze the temporal aggregation behavior data of related combat units, with which the key factors of aggregation behaviors such as time, location could be calculated.* Experiment results suggest that the proposed method could predict operational aggregation behaviors accurately. Meanwhile, the method will perform much better when introducing the man-in-the-loop mechanism.

Keywords

operational aggregation behavior, 3D convolution neural network, spatio-temporal feature, situation comprehension

Authors

Liao Ying, Yi Zhuo, Xiaofeng Hu, Tian Yuan, and Jiuyang Tao

Recommended Citation

Liao Ying, Yi Zhuo, Hu Xiaofeng, Tian Yuan, Tao Jiuyang. A 3D Convolution Neural Network for Operational Aggregation Behavior Prediction[J]. Journal of System Simulation, 2018, 30(3): 801-808.

基于三维卷积神经网络的战场聚集行为预测

廖鹰^{1,2}, 易卓¹, 胡晓峰², 田园¹, 陶九阳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:为解决战场聚集行为预测面临的特征空间大、涉及单元动态变化、聚集特征难以提取等挑战,提出基于三维卷积神经网络的战场聚合行为预测方法。通过在二维卷积核基础上引入时间维度,建立三维卷积神经网络模型,以识别战场聚集行为;通过构建可变结构的层次长短时记忆网络对聚集行为进行时序分析,预测聚集行为发生的时间、地点等关键要素。实验分析表明,该方法能较准确地预测战场的聚集行为,且引入人在回路策略将进一步提升预测的准确性。

关键词: 聚集行为; 3D卷积神经网络; 时空特征; 态势理解

中图分类号: TP183; E919 文献标识码: A 文章编号: 1004-731X (2018) 03-0801-08
DOI: 10.16182/j.issn1004731x.joss.201803005

A 3D Convolution Neural Network for Operational Aggregation Behavior Prediction

Liao Ying^{1,2}, Yi Zhuo¹, Hu Xiaofeng², Tian Yuan¹, Tao Jiuyang²

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

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

Abstract: Operational aggregation behavior prediction has encountered the challenges of large feature space, dynamic changes of related combat units and large behavior noise, etc. To address these issues, a operational aggregation behavior prediction method based on a 3D convolution neural network is proposed. In this method, a three-dimension convolution neural network is constructed by introducing the time dimension into the two-dimension convolution so as to recognize the operational aggregation behaviors. After that, a reconfigurable hierarchical long short-term memory (LSTM) network is adopted to analyze the temporal aggregation behavior data of related combat units, with which the key factors of aggregation behaviors such as time, location could be calculated. Experiment results suggest that the proposed method could predict operational aggregation behaviors accurately. Meanwhile, the method will perform much better when introducing the man-in-the-loop mechanism.

Keywords: operational aggregation behavior; 3D convolution neural network; spatio-temporal feature; situation comprehension

引言

战场聚集行为是联合作战环境常见的群体行



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: 廖鹰(1979-), 男, 江西上饶, 博士后, 副教授, 研究方向为作战指挥, 系统工程。

为,其通常是兵力调整、战斗集结、突然袭击等重要作战事件的先兆。预先识别敌方战场聚集行为,预判其聚集行为的时间、地点、目标等关键要素,对夺得战场作战先机具有重要意义。然而,由于战场作战单元密集、作战单元间关系动态变化,导致战场聚集行为面临若干挑战: 1) 聚集行为特征空间大, N 个作战单元可能存在 2^N 种聚集情况,而同一作战单元在不同时刻执行同一作战任务时,其

行为特征也不尽相同, 导致聚集行为特征空间大; 2) 参与作战单元数量不确定, 根据作战目标、任务分配、作战环境等差异, 相同的作战任务可能出现不同的聚集行为; 3) 聚集行为轨迹扰动大, 作战行动的机密性要求降低作战行动暴露的概率, 使得聚集行为具有一定的诱导, 而作战单元的自主性和战场环境的多变性进一步增加聚集行为的扰动。

通过研究, 聚集行为可视作群体向着某一特定目标运动的行为。从空间上看, 聚集行为在战场空间呈现出相对位置的变化; 从时间上, 聚集行为是作战单元群体密度从低到高变化的时间序列。因此, 战场聚集行为表现出特点的时空特征。

