

6-4-2020

A CNN Based Cognitive Method to Battlefields Encompassing Situation with Insufficient Samples

Zhu Feng

1. The Department of Information Operation and Command Training, National Defense University, Beijing 100091, China;;2. No. 93682 Unit of PLA, Beijing 101300, China;;

Xiaofeng Hu

1. The Department of Information Operation and Command Training, National Defense University, Beijing 100091, China;;

Xiaoyuan He

1. The Department of Information Operation and Command Training, National Defense University, Beijing 100091, China;;

Yisi Kong

1. The Department of Information Operation and Command Training, National Defense University, Beijing 100091, 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 CNN Based Cognitive Method to Battlefields Encompassing Situation with Insufficient Samples

Abstract

Abstract: To research the issue of how to grasp the commander's cognitive experience successfully and effectively facing to battlefields sight map, Convolution Neural Network (CNN) as a kind of the typical algorithm in deep learning can provide the key ways. However, CNN needs the enough samples for running. These samples are hardly to achieve for the time being. Aimed at these problems, some exploring researches were carried out. The issues of battlefields encompassing situation cognition met generally in the warfare and lacking enough samples were discussed. On the basis of analyzing the image characteristics of battlefields encompassing situation and the operational principles of CNN, *a new method of battlefields encompassing situation cognition based on CNN without enough samples was proposed. In the method, the non-linear fitting function of CNN and the symmetry characteristics of the battlefields encompassing situation images were utilized to catch the commander's experience for cognizing the battlefields encompassing situation at a certain extent.* Simulation results validate the effectiveness and the robustness of the proposed method.

Keywords

battlefields encompassing situation cognition, commanders, method of establishing models, CNN, insufficient samples, deep learning

Authors

Zhu Feng, Xiaofeng Hu, Xiaoyuan He, Yisi Kong, and Yang Lu

Recommended Citation

Zhu Feng, Hu Xiaofeng, He Xiaoyuan, Kong Yisi, Yang Lu. A CNN Based Cognitive Method to Battlefields Encompassing Situation with Insufficient Samples[J]. Journal of System Simulation, 2017, 29(10): 2291-2300.

一种基于 CNN 的样本不足战场包围态势认知方法

朱丰^{1,2}, 胡晓峰¹, 贺筱媛¹, 孔亦思¹, 杨璐^{3,4}(1.中国人民解放军国防大学信息作战与指挥训练教研部, 北京, 100091; 2.中国人民解放军93682部队, 北京, 101300;
3.中国人民解放军91053部队, 北京, 100070; 4.空军工程大学防空反导学院, 陕西西安, 710051)

摘要: 为研究面对战场视图如何捕捉到指挥员认知经验的问题, 深度学习中 CNN 可提供有力支持。但 CNN 的训练需要足够的样本数据, 目前难以获得。针对战争中常见的战场包围态势认知及样本不足问题进行了剖析, 提出一种基于 CNN 的样本不足包围态势认知新方法, 该方法利用 CNN 的非线性拟合功能及包围态势图像的对称特性, 可在一定程度上获得指挥员对包围态势的认知经验。仿真实验结果证明了方法的有效性和鲁棒性。

关键词: 战场包围态势认知; 指挥员; 建模方法; 卷积神经网络; 样本不足; 深度学习
中图分类号: TP183 文献标识码: A 文章编号: 1004-731X (2017) 10-2291-10
DOI: 10.16182/j.issn1004731x.joss.201710009

A CNN Based Cognitive Method to Battlefields Encompassing Situation with Insufficient Samples

Zhu Feng^{1,2}, Hu Xiaofeng¹, He Xiaoyuan¹, Kong Yisi¹, Yang Lu^{3,4}(1. The Department of Information Operation and Command Training, National Defense University, Beijing 100091, China;
2. No. 93682 Unit of PLA, Beijing 101300, China; 3. No. 91053 Unit of PLA, Beijing 100070, China;
4. Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China)

Abstract: To research the issue of how to grasp the commander's cognitive experience successfully and effectively facing to battlefields sight map, Convolution Neural Network (CNN) as a kind of the typical algorithm in deep learning can provide the key ways. However, CNN needs the enough samples for running. These samples are hardly to achieve for the time being. Aimed at these problems, some exploring researches were carried out. The issues of battlefields encompassing situation cognition met generally in the warfare and lacking enough samples were discussed. On the basis of analyzing the image characteristics of battlefields encompassing situation and the operational principles of CNN, a new method of battlefields encompassing situation cognition based on CNN without enough samples was proposed. In the method, the non-linear fitting function of CNN and the symmetry characteristics of the battlefields encompassing situation images were utilized to catch the commander's experience for cognizing the battlefields encompassing situation at a certain extent. Simulation results validate the effectiveness and the robustness of the proposed method.

Keywords: battlefields encompassing situation cognition; commanders; method of establishing models; CNN; insufficient samples; deep learning

引言

军事领域中, 战场态势认知一直是个未完全解



收稿日期: 2017-04-30; 修回日期: 2017-07-28;
基金项目: 国家自然科学基金(61374179), 国家自然科学基金青年科学基金(61703412), 军民共用重大研究计划联合基金(U1435218), 中国博士后科学基金(2016M602996);
作者简介: 朱丰(1983-), 男, 北京, 博士后, 工程师, 研究方向为战场态势评估与辅助决策分析、体系效能评估、深度学习理论与方法、雷达信号与信息处理。

决的重要难题。特别是在当今信息化主导的大数据时代, 这个难题的研究解决显得更为严峻。因为, 大数据时代带来了爆炸式增长的“全息战场大数据”(主要包括: 情报、侦察、监控等数据)^[1], 这些大数据会像迅猛的洪流一样高速涌入, 其积累效应远远超出了人的分析处理能力, 此时, 仅靠传统的指挥员主观认知和判断来理解和掌握战场态势, 就像“打开高压水管喝水一样困难”, 因此, 必须要突

