

1-2-2019

## A Model for Battlefield Situation Change Rate Prediction Based on Deep Learning

Jiuyang Tao

*1. Joint Operations College, National Defense University, Beijing 100091, China; ;2. Army Engineering University of PLA, Nanjing 210007, China;*

Wu Lin

*1. Joint Operations College, National Defense University, Beijing 100091, China; ;*

Wang Chi

*1. Joint Operations College, National Defense University, Beijing 100091, China; ;*

Junda Chu

*1. Joint Operations College, 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 Model for Battlefield Situation Change Rate Prediction Based on Deep Learning

## Abstract

**Abstract:** To measure and estimate the uncertainty of the battlefield situation is of great significance for the commanders to plan the reconnaissance mission and reduce the risk of decision-making. Based on Shannon's information theory, firstly, *methods and a model on measurement of situation change rate are proposed*. Secondly, a scene with two-dimensional grid elements maneuvering is established, based on deep learning, *the prediction method for maneuvering trend is explored*. It is proved that *cross entropy is equivalent to situation change rate*. Finally, with the increase of the objective uncertainty, situation change rate and the accuracy of the forecast is analyzed. *It is deduced that there is an upper limit on the prediction accuracy based on the learning model, and the upper limit is inversely proportional to the situation change rate*.

## Keywords

information theory, situation awareness, deep learning, shannon entropy

## Authors

Jiuyang Tao, Wu Lin, Wang Chi, Junda Chu, Liao Ying, and Zhu Feng

## Recommended Citation

Tao Jiuyang, Wu Lin, Wang Chi, Chu Junda, Liao Ying, Zhu Feng. A Model for Battlefield Situation Change Rate Prediction Based on Deep Learning[J]. Journal of System Simulation, 2018, 30(3): 785-792.

# 基于深度学习的战场态势变化速度预测模型

陶九阳<sup>1,2</sup>, 吴琳<sup>1</sup>, 王驰<sup>1</sup>, 褚君达<sup>1</sup>, 廖鹰<sup>1</sup>, 朱丰<sup>1</sup>

(1.国防大学联合作战学院, 北京 100091; 2.陆军工程大学, 江苏 南京 210007)

**摘要:** 战场态势变化剧烈程度的度量 and 估计, 对指挥员均衡认知负载, 降低决策风险具有重要意义。首先, 基于态势要素状态变化过程中产生的自信息量, 建立了态势变化速度计算模型; 随后, 以二维网格中态势要素机动为基本案例, 探索了基于深度学习的态势要素趋势预测方法, 证明了深度学习模型的损失函数交叉熵等价于态势变化速度; 最后, 通过实验分析了随着态势要素客观不确定性的增加, 态势变化速度和趋势预测准确性的变化情况, 得到推论: 学习模型对态势要素的趋势预测准确率存在上限, 上限值与态势变化速度成反比。

**关键词:** 不确定性; 信息论; 态势认知; 深度学习; 香农熵

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2018) 03-0785-08

DOI: 10.16182/j.issn1004731x.joss.201803003

## A Model for Battlefield Situation Change Rate Prediction Based on Deep Learning

Tao Jiuyang<sup>1,2</sup>, Wu Lin<sup>1</sup>, Wang Chi<sup>1</sup>, Chu Junda<sup>1</sup>, Liao Ying<sup>1</sup>, Zhu Feng<sup>1</sup>

(1. Joint Operations College, National Defense University, Beijing 100091, China; 2. Army Engineering University of PLA, Nanjing 210007, China)

**Abstract:** To measure and estimate the uncertainty of the battlefield situation is of great significance for the commanders to plan the reconnaissance mission and reduce the risk of decision-making. Based on Shannon's information theory, firstly, *methods and a model on measurement of situation change rate are proposed*. Secondly, a scene with two-dimensional grid elements maneuvering is established, based on deep learning, *the prediction method for maneuvering trend is explored*. It is proved that cross entropy is equivalent to situation change rate. Finally, with the increase of the objective uncertainty, situation change rate and the accuracy of the forecast is analyzed. *It is deduced that there is an upper limit on the prediction accuracy based on the learning model, and the upper limit is inversely proportional to the situation change rate*.

**Keywords:** information theory; situation awareness; deep learning; shannon entropy

## 引言

随着网络武器、高超音速武器以及智能无人系统等武器平台持续进入战争空间, 战场态势在剧烈的动态变化中越来越难以把握。如何估计和预测战场态势变化的剧烈程度, 以及如何提高认知速度来

适应战场态势的高速动态变化, 成为一个亟需研究的问题。

战场态势是一个典型的复杂系统, 而不确定性是其基本特征之一。由于交战双方信息不对称, 态势要素之间存在大量的非线性相互作用, 使得战场态势不确定性骤增。愈发浓重的“战争迷雾”, 使指挥员在决策时面临巨大风险。如何提高指挥员的态势认知能力, 成为人因工程研究的核心主题。前美国空军首席科学家 Endsley 在研究如何提高高空战飞行员的认知能力的过程中, 建立了比较完善的态



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(61403400, 61403401, 61773399, 61703412), 军民共用重大研究计划联合基金(U1435218);  
作者简介: 陶九阳(1983-), 男, 山东五莲, 博士生, 研究方向为运筹分析与军事智能决策。