综上所述, 本文将时间序列建模引入卷积神经网络, 提出基于三维卷积神经网络的战场聚集行为识别方法。在空间维度, 在社团划分的基础上利用二维卷积确定时间维度的卷积范围; 在时间维度, 利用作战单元状态的时间序列识别战场态势中的聚集行为; 最后, 通过可变层次 LSTM 网络预测聚集行为的关键要素。

1 相关工作

战场聚集行为是多作战单元在执行相关作战任务时表现出的一种趋同的复杂行为, 受战场环境、指挥人员认知和作战任务多重因素影响。

现有关于聚集行为的研究中, 部分研究尝试从心理学、行为学和动力学方面分析聚集行为的特征。文献[1]将 Agent 模型引入元胞自动机, 通过赋予 Agent “感知-决策-行动” 的行为特点, 提出一种人群聚集模型。文献[2]从生理学和从众心理的角度, 分析人员疏散过程中聚集行为的动力学原理, 建立聚集行为的运动方程。文献[3]从好奇心的角度, 仿真分析个体与事件内容的关联度和人流量对聚集规模的影响。从聚集行为特征可以看出, 个体认知及作战目标可能导致聚集行为轨迹的扰动, 因此, 聚集行为识别需具有良好的抗噪能力。

聚集行为检测的研究主要从人群密度、角点特征和纹理等特征出发, 利用机器学习、贝叶斯特征

等方法检测聚集行为。文献[4]通过优化时空特征提取方法, 设计时空特征的竞争性神经网络模型, 以检测大规模人群中的异常行为。文献[5]将深度学习和卡尔曼滤波相结合, 通过行人检测和位置预测检测聚集行为。文献[6]利用角点聚类及人群角点面积, 分别提出两种人群聚集检测算法。文献[7]提出一种基于分布熵和平均运动速度的检测方法, 引入分布熵衡量人群密集程度, 实现对人群聚集行为的检测, 采用流光法跟踪人群运动角点, 计算运动速度。文献[8]将人群聚集视作管道液体流动过程, 通过形态边缘算法理论提取人群的边缘信息, 建立聚集人群流量方程, 实现聚集行为的检测。

2 战场聚集行为预测架构

为准确捕捉战场聚集行为, 预测聚集行为的关键要素, 战场聚集行为预测采用“识别+预测”的思路, 引入三维卷积神经网络^[9-12]对战场聚集行为进行预先识别, 构建可变层次 LSTM 网络^[10]对聚集出聚集行为的关键要素。同时, 为加速聚集行为识别, 采用社团划分机制对战场进行分解。

本文提出的战场聚集行为预测架构如图 1 所示, 预测过程如下: 1) 首先, 采用社团划分机制将战场划分子战场空间, 缩小聚集行为识别的空间维度; 2) 其次, 利用三维卷积神经网络模型对战场空间时序态势数据中的聚集行为进行识别, 并确定聚集行为涉及的作战单元; 3) 同时, 利用二维卷积从子战场空间态时序态势数据中提取各作战单元的时序行为, 并结合聚集行为识别结果, 利用 RELU 层调节可变层次 LSTM 网络结构, 预测聚集行为发生的时间节点和可能位置。

2.1 社团划分

社团划分主要使用的是凝聚式聚类的思想, 即开始每个点各成一簇, 然后重复的合并两个最近的簇, 直到达到指定的簇数量, 将凝聚式聚类的过程理解为节点之间自我组合的过程。最初阶段, 把网络结构的每个节点都当成一个个单独的社团或者