破传统观念,借助计算机及有关智能手段辅助指挥员来完成战场态势认知^[2]。这样一来,对于战场态势认知的研究而言,无疑又增加了很多新的难点和挑战。首先一点就是,基于智能手段的战场态势认知结果是否合理、有效,是否与指挥员的思维结果一致,这就需要立足于指挥员的思维模式,研究指挥员战场态势认知思维建模方法。

通常,指挥员在认知战场态势时,首先在战场一级数据(即对战场上目标位置和身份等的估计)融合处理的基础上,要依据当前的战场情况,建立关于作战活动、事件、时间、位置、兵力要素等组织形式的一张多重视图,即战场视图^[3];然后,根据这个战场视图并结合其他有关信息,基于自己的已有经验和临机智慧来理解和预测战场态势^[4-5]。在这过程中,很多情况往往都是指挥员“运用之妙、存乎一心”、“只可意会,不可言传”的经验之举,很难通过简单的数学模型进行理论表达和模拟,那么,基于复杂的战场视图,如何对指挥员的认知经验进行建模,以期有效捕捉到指挥员的认知经验,是亟需研究探索突破的关键问题。

深度学习作为智能方法中的新兴典型代表^[6-8],被誉为最接近人脑的智能学习方法,目前已在很多领域都发挥着重要作用,具有广泛的应用前景。特别是其中的卷积神经网络(Convolution Neural Network, CNN)对于图像处理、提取图像特征有着独特的优势^[9-11],因此, CNN 在语音谱图识别、图像识别等领域中已有广泛的应用,同时在图像去噪、图像反卷积、图像修复、基于图像特征的视频处理等诸多领域也很强大的应用潜力。从 CNN 构建原理上分析知, CNN 所具有的深层神经网络结构是典型的复杂网络结构,甚至是个黑箱结构,该结构随着输入、输出的变化也在不断调整演变,这个原理与指挥员头脑中的思维机理是基本一致的,因此,依据指挥员战场态势认知思维,利用 CNN 来研究指挥员面对战场视图的态势认知建模问题,即对复杂系统的非线性建模问题,从而捕捉指挥员的认知经验,是一条有探索价值的新途径,

更是一个难得的宝贵研究契机。

但是,利用深度学习开展研究进行训练时,需要大量的数据样本,而对于平时期的战争问题特别是战场态势认知问题的研究而言,由于真实战争或大规模演习场次极为有限难以获得很多大量的实际战争或包含指挥员经验的“人在回路”的计算机战争推演样本数据,因此,需要研究样本不足问题的解决办法。目前,可通过以下两个主要思路来研究解决,一是从样本数据角度出发,通过变换处理构造出大量的有效样本数据^[12-14];二是从模型算法角度出发,通过改造算法设计出适合无大量数据样本条件下的战场态势认知模型^[15-16],这两方面相辅相成,共同促进,都具有需要开展探索研究的广泛空间。

鉴于此,本文对利用 CNN 进行战场态势认知建模这个问题展开了探索性研究,对于战争中常见的战场包围态势认知问题进行了剖析和探索,在分析了战场包围态势图像特点及其对称特性,以及 CNN 运行原理的基础上,针对态势数据样本不足问题,从构造大量样本数据的角度,提出了一种基于 CNN 的样本不足条件下的战场包围态势认知新方法,该方法利用 CNN 的运行原理来对指挥员认知战场包围态势的认知经验进行探索性的建模,并通过图像变换探索解决态势认知样本不足问题,从而达到了在一定程度上获得指挥员认知包围态势经验的目的。仿真实验结果表明了本文方法具有很好的正确认知率,证明了该方法的有效性和鲁棒性。

1 战场包围态势图像矩阵

(1) 基本概述

指挥员在认知战场态势时,首先通过一定的处理(主要包括划分感兴趣区域 U ,并对各方作战实体及其属性的统计、整理、运算等来抽象为作战单元从而完成战场态势特征表示)来建立从空间分布角度认知的战场视图,即提炼为图像矩阵。假设战场平面上南北 L_M km 宽、东西 L_N km 宽范围内的战场视图图像矩阵为 $S_{A \times B}$,该矩阵表示敌我双方各作

战单元地理分布情况, 公式表达如下

$$S_{A \times B} = \{s_{ab}\} = \begin{bmatrix} s_{11} & \cdots & s_{1B} \\ \vdots & \ddots & \vdots \\ s_{A1} & \cdots & s_{AB} \end{bmatrix}_{A \times B},$$

$$a = 1, 2, \dots, A, b = 1, 2, \dots, B \quad (1)$$

其中, $S_{A \times B}$ 中共有 $A \times B$ 个元素, 每个元素为图像的像素, 取值为 $[0, 255]$ 内的整数值, A 为纬度方向上的像素个数, B 为经度方向上的像素个数, 可知

$$L_A = A \cdot D_A \quad (2)$$

$$L_B = B \cdot D_B \quad (3)$$

其中, D_A km、 D_B km 分别为纬度、经度分辨率。

假设图像矩阵 $S_{A \times B}$ 中敌、我双方呈现包围态势的作战单元分别为 s_n 和 s'_n , 对应图像矩阵中的坐标分别为 (x_n, y_n) 和 (x'_n, y'_n) , $n=1, 2, \dots, N$, $n'=1, 2, \dots, N'$, 其中, N 和 N' 分别表示敌、我双方呈现包围态势的作战单元个数, 被包围的作战单元所在区域为 V , 形成包围的作战单元所在区域为 V' , ($V \subset V' \subseteq U$), 则

命题(1): 敌方对我方形成包围态势的图像为

$$(x'_n, y'_n) \in V, n' = 1, 2, \dots, N' \quad (4)$$

$$(x_n, y_n) \in V', \text{且} (x_n, y_n) \notin V, n = 1, 2, \dots, N \quad (5)$$