个体。每次进行迭代的时候,从与之相连的节点的集合中选择一个相似度系数最大或者“距离”最小

的节点合并,不断进行迭代,直到所有节点都被划分为止,算法流程如图 2 所示。

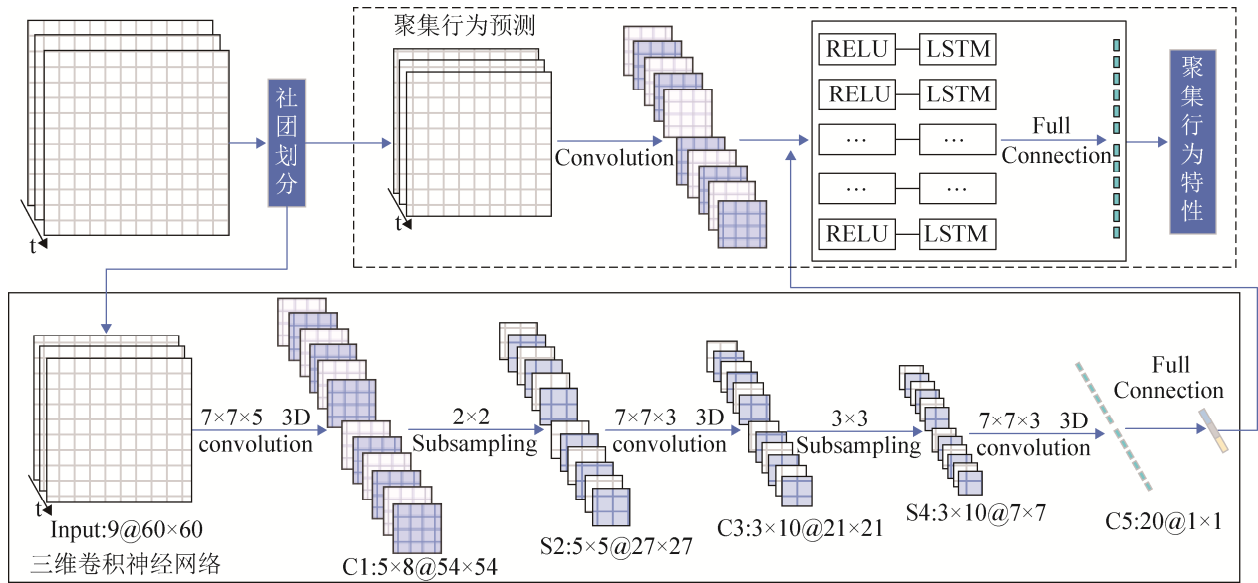


图 1 战场聚集行为预测架构
Fig. 1 Architecture for operational aggregation behavior prediction

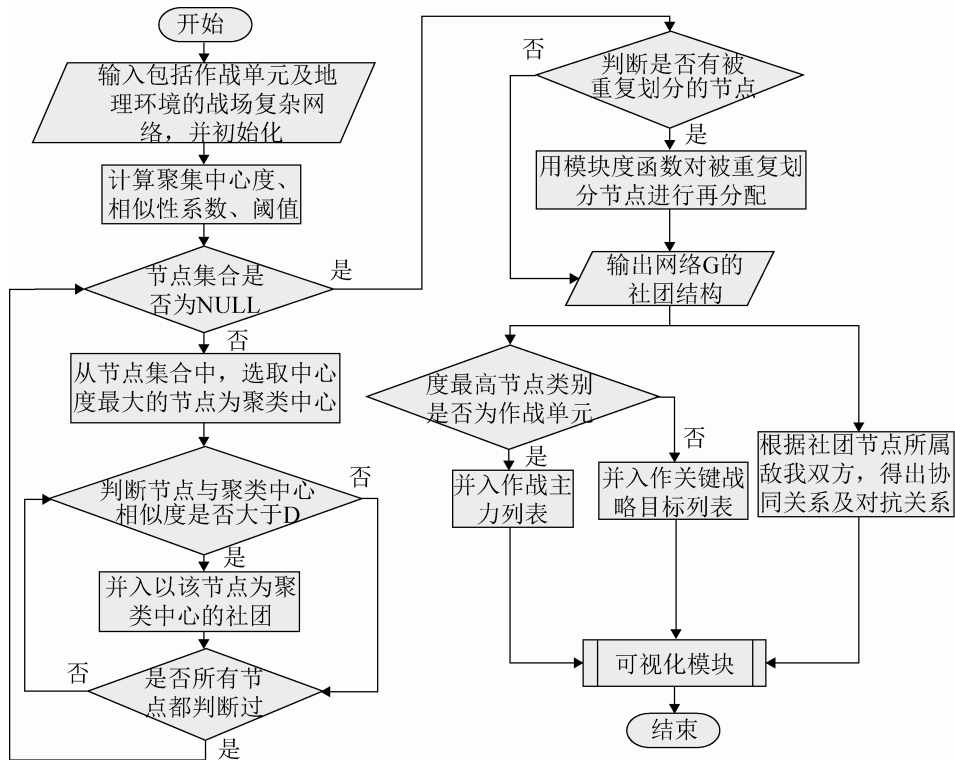


图 2 社团划分流程
Fig. 2 Procedure for community division

2.2 聚集行为识别的三维卷积神经网络

战场聚集行为可视为作战单元从各自的起始位置向某一固定目标运动的过程,具有明显的时空特征。二维卷积神经网络常用于提取二维数据特征图的特征,难以提取聚集行为的三维特征,因此,在二维卷积之上加入时间维度,构建聚集行为识别的三维卷积神经网络模型,用于提取战场聚集行为的时空特征,如图1预测架构中的下半部分所示。