此外, 当敌、我双方部分作战单元所处坐标不满足上述公式, 但形成的总体态势也类似于敌方对我方形成包围的趋势时, 也归为敌方对我方形成包围态势的图像。

命题(2): 我方对敌方形成包围态势的图像为

$$(x_n, y_n) \in V, n = 1, 2, \dots, N \quad (6)$$

$$(x'_n, y'_n) \in V', \text{且} (x'_n, y'_n) \notin V, n' = 1, 2, \dots, N' \quad (7)$$

此外, 当敌、我双方部分作战单元所处坐标不满足上述公式, 但形成的总体态势也类似于我方对敌方形成包围的趋势时, 也归为我方对敌方形成包围态势的图像。

命题(3): 敌、我双方未形成明显的包围态势图像为命题(1)、(2)都不成立时的战场视图图像。

(2)对称特性

针对战场视图图像矩阵 $S_{A \times B}$, 假设具有包围态势的图像矩阵为 $S_{A \times B}$,

$$\tilde{S}_{A \times B} = \{\tilde{s}_{ab}\} = \begin{bmatrix} \tilde{s}_{11} & \cdots & \tilde{s}_{1B} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{A1} & \cdots & \tilde{s}_{AB} \end{bmatrix}_{A \times B},$$

$$a = 1, 2, \dots, A, b = 1, 2, \dots, B \quad (8)$$

其中, $S_{A \times B}$ 中共有 $A \times B$ 个元素, 每个元素为图像的像素, 取值为 $[0, 255]$ 内的整数值, 且 $S_{A \times B}$ 满足命题(1)或命题(2)。

从这两个命题可以看出, 在包围态势认知过程中, 由于图像的特点, 对 $S_{A \times B}$ 的认知满足以下几个对称特性:

特性(1): 图像矩阵转置对包围态势的认知结果不变

对具有包围态势的图像矩阵 $S_{A \times B}$ 进行转置运算, 即得到如下表达式

$$\tilde{S}_{A \times B}^T = \{\tilde{s}_{ab}\}^T = \begin{bmatrix} \tilde{s}_{11} & \cdots & \tilde{s}_{A1} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{1B} & \cdots & \tilde{s}_{AB} \end{bmatrix}_{B \times A} \quad (9)$$

按照该表达式的运算原理, 图像矩阵 $S_{A \times B}$ 中坐标分别为 (x_n, y_n) 和 (x'_n, y'_n) 的敌、我双方呈现包围态势的作战单元 s_n 和 s'_n , 经转置运算后, 坐标分别为 (y_n, x_n) 和 (y'_n, x'_n) 。根据包围态势的特点, 转置运算后, 这些作战单元 s_n 和 s'_n 所对应的坐标位置仍呈现出包围的态势, 因此, $\tilde{S}_{A \times B}^T$ 仍为包围态势, 且与 $S_{A \times B}$ 具有相同的包围态势认知结果。

特性(2): 图像矩阵上下、左右颠倒对包围态势的认知结果不变

对具有包围态势的图像矩阵 $S_{A \times B}$ 进行上下或左右颠倒运算, 即得到如下表达式

$$\tilde{S}'_{A \times B} = \Phi_{ud}(\tilde{S}_{A \times B}) = \begin{bmatrix} \tilde{s}_{A1} & \cdots & \tilde{s}_{AB} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{11} & \cdots & \tilde{s}_{1B} \end{bmatrix}_{A \times B} \quad (10)$$

$$\tilde{S}''_{A \times B} = \Phi_{lr}(\tilde{S}_{A \times B}) = \begin{bmatrix} \tilde{s}_{1B} & \cdots & \tilde{s}_{11} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{AB} & \cdots & \tilde{s}_{A1} \end{bmatrix}_{A \times B} \quad (11)$$

其中, $S'_{A \times B}$ 和 $S''_{A \times B}$ 分别为对图像矩阵 $S_{A \times B}$ 进行上下和左右颠倒运算的结果。按照这些表达式的运算原理, 图像矩阵 $S_{A \times B}$ 中坐标分别为 (x_n, y_n) 和 (x'_n, y'_n) 的敌、我双方呈现包围态势的作战单元 s_n 和 s'_n ,

经上下、左右颠倒运算后,坐标分别为

$(x_n, \max(y_n) - y_n + \min(y_n))$ 和 $(x'_n, \max(y'_n) - y'_n + \min(y'_n))$ 以及 $(\max(x_n) - x_n + \min(x_n), y_n)$ 和 $(\max(x'_n) - x'_n + \min(x'_n), y'_n)$, 根据包围态势的特点,上下、左右颠倒运算后,这些作战单元 s_n 和 s'_n 所对应的坐标位置仍呈现出包围的态势,因此, $S'_{A \times B}$ 和 $S''_{A \times B}$ 均为包围态势,且均与 $S_{A \times B}$ 具有相同的包围态势认知结果。

特性(3): 图像矩阵旋转任意个 90° 后对包围态势的认知结果不变

对具有包围态势的图像矩阵 $S_{A \times B}$ 进行旋转任意个 90° 运算,其中,旋转 1 至 3 个 90° 的运算如下表达式,旋转 4 个 90° 的运算结果即为图像矩阵 $S_{A \times B}$ 本身,旋转大于等于 4 个 90° 的运算结果即进入循环,循环结果为 $S_{A \times B}$ 本身和旋转 1 至 3 个 90° 的运算结果,具体表达如下(以逆时针旋转为例)

$$\tilde{S}_{B \times A}^{*4z+1} = \Psi_{90^\circ}^{*1}(\tilde{S}_{A \times B}) = \begin{bmatrix} \tilde{s}_{1B} & \cdots & \tilde{s}_{AB} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{11} & \cdots & \tilde{s}_{A1} \end{bmatrix}_{B \times A} \quad (12)$$

$$\tilde{S}_{A \times B}^{*4z+2} = \Psi_{90^\circ}^{*2}(\tilde{S}_{A \times B}) = \Psi_{90^\circ}^{*1}(\tilde{S}_{B \times A}^{*1}) = \begin{bmatrix} \tilde{s}_{AB} & \cdots & \tilde{s}_{A1} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{1B} & \cdots & \tilde{s}_{11} \end{bmatrix}_{A \times B} \quad (13)$$

$$\tilde{S}_{B \times A}^{*4z+3} = \Psi_{90^\circ}^{*3}(\tilde{S}_{A \times B}) = \Psi_{90^\circ}^{*2}(\tilde{S}_{B \times A}^{*1}) = \Psi_{90^\circ}^{*1}(\tilde{S}_{A \times B}^{*2}) = \begin{bmatrix} \tilde{s}_{A1} & \cdots & \tilde{s}_{11} \\ \vdots & \ddots & \vdots \\ \tilde{s}_{AB} & \cdots & \tilde{s}_{1B} \end{bmatrix}_{B \times A} \quad (14)$$

$$\tilde{S}_{A \times B}^{*4z+4} = \tilde{S}_{A \times B} \quad (15)$$

其中, $z \in \mathbb{Z}$ 。按照上述表达式的运算原理,根据包围态势的特点,图像矩阵 $S_{A \times B}$ 中坐标分别为 (x_n, y_n) 和 (x'_n, y'_n) 的敌、我双方呈现包围态势的作战单元 s_n 和 s'_n , 经旋转任意个 90° 后所对应的坐标位置仍呈现出包围的态势,因此, $\tilde{S}_{B \times A}^{*4z+1}$ $\tilde{S}_{A \times B}^{*4z+2}$ $\tilde{S}_{B \times A}^{*4z+3}$ $\tilde{S}_{A \times B}^{*4z+4}$ 均为包围态势,且与 $S_{A \times B}$ 具有相同的包围态势认知结果。


此外,对于满足命题(3),即敌、我双方未形

成明显的包围态势的战场视图图像矩阵 $S_{A \times B}$, 也满足上述三个对称特性,即通过上述这些图像变换后对于是非包围态势的认知结果保持不变。

基于以上论述分析,可以利用战场视图图像矩阵的对称特性来构造更多的有效样本数据,为探索解决样本不足问题提供支持。

2 卷积神经网络及运行原理

CNN 受启发于猫的视觉系统结构,即以局部感受野来平铺覆盖整个视野区域,这种方式可以在具备深层次网络结构的同时大幅减少了网络参数(如图 1 所示),使得基于深层网络结构的训练变得更加可行,由此打破了原有全连接浅层神经网络的技术瓶颈,因而获得了全球专家、学者的广泛关注。由于 CNN 具有很好的图像处理、提取图像特征等独特优势,目前已在相关重要领域已有广泛的应用,同时也在很多其他领域具有强大的应用潜力^[9]。



(a) 全连接 (b) 局部感受野 (c) 权重共享
图 1 CNN 减少参数的过程示意图

Fig. 1 Sketch of CNN process of reducing parameters

CNN 的运行原理是通过多重组合、底层信息学习、寻找关联关系、再自底向上地逐层压缩,从而实现端到端的训练,完成对大量样本的全面学习,即非线性拟合过程,网络中的各个连边都对应着不同的权重,即非线性拟合的待定系数。可以见得,这个过程很像人脑的思维过程。与 BP 类似, CNN 采用前向传播计算输出值,反向传播调整权重和偏置,其结构模型如图 2 所示,经典的 CNN 主要包括卷积层(C)、降采样层(S)和全连接层(F)三大部分。卷积层的卷积核本质就是特征提取器,配合深度网络模型可以自动提取输入信号的深层信息;

降采样层即池化层, 实现特征图的采样处理, 在减少数据量的同时保留有用的信息, 也使 CNN 具有抗畸变的能力; 全连接层(如逻辑分类、softmax 层)一般位于网络末端, 对前面逐层变换和映射提取的特征进行回归分类等处理, 也可作输出层, 把训练得到的特征图汇总成特征向量, 为输入图像的另一信息表示。CNN 通过增加隐含层的层数可以明显增强网络学习能力, 学到的特征更贴近待识别事物本身。值得注意的是, 正是由于 CNN 网络中包含了大量的神经元以及它们之间复杂的连接关系, 因此, 为有效地训练出 CNN 网络, 需要具备充足的数据集, 包括训练数据集、测试数据集等。




图 2 CNN 结构模型示意图

Fig. 2 Sketch of CNN structure model

目前, 随着深度学习以及 CNN 研究的不断进步, 许多改进的 CNN 模型被相继提出, 主要包括: 1) 对 CNN 卷积层的改进, 如 Krizhevsky、Zhang、DeepMind 公司、Szegedy 等组成的 GoogLeNet 小组以及 ILSVRC 分别构建了 5、7、13、22 和 152 层的 CNN。随着 CNN 构建的层数逐渐增加, 一些新的技术不断被提出和应用来解决更深层网络进行图像分类识别时的准确度与层数之间的矛盾, 但可以见得, 随着层数的不断提高, 识别准确度的整体趋势是不断提高的。2) 对 CNN 降采样层的改进, 如 He、Rippel、Zeiler 等人及所在的研究团队分别提出了金字塔降采样网络、基于傅里叶变换的频谱池化方法以及反卷积(DN)网络, 从不同角度对降采样的池化过程进行改进。3) 对 CNN 全连接层的改进, 如 Krizhevsky、孙艳丰、Girshick、Ren 等研究人员分别提出了采用“Dropout”策略、基于改进 Fisher 准则的 CNN 识别算法、基于区域特征卷积的 CNN 识别算法以及快速区域特征卷积算法

等来构建全连接层, 可更利于完成图像分类和特征识别, 提高运行效率。

3 基于 CNN 的战场包围态势认知方法

依据前述的战场包围态势图像特点特别是其对称特性以及 CNN 的运行原理, 本文提出一种基于 CNN 的样本不足条件下战场包围态势认知新方法, 该方法的主要运行原理是, 由于 CNN 所具有的深层复杂结构可体现出以卷积函数为基础的非线性表达能力, 利用该非线性表达能力, 并依据指挥员的主观知识和经验, 通过拟合过程建立一个从战场视图图像矩阵到指挥员认知结果的非线性映射, 以获得最终的处理结果, 同时, 利用战场包围、非包围态势图像对称特性, 设计样本不足条件下的样本数据构造方法, 以获得满足 CNN 训练所需的足够的样本量, 保证 CNN 的有效运行, 从而达到对指挥员面对战场视图进行态势认知的探索性建模的目的。由此, 本文认知方法流程如 3 所示。