由图1可看出,三维卷积神经网络由3个三维卷积层、2个下采样层及一个全连接层构成,其中C1, C3, C5为卷积层,并在C1和C3层之后分别设置一个下采样层S2和S4,降低特征维度。模型设定输入态势数据的时序长度为9,在第一个卷积层C1时,分别采用8个不同 $7 \times 7 \times 5$ 的三维卷积核识别作战单元的运动趋势,在第三层卷积层采用3个 $7 \times 7 \times 3$ 提取上一层S2层的组合特征。卷积层C5最后将上层特征图提取为 1×1 的特征,再经由全相连接层将时空域特征映射为特征向量。

2.2.1 三维卷积

3D卷积神经网络的核心在于3D卷积核,其由多个连续时间的2D卷积核堆叠而成,时间相邻的2D卷积核之间彼此连接,以便提取战场时序态

势中获取作战单元的静态属性特征及作战单元的运动特征,进而能捕捉作战单元的聚集行为,图3所示,其中图3(a)为 $7 \times 7 \times 3$ 的三维卷积核,图3(b)为三维卷积核依时间的展开。

令子战场空间的宽度和高度分别为 w 和 h ,三维卷积核的规模为 $w' \times h' \times m'$,其中宽、高及时间维度分别为 w' , h' , m' 。如图3(c)说明了利用图3(a)所示卷积核对时刻 z 到时刻 $z+m'-1$ 的时序态势进行卷积运算的过程。对于子战场空间 (x,y) 特征图进行三维卷积的结果可表示为

$$v_{xyz} = \tanh \left(b + \sum_{i=0}^{w'} \sum_{j=0}^{h'} \sum_{k=0}^{m'} \omega_{ijk} \cdot l_{(x+i)(y+j)(z+k)} \right) \quad (1)$$

式中: $l_{(x+i)(y+j)(z+k)}$ 表示时刻 $(s+k)$ 子战场空间 $(x+1, y+1)$ 处的战场态势; ω_{ijk} 表示卷积核对应位置的取值; b 表示特征图的偏置。

由于单个三维卷积核只能提取出战场态势中的一类聚集行为特征,因此,在图1所示三维卷积神经网络的每一层卷积层,都部署多个三维卷积核,以便获得不同的聚集行为特征。

此外,在卷积层C1和C3之后设置下采样层,可以在不改变特征图数量的前提下降低特征维度,减少模型参数,从而加快模型训练速度。

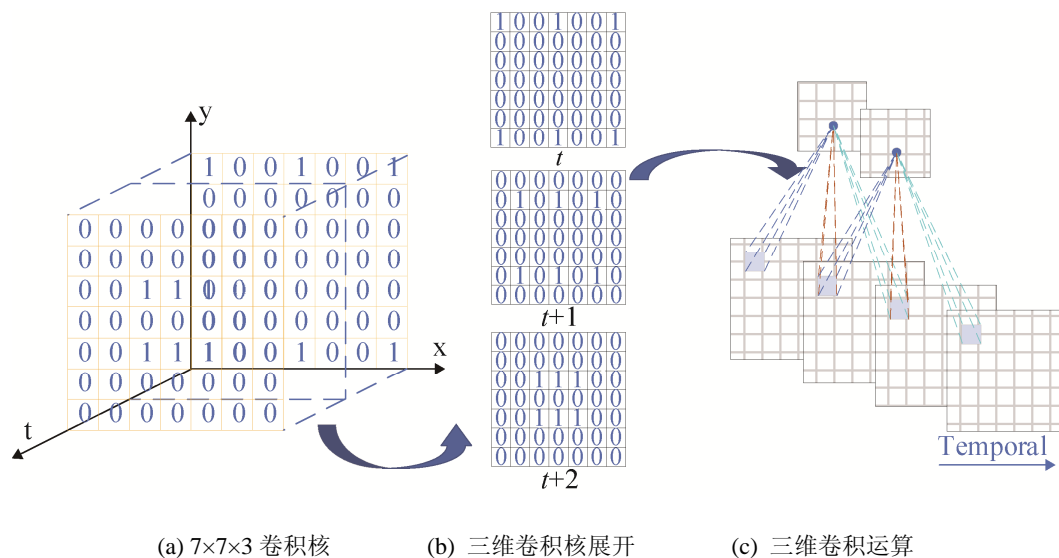


图3 三维卷积

Fig. 3 Three-dimensional convolution

2.2.2 扩展卷积算子

由于战场态势数据中存在大量的作战单元,且作战单元的运动轨迹相互交错,单纯利用三维卷积核对战场所态势进行卷积操作尚不能达到识别聚集行为识别的目的,还需要在卷积运算的过程中,考虑作战单元的属性特征。因此,在三维卷积神经网络卷积过程中,对传统的卷积运算进行扩展,将作战单元属性维度纳入卷积运算的计算过程中。扩展后的卷积运算可以用公式(2)表示

$$(v_{xyz}, a_{xyz}) = \tanh \left(b + \sum_{i=0}^{w'} \sum_{j=0}^{h'} \sum_{k=0}^{m'} a_{ijk} \cdot (l_{(x+i)(y+j)(z+k)} | a_{(x+i)(y+j)(z+k)}) \right) \quad (2)$$

式中: $a_{(x+i)(y+j)(z+k)}$ 表示时刻 $(s+k)$ 子战场空间位置 $(x+1, y+1)$ 所在作战单元的属性,符号“|”表示并列计算,即是三维卷积核在对 $l_{(x+i)(y+j)(z+k)}$ 进行卷积运算的同时,也对作战单元属性 $a_{(x+i)(y+j)(z+k)}$ 进行卷积运算,扩展卷积算子计算出的结果则为特征对 (v_{xyz}, a_{xyz}) 。由于在三维卷积运算过程中包含了作战单元属性特征,三维卷积神经网络最终输出的特征向量中也包含了聚集行为对应的属性。

2.3 聚集行为预测

三维卷积神经网络实现战场聚集行为的识别,锁定聚集行为发生的作战单元子集,为进一步确定聚集行为的聚集时间、聚集地点等重要聚集行为属性,采用可变结构的层次 LSTM 网络对聚集行为相关作战单元的行为进行预测,综合得出聚集行为的关键要素。

如图 1 所示预测架构中的聚集行为预测模块,其主要包括一个卷积层及一个可变结构层次 LSTM 网络。其中,卷积层主要是在聚集行为识别的过程中,同步提取战场各作战单元的时序行为数据,形成多通道时序分析。当聚集行为识别过程结束,输出聚集行为特征时,通过 RELU 层的选择,动态连通其后的 LSTM 层。如果 RELU 层选择连通 LSTM 层,则,利用 LSTM 时序网络预测作战单元未来的行为状态。最后,利用不同通道的未来

状态的综合,得出聚集行为将要发生的时间、地点及相关作战单元。

2.3.1 作战单元时序状态提取

为提取作战单元时序状态,引入二维卷积核,通过卷积不同时间的态势数据,获得作战单元每一时刻的态势数据。

假设 t 时刻作战单元 u_i 的态势数据定义为

$$u_i^t = (x_i^t, y_i^t, v_i^t, d_i^t, e_{xy}) \quad (3)$$

式中: x_i^t, y_i^t 为作战单元 u_i 所处位置; v_i^t, d_i^t 为作战单元 u_i 的运动速度; e_{xy} 为作战单元 u_i 所处位置的地理环境。定义整个战场空间态势矩阵 X 为

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (4)$$

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

$$x_{ij} = (x_E^t, x_E^t, \dots, x_E^t, x_A, x_S^t, x_S^t, \dots, x_S^t) \quad (5)$$

定义二维卷积核 C ,提取战场态势中作战单元的态势数据,则有

$$U_i = X \oplus C \quad (6)$$

利用上述卷积运算,即可获得作战单元的时序状态数据。

2.3.2 时间序列分析

时间序列分析利用长短期记忆网络对作战单元的时序状态数据进行预测分析。为了自适应预测聚集行为涉及的所有作战单元的运动状态,计算聚集行为的关键要素,在长短期记忆网络之前引入 RELU 层,将聚集行为识别结果输入 RELU 层,选择性地调节 LSTM 网络的层次结构,以屏蔽与聚集行为无关的态势数据。