图 3 中所示本文设计的战场包围、非包围态势图像矩阵样本构造方法包括以下两种。

方法(1): 基于对称特性(1)、(2)构造成 4 倍的样本数据

对于战场视图图像矩阵 $S_{A \times B}$, 对其进行转置运算得到 $S_{A \times B}^T$, 再对 $S_{A \times B}^T$ 进行上下颠倒处理得到 $\Phi_{ud}(S_{B \times A}^T)$, 再对 $\Phi_{ud}(S_{B \times A}^T)$ 进行左右颠倒处理得到 $\Phi_{lr}(\Phi_{ud}(S_{B \times A}^T))$, 由此构造出样本集为 $\{S_{A \times B}, S_{B \times A}^T, \Phi_{ud}(S_{B \times A}^T), \Phi_{lr}(\Phi_{ud}(S_{B \times A}^T))\}$, 其样本数量是原始样本集 $\{S_{A \times B}\}$ 的 4 倍。

方法(2): 基于对称特性(3)构造成 4 倍的样本数据

对于战场视图图像矩阵 $S_{A \times B}$, 分别对其进行 1、2、3 次(非累加)的逆时针旋转 90° 运算可得到 $\Psi_{90}^{*1}(S_{A \times B}), \Psi_{90}^{*2}(S_{A \times B}), \Psi_{90}^{*3}(S_{A \times B})$, 由此方法, 所构造出的样本集为 $\{S_{A \times B}, \Psi_{90}^{*1}(S_{A \times B}), \Psi_{90}^{*2}(S_{A \times B}), \Psi_{90}^{*3}(S_{A \times B})\}$, 样本数量是原始样本集 $\{S_{A \times B}\}$ 的 4 倍。

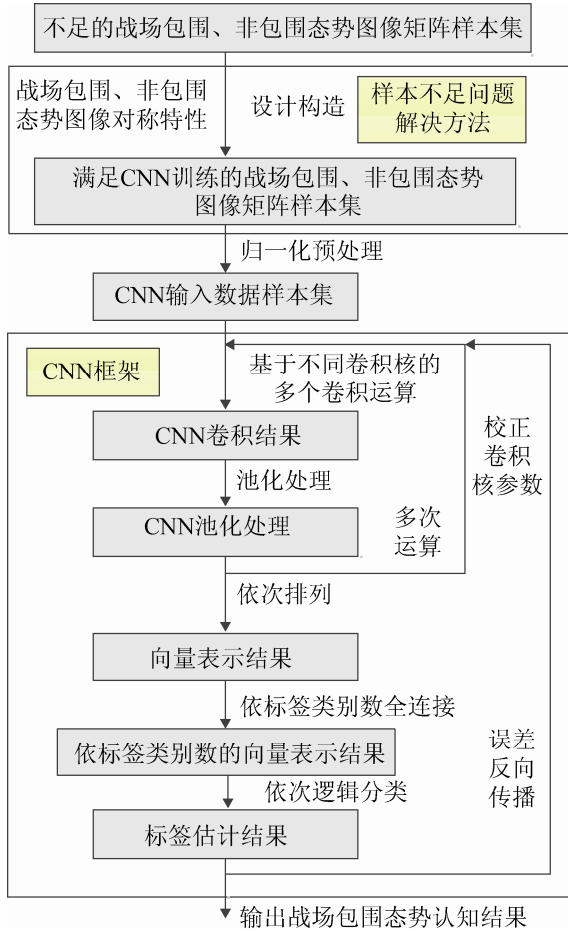


图 3 基于 CNN 的样本不足条件下
战场包围态势认知方法流程图
Fig.3 Flow chart of cognition method
for battlefields encompassing situation
based on CNN without enough samples

图中的归一化预处理是为了适合 CNN 训练需要统一单位量纲,具体如下。对战场视图图像矩阵 $S_{A \times B}$ 的所有元素 $x_i, i=1,2,\dots,A \times B$, 进行归一化, 处理过程如下公式

$$\tilde{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

其中,

$$x_{\min} = \min \{x_1, x_2, \dots, x_{A \times B}\} \quad (17)$$

$$x_{\max} = \max \{x_1, x_2, \dots, x_{A \times B}\} \quad (18)$$

\tilde{x}_i 为对 x_i 的归一化结果。可以看出, 利用归一化方法可将不同的数据映射到 [0,1] 空间, 以统一不同数据的单位量纲, 从而构建出适合 CNN 训练的输入样本集。

对图像矩阵 $S_{A \times B}$ 进行矩阵卷积运算, 即

$$S'_{A' \times B'} = S_{A \times B} \otimes F_{core} = \begin{bmatrix} s'_{11} & \cdots & s'_{1B'} \\ \vdots & \ddots & \vdots \\ s'_{A'1} & \cdots & s'_{A'B'} \end{bmatrix} \quad (19)$$

其中, F_{core} 为卷积核函数, 通常为 $L(L < \min \{A, B\})$ 阶矩阵, $A'=A-L+1, B'=B-L+1, F_{core}$ 即

$$F_{core} = \begin{bmatrix} f_{11} & \cdots & f_{1L} \\ \vdots & \ddots & \vdots \\ f_{L1} & \cdots & f_{LL} \end{bmatrix} \quad (20)$$

其中, $f_{11}, f_{1L}, \dots, f_{L1}, f_{LL}$ 这些元素均为 CNN 训练中的权重(即非线性拟合中的待定系数), 权重的个数还与卷积核的个数以及卷积运算的次数有关。