为预测作战单元的运动轨迹,进而预测聚集行为,设计如图 4 所示长短期记忆单元。

首先,利用 t 时刻的输入 x_t 及 $t-1$ 时刻的隐含层输出 h_{t-1} 计算输入节点的值,如公式(7)所示,

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (7)$$




图4 长短期记忆网络结构

Fig. 4 Network structure for long short-term network

然后, 计算输入门的值, 如公式(8)所示,

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$

再按照公式(9-10)计算遗忘门和输出门的值,

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (9)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (10)$$

在公式(8)和(9)的基础上, 计算并更新记忆单元在 t 时刻的状态

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (11)$$

然后计算并更新模型在 t 时刻的隐含层输出

$$h_t = o_t \times \tanh(C_t) \quad (12)$$

最后, 根据 h_t 计算 t 时刻的输出 \hat{y}_t

$$\hat{y}_t = \varphi(W_h \cdot [h_t, x_t] + b_y) \quad (13)$$

3 实验分析

3.1 实验设置

本实验以计算机兵棋 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 30 倍, 以时间长度为 15 帧, 提取 500 组作战态势数据作为训练样本, 领取 500 组作战态势数据作为测试集, 其中 400 组用于聚集行为识别, 100 组用于聚集行为预测。

3.2 性能分析

实验主要对比了模型在聚集行为识别和聚集行为要素预测的准确性。

3.2.1 聚集行为识别

聚集行为识别主要采用本文提出的三维卷积神经网络(3D-CNN)对 400 组测试数据进行聚集行为识别, 如图 5 显示了若干作战态势的聚集行为识别情况。聚集行为识别主要是识别时序态势图中具有聚集关系的作战单元, 由图中红色框进行标注。

3.2.2 聚集行为要素预测

定义聚集行为预测的误差 ρ 如公式(14)所示:

$$\rho = \omega_1 \frac{\sqrt{(x - \hat{x})^2 + (y - \hat{y})^2}}{(x^2 + y^2)} + \omega_t \frac{|z - \hat{z}|}{z} + \omega_u \frac{|a - \hat{a}|}{a} \quad (14)$$

式中: ω_1 , ω_t , ω_u 分别为聚集地点、聚集时间及聚集行为在误差计算中的权重; (x, y) 表示实际聚集位置坐标; z, a 分别表示实际聚集时间和聚集行为总次数, 而 $(\hat{x}, \hat{y}), \hat{z}, \hat{a}$ 表示聚集位置坐标、聚集时间和聚集行为次数的预测值。

聚集行为预测采用 3 种不同结构的卷积神经网络作为基准算法, 对比分析算法预测聚集行为的准确性。这 3 种算法分别为 ConvNet-Kalman^[5], CompNN^[4]和 ConvGRBM^[13]。此外, 加上本文提出的三维卷积神经网络(记作 3D-CNN)和引入人在回路机制的三维卷积神经网络(记作 3DCNN-MITL), 共 5 种算法。实验针对采用 100 组测试样本进行预测, 实验结果如表 1 所示。

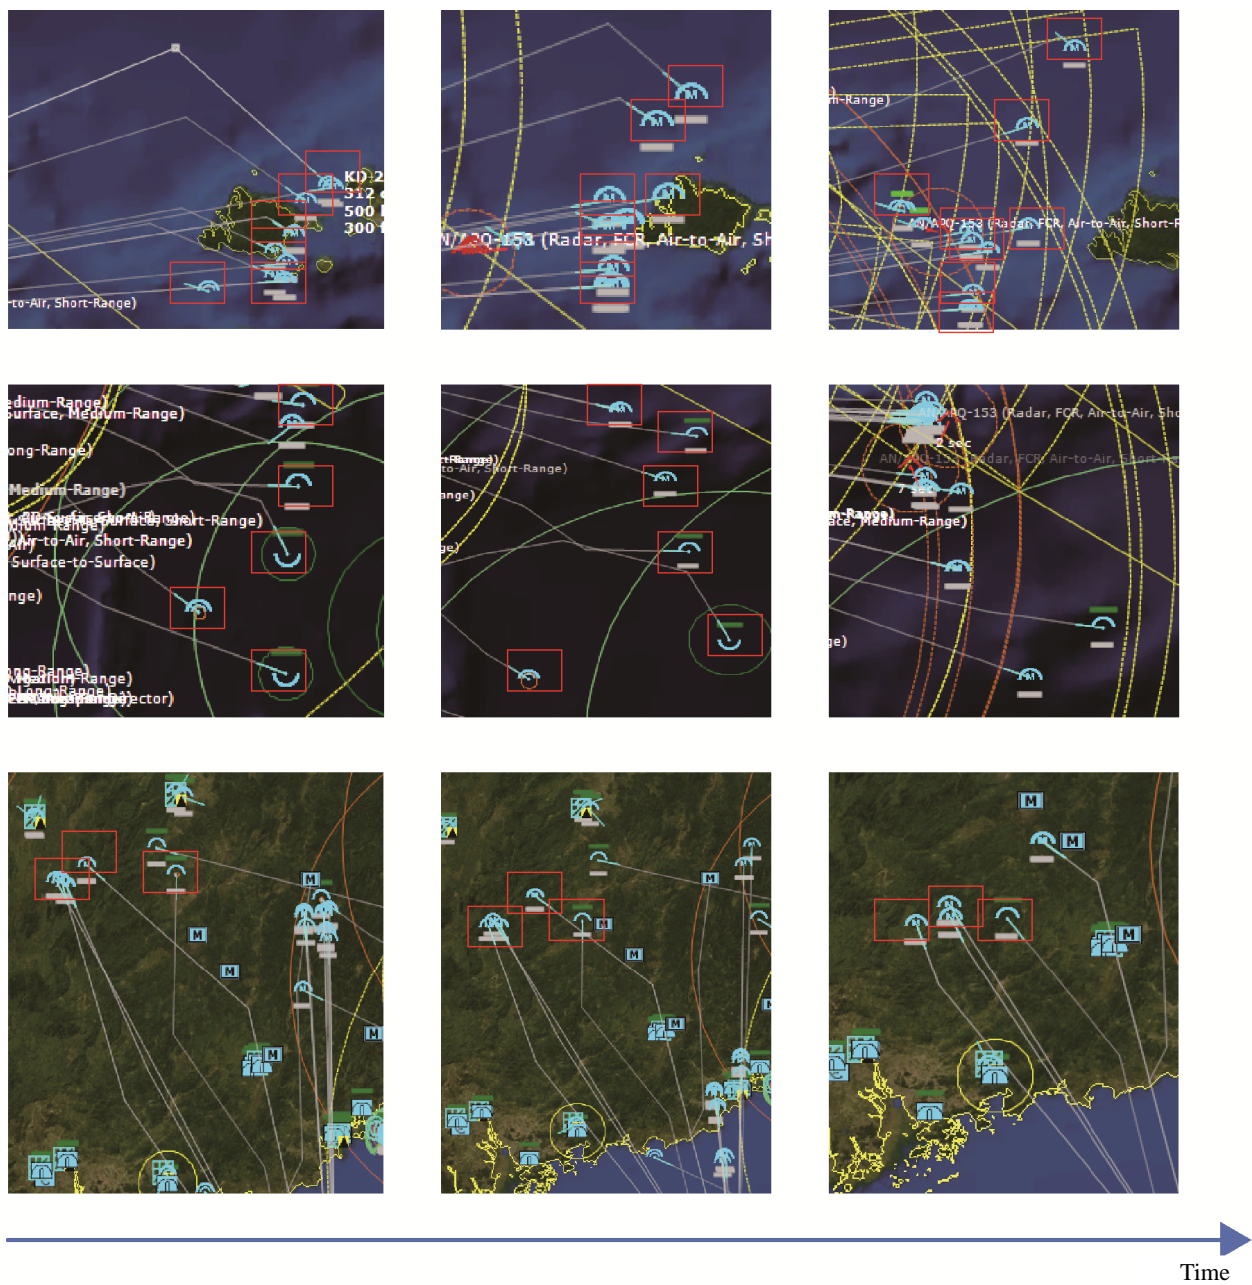


图 5 聚集行为识别

Fig. 5 Operational aggregation behavior prediction

表 1 预测精度

Tab. 1 Accuracy of prediction /%

算法	位置精度	时间精度	次数精度	总精度
3D-CNN	89.7	90.3	93.6	91.6
3D-CNN+MITL	93.5	92.8	93.6	93.3
ConvNet-Kalman	86.9	86.1	88.9	87.3
CompNN	85.1	86.7	86.5	86.1
ConvGRBM	88.6	87.4	93.1	89.7