对卷积结果 $S'_{A' \times B'}$ 进行池化运算, 即

$$S''_{A'' \times B''} = \begin{bmatrix} s''_{11} & \cdots & s''_{1B''} \\ \vdots & \ddots & \vdots \\ s''_{A''1} & \cdots & s''_{A''B''} \end{bmatrix} \quad (21)$$

其中, $A''=A/2, B''=B/2,$

$$s''_{ij} = \frac{1}{4} (s'_{2i-1, 2j-1} + s'_{2i, 2j-1} + s'_{2i-1, 2j} + s'_{2i, 2j}), \quad i=1, 2, \dots, A'', j=1, 2, \dots, A'' \quad (22)$$

值得注意的是: 卷积核的个数以及卷积、池化运算的次数与战场包围态势认知的复杂度密切相关。

标签可由人为判断并直接给出, 即,

$$\{\text{敌方对我方形成包围态势、我方对敌方形成包围态势、双方未形成包围态势}\} = \{100, 010, 001\} \quad (23)$$

基于逻辑分类的输出层分类器由 sigmoid 函数组(即 3 个 sigmoid 函数)构成, 每个 sigmoid 函数表达式均为

$$P(x) = \frac{1}{1 + e^{-x}} \quad (24)$$

其中, 指标中每个元素信息在集合 {0,1} 中取值, $x \in (-\infty, +\infty), P(x) \in (0,1),$ 且当 $x=0$ 时, $P(x)=0.5。$ 将 0.5 作为分界值, 当 $P(x) \geq 0.5$ 时, 标签值为 1; 当 $P(x) < 0.5$ 时, 标签值为 0。

4 仿真实验

为验证本文方法有效性, 下面展开仿真实验。首先分别给出敌方对我方、我方对敌方形成包围态势以及双方未形成包围态势的图像样本例子, 如图

4 所示。据分析可知, 图 4(a), (b), (c)分别对应的标签为 100, 010, 001。

由此所例, 在样本数据不足条件下, 构造出包括这 3 种不同分类的带标签的训练和测试样本分别为 1.5 万个和 1 万个。利用本文解决样本不足问

题所设计的方法(1)、(2)分别构造样本数据, 可构造出训练样本 6 万个, 再结合已有的 1 万个测试样本共同组成样本数据集, 构造结果示例分别如图 5 和 6 所示。




图 4 战场包围、非包围态势相关例子图像

Fig. 4 Relevant example images of battles encompassing and non-encompassing situation




图 5 本文样本不足解决方法(1)处理结果示例

Fig. 5 Example processing results by using first solve method without enough samples

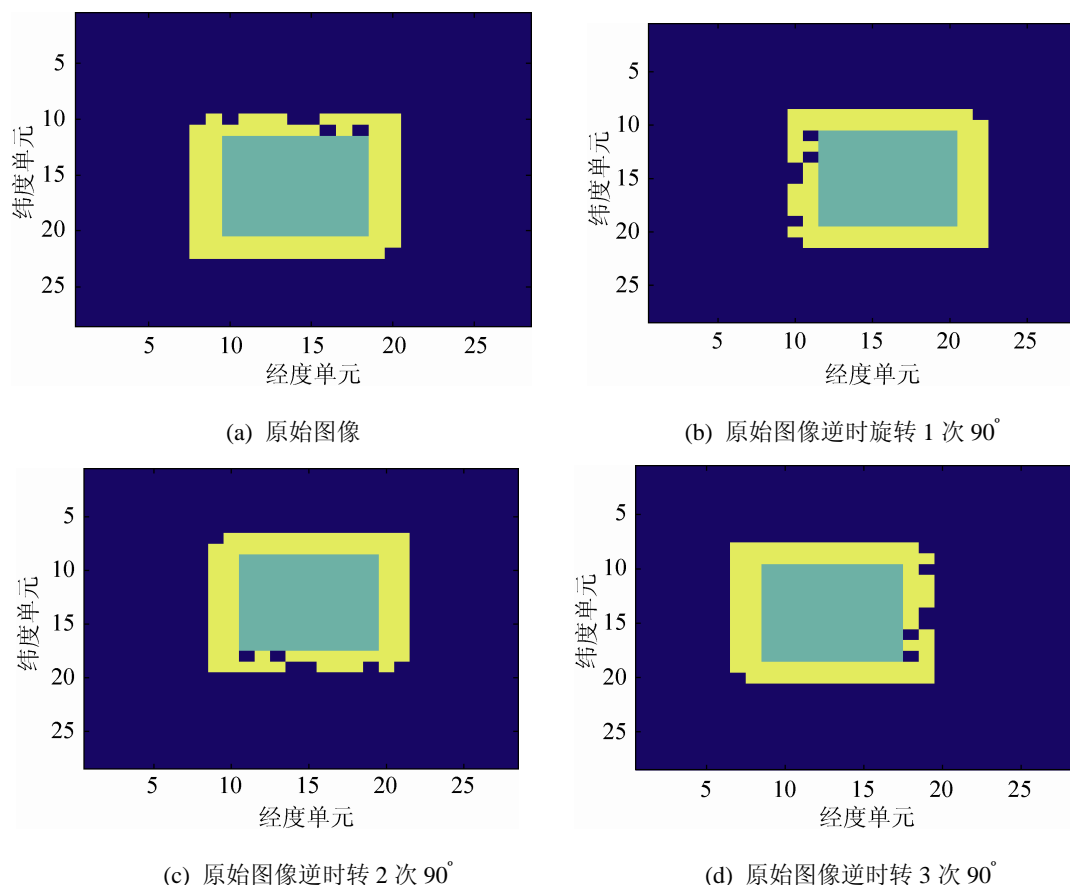


图 6 本文样本不足解决方法(2)处理结果示例

Fig. 6 Example processing results by using second solve method without enough samples

利用本文方法,首先对抽象成的图像矩阵做归一化处理,即得到预处理后的样本数据集,并匹配上相应的标签。再利用 CNN 进行训练和测试,每次迭代中的卷积和池化运算均为 2 组,第 1、2 组中卷积运算的卷积核分别为 6、12 个,误差反向传播算法用梯度下降法。

图 7(a)、(b)分别给出了样本不足条件下利用本文方法(1)、(2)以及非样本不足条件下(即拥有 6 万个有效的训练样本)基于 CNN 的包围态势认知方法获得训练终止误差、正确认知率随迭代次数的变化曲线比较结果。从图中可以看出,随着迭代次数的不断增加,3 种方法得到的训练终止误差都在不断降低、正确认知率都在不断提高,当训练从 1 代进行到 10 代时,正确认知率基本可以从 85% 以上增加到 100%,基本都在接近 100% 的数量级。这些结果说明,与非样本不足条件下获得的包围态

势认知结果相比,本文方法可在样本不足条件下获得相当的认知结果,因此,证明了本文方法的有效性。图 8(a)、(b)分别给出了训练迭代次数为 1 时,不同信噪比条件下利用 3 种方法获得的训练终止误差、正确认知率变化曲线比较结果。从图中可以看出,随着噪声的增加,3 种方法获得训练终止误差和正确认知率都有一定的波动,主要原因是噪声的随机性所造成的,进一步可通过开展大量的 Monte Carlo 仿真实验来减少随机性的影响,从而更好地判断不同信噪比条件下噪声对包围态势认知结果的影响情况。但从图中也可以看出,在不同程度的噪声影响条件下,3 种方法获得的包围态势正确认知率均保证了 70% 左右,且大多数结果均达到或非常接近 100%。因此,可以说通过仿真实验得到的实验结果表明了本文方法具有一定的鲁棒性。

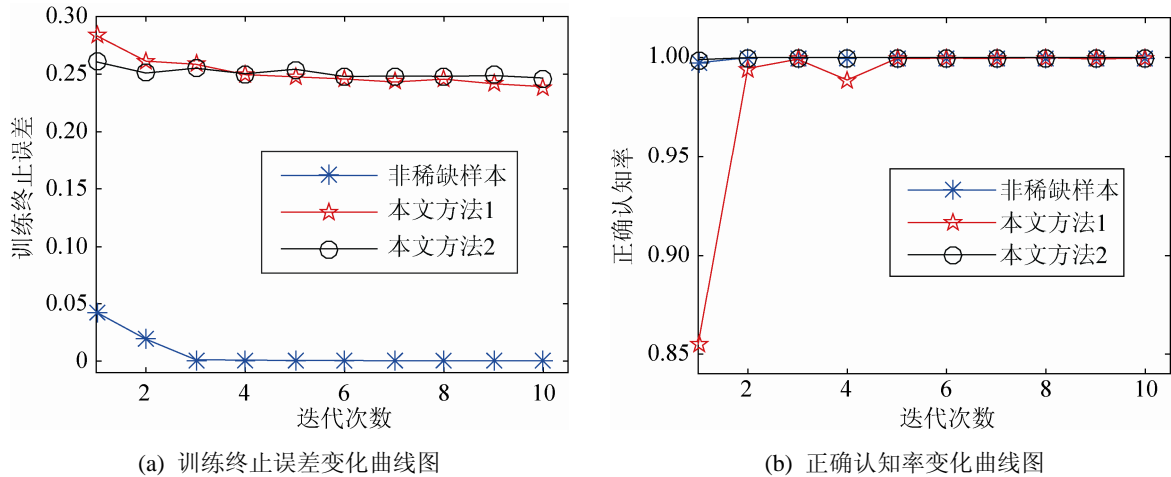


图 7 实验结果随迭代次数的变化曲线图

Fig. 7 Changing curve of simulation results corresponding to iterative times

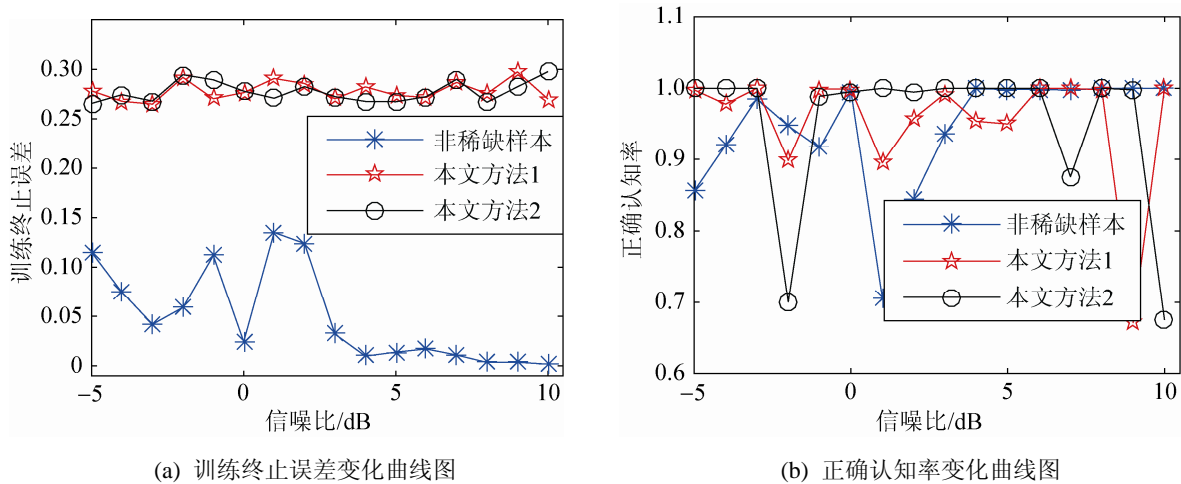


图 8 训练迭代次数为 1 时不同信噪比条件下的实验结果

Fig. 8 Simulation results under different SNRs at training iterative time as 1

5 结论

本文着眼于当今信息化时代大数据条件下的军事需求, 对于战争中常见的战场包围态势认知 (通常是基于指挥员的主观知识和经验) 问题进行了剖析和研究, 在分析了战场包围态势图像特点, 特别是其对称特性, 以及 CNN 运行原理的基础上, 提出了一种基于 CNN 的样本不足条件下战场包围态势认知新方法, 该方法利用了 CNN 的非线性拟合功能, 来探索性地研究对指挥员战场包围态势认知经验的建模问题, 同时, 基于战场包围态势图像的对称特性, 研究并设计了两种样本构造方法, 以获得 CNN 训练所需的足够的样本数据。通过这些