如表 1 所示, 相比于 ConvNet-Kalman 算法、CompNN 算法和 ConvGRBM 算法, 本文提出的三维卷积神经网络在位置预测、时间预测及聚集行为识别方面均由较高的精度。同时, 将人在回路机制引入本文算法的预测部分时, 位置和时间预测精度得到提升, 证明了人机结合在态势识别中的优势。此外, ConvGRBM 及 3D-CNN 由于引入了时空特征, 在聚集行为识别方面具有更优的效果。

4 结论

战场聚集行为是联合作战行动中作战事件发生的先兆,为提前对敌方聚集行为进行预警,提出基于三维卷积神经网络的战场聚集行为识别方法。该方法将行为识别和时间序列分析相结合,在构建三维卷积神经网络识别聚集行为的基础上,设计可变结构 LSTM 网络对聚集行为进行时序分析,预测聚集行为发生的时间、地点等关键信息。此外,为加速预测过程,引入社团划分机制缩小聚集行为识别的范围,加速了模型预测速度。战场聚集行为的识别将极大地弥补人计算能力的不足,通过聚集行为预测的辅助,战场指挥人员可以准确预报预警战场中即将发生的重要作战行动,对夺得战场先机具有重大意义。

参考文献:

- [1] 常钦, 党会森. 基于网格 Agent 的群体性事件人群聚集模型研究[J]. 中国人民公安大学学报(自然科学版), 2011, 17(3):71-74.
Chang Qin, Dang Huiseng. Group event crowd aggregation model based on grid Agent[J]. Journal of Chinese People's Public Security University (Science and Technology), 2011, 17(3): 71-74.
- [2] 赵道亮, 王小群. 人员疏散中聚集行为的理论研究[J]. 上海应用技术学院学报(自然科学版), 2013, 13(1): 12-16.
Zhao Daoliang, Wang Xiaoqun. Theoretical study on assembling behavior during occupant evacuation[J]. Journal of Shanghai Institute of Technology (Science and Technology), 2013, 13(1): 12-16.
- [3] 殷雁君, 唐卫清. 好奇心理的人群聚集行为仿真[J]. 智能系统学报, 2014, 9(4):413-418.
Yin Yanjun, Tang Weiqing. Simulation of the crowd collective behavior based on curiosity[J]. CAAI Transactions on Intelligent Systems, 2014, 9(4): 413-418.
- [4] Zhang D, Peng H, Yu H, et al. Crowd Abnormal Behavior Detection Based on Machine Learning[J]. Information Technology Journal (S1812-5638), 2013, 12(6).
- [5] 李春旭. 面向复杂公共区域的群体聚集性计算方法研究[D]. 郑州: 郑州大学, 2017.
Li Chunxu. The Study of Crowd Aggregation Computation in Public Areas[D]. Zhengzhou: Zhengzhou University, 2017.
- [6] 何丽文. 基于角点特征的人群聚集事件与行为检测算法的研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
He Liwen. Detection of crowd gathering events and behavior based on corner feature[D]. Harbin: Harbin Institute of Technology, 2013.
- [7] 桑海峰, 陈禹, 何大阔. 基于整体特征的人群聚集和奔跑行为检测[J]. 光电子·激光, 2016(1): 52-60.
Sang Haifeng, Chen Yu, He Dakuo. Crowd gathering and running behavior detection based on overall features[J]. Journal of Optoelectronics · Laser, 2016(1): 52-60.
- [8] 郝永杰. 基于智能视觉的人群忽然聚集过程软件检测算法[J]. 科技通报, 2015(3):181-183.
Hao Yongjie. People Suddenly Gathered Process Software Detection Algorithm Based on Intelligent Vision[J]. Bulletin of Science and Technology, 2015(3): 181-183.
- [9] 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), 2012, 35(1): 221-231.
- [10] Wang K, Wang X, Lin L, et al. 3D Human Activity Recognition with Reconfigurable Convolutional Neural Networks[C]. Proceedings of the ACM International Conference on Multimedia. ACM, 2015: 97-106.
- [11] Sozykin K, Khan A M, Protasov S, et al. Multi-label Class-imbalanced Action Recognition in Hockey Videos via 3D Convolutional Neural Networks[J]. arXiv: 1709.01421. 2017.
- [12] Ding C, Fan S, Zhu M, et al. Violence Detection in Video by Using 3D Convolutional Neural Networks[M]// Advances in Visual Computing. Springer International Publishing, 2014: 551-558.