处理, 本文方法可在一定程度上获得指挥员对包围态势的认知经验, 达到了一定的经验捕捉效果。仿真实验结果表明利用本文方法可在包围态势图像样本数据量为常规样本数据量的 1/4 的条件下即可获得很好的认知正确率, 同时具有一定的鲁棒性, 因而证明了本文方法的有效性。

本文工作可为研究如何面对复杂的战场视图, 对指挥员的认知经验进行建模, 并在样本数据不足的条件, 以期有效捕捉到指挥员的认知经验这个重要问题提供探索性的新思路, 也为开展战场态势智能认知、辅助决策分析等研究工作奠定基础, 同时, 更深入的研究工作仍在不断开展。

参考文献:

- [1] 胡晓峰, 贺筱媛, 徐旭林. 大数据时代对建模仿真的挑战与思考-中国科协第 81 期新观点新学说学术沙龙综述 [J]. 中国科学: 信息科学, 2014, 44(5): 676-692. (Hu Xiaofeng, He Xiaoyuan, Xu Xulin. Simulation in the Big Data Era Review of New Ideas and New Theories in the 81st Academic Salon of China Association for Science and Technology [J]. Science China: Information Science, 2014, 44(5): 676-692.)
- [2] Zhu Feng, Hu Xiaofeng, Wu Lin, et al. Inspiration for Battlefield Situation Cognition from AI Military Programs Launched by DARPA of USA and Development of AI Technology [C]// 2016 International Simulation Multi-Conference (S1865-0929), Beijing, China, Springer Nature, 2016: 566-577.
- [3] Alan N Steinberg, Christopher L Bowman, Franklin E White. Revisions to the JDL Data Fusion Model [C]// The Joint NATO/IRIS Conference, Quebec, Canada, October, 1998.
- [4] Marvin S Cohen, Leonard Adelman, Martin A Tolcott, et al. A Cognitive Framework for Battlefield Commanders' Situation Assessment [R]. Arlington, VA, USA: Cognitive Technologies, Inc, 1993.
- [5] Octavio Juarez-Espinosa, Cleotilde Gonzalez. Situation Awareness of Commanders: A Cognitive Model [C]// 2004 Conference on Proceedings of Behavior Representation in Modeling and Simulation.
- [6] 郭丽丽, 丁世飞. 深度学习研究进展 [J]. 计算机科学, 2015, 42(5): 28-33. (Guo Lili, Ding Shifei. Research Progress on Deep Learning [J]. Computer Science, 2015, 42(5): 28-33.)
- [7] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [8] 李卫. 深度学习在图像识别中的研究及应用 [D]. 武汉: 武汉理工大学, 2014. (Li Wei. Research and Application of Deep Learning in Image Recognition [D]. Wuhan, China: Wuhan University of Technology, 2014.)
- [9] 杨斌, 钟金英. 卷积神经网络的研究进展综述 [J]. 南华大学学报(自然科学版), 2016, 30(3): 66-72. (Yang Bin, Zhong Jinying. Review of Convolution Neural Network [J]. Journal of University of South China (Science and Technology), 2016, 30(3): 66-72.)
- [10] 惠国保. 基于深度学习的自动目标识别技术 [C]// 第四届指挥控制大会报告, 北京. 中国指挥与控制学会, 电子工业出版社, 2016: 319-324. (Hui Guobao. Auto Target Recognition Technology Based on Deep Learn [C]// 4th China Command and Control Conference, Beijing, China, Chinese Institute of Command and Control, Publishing House of Electronics Industry, 2016: 319-324.)
- [11] 高惠琳. 基于卷积神经网络的军事图像分类 [J]. 计算机应用研究, 2017, 34(10): 优先出版. (Gao Huilin. Military Image Classification Based on Convolutional Neural Network [J]. Application Research of Computers, 2017, 34(10): First Published.)
- [12] Elpiniki I Papageorgiou, Jose L Salmeron. A Review of Fuzzy Cognitive Maps Research during the Last Decade [J]. IEEE Transactions on Fuzzy Systems (S1063-6706), 2013, 21(1): 66-79.
- [13] 张玉叶, 周胜明, 赵育良, 等. 高速运动目标的运动模糊图像复原研究 [J]. 红外与激光工程, 2017, 46(4): 0128001. (Zhang Yuye, Zhou Shengming, Zhao Yuliang, et al. Motion-Blurred Image Deblurring of Fast Moving Target [J]. Infrared and Laser Engineering, 2017, 46(4): 0128001.)
- [14] 王坤峰, 苟超, 段艳杰, 等. 生成式对抗网络 GAN 的研究进展与展望 [J]. 自动化学报, 2017, 43(3): 321-332. (Wang Kunfeng, Gou Chao, Duan Yanjie, et al. Generative Adversarial Networks: The State of the Art and Beyond [J]. Acta Automatica Sinica, 2017, 43(3): 321-332.)
- [15] 计算机视觉战队. 深度压缩网络较大幅度减少了网络参数存储问题 [R]. 微信文章. (2017-07-09) [2017-07-15]. (Computer Vision Team. Issue of Saved Network Parameters are Reduced by Deep Compress Network at a Large Extent [R]. Weixin Paper. (2017-07-09) [2017-07-15].)
- [16] Brenden M Lake, Ruslan Salakhutdinov, Joshua B Tenenbaum. Human-Level Concept Learning through Probabilistic Program Induction [J]. Science (S0036-8075), 2015, 350(6266): 1332-1338.