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

势认知(Situation Awareness)理论<sup>[1-3]</sup>, 该理论将态势认知分为线索察觉、理解和预测三个层次, 分析了在复杂动态变化的信息环境中, 如何度量和提升认知能力<sup>[4]</sup>; 在此基础上, 研究人员陆续开展了大量态势认知度量和实验, 重点研究了态势认知能力训练<sup>[5-6]</sup>, C4ISR 系统的态势认知设计与优化<sup>[7-9]</sup>, 以及系统的自动化水平提升等问题<sup>[10-11]</sup>。上述研究工作大多针对认知主体的认知质量进行测量和改进, 如给出一个场景, 让认知主体对场景进行分析理解和预测, 然后对认知结果进行分析和评估。然而, 随着战争节奏的加快, “敏捷性”成为决定战争胜负的关键因素<sup>[12]</sup>。态势认知速度如果无法跟上战争节奏, 就会导致作战主体的 OODA 循环死锁, 从而陷入被动局面<sup>[13]</sup>。虽然, Endsley 在文献[1]中提出了态势认知的“时间观点”, 认为时间是态势认知的重要构成元素, 在理解和预测层次上, 态势环境变化的速度会影响态势认知能力, 但她并没有给出如何度量态势环境的变化速度, 也没有给出态势变化速度与态势认知能力之间的量化关系。对态势认知速度进行度量, 并寻求提升认知速度的方法, 具有重要的现实意义<sup>[14]</sup>。

面对高度动态变化的环境, 猎人具备让态势“变慢”的能力。一个魔术师能够轻易骗过大众的眼睛却往往无法骗过猎人, 猎人这种能力是通过反复学习训练得到的。可见, 同样一个态势, 不同的认知主体对态势变化的剧烈程度会有不同的感受。因此, 态势变化的剧烈程度具有主观性, 主观上降低态势变化速度, 本质上是提升了态势认知速度。本文从战场态势的不确定性入手, 建立主观态势变化速度计算模型, 并探索了通过建立深度学习模型来让态势变化速度“慢下来”的方法, 一方面为指挥员或指挥信息系统应对复杂动态战场环境的能力提供评估指标, 另一方面, 也为目前正在兴起的智能态势认知与决策<sup>[15-18]</sup>提供理论基础和技术方法。

## 1 战场态势变化速度计算模型

认知主体处于一个复杂的动态环境中, 会对环

境的变化程度有一个主观感受。根据人因工程认知负载理论<sup>[19-20]</sup>, 态势环境变化越剧烈, 带来的不确定性就越高, 认知主体的认知负载也越高, 越需要快速调整自身状态来适应态势环境的变化。因此, 如何度量这种变化的剧烈程度成为一个需要研究的问题。

根据经验, 天空中飞行的飞机态势要比公路上行驶的汽车态势变化快, 汽车的态势变化要比行人的态势变化快。如此看来, 描述态势变化的剧烈程度, 就可以用状态的转换速度来进行描述。实际上这种描述方法并不合理。认知主体事先能够预料的, 即使变化剧烈, 往往也能应对。例如, 天上的客机, 即使飞行速度很快, 但是其航线是确定的, 能够精确预测其下一时刻所处的位置。行人虽然速度很慢, 如果突然冲进车行道, 这时候司机会感觉态势变化很剧烈。由此可见, 主观感受上, 态势变化的快慢, 一方面与态势要素状态转换的速度有关, 另一方面与态势要素状态转换过程中带来的不确定性大小有关。因此, 态势环境的这种动态不确定性反应的就是态势变化的剧烈程度。

在一定的时间内, 发生的事件概率越小, 认知主体感觉到态势的不确定度越大。就像前面突然闯入行车道的行人, 对于司机来说, 这种情况很少发生, 是小概率事件, 所以司机感觉到态势变化很快, 其可反应时间也相应很短。如果一个动态环境不断有这种小概率事件发生, 认知主体必然会感觉这个动态环境难以应付。战场上如果频繁出现一些预料之外的事, 指挥员就需要反复推测到底发生了什么, 可能会继续发生什么。从而需要不断动态调整已有的作战部署和作战方案, 被对手牵着鼻子走, 这很可能会丧失战争的主动权, 陷入极为被动的局面。

假设战场中态势要素组成的集合用  $\Omega$  表示,  $\Omega = \{\omega_1, \omega_2, \dots, \omega_i, \dots, \omega_n\}$  称为态势空间。  $\Omega$  中的元素称为态势要素。态势要素  $\omega_i$  在时刻  $t_j$  的状态用  $S_j^i$  表示。在一个时间段内, 假设指挥员可以连续观察态势要素  $\omega_i$  的状态变化情况, 如图 1 所示。




图 1 状态转移过程中  $\omega_i$  动态不确定性变化情况  
Fig. 1 Dynamic uncertainty of  $\omega_i$  in the process of state transfer

在某个时刻到达之前, 指挥员通过侦察信息可以对态势要素  $\omega_i$  的趋势进行预测, 其预测值表示在当前状态下, 下一时刻态势要素  $\omega_i$  将会到达的各个状态的概率。如图 1, 在  $t_0$  时刻,  $\omega_i$  处于状态  $S_0^i$ , 指挥员会预测在  $t_1$  时刻  $\omega_i$  处于各状态的概率, 例如预测到处于  $S_1^i$  的概率为  $p_{01}^i$ 。当时间点到达  $t_1$ , 指挥员可以观察到  $\omega_i$  所处的状态, 假设态势要素  $\omega_i$  到达状态  $S_1^i$ , 则在这个状态转移的过程中,  $p_{01}^i$  越大表示预测的和实际发生的越相似。当  $p_{01}^i=1$  时表示预测完全准确。反之, 如果  $p_{01}^i$  越小, 表示指挥员主观预测的小概率事件发生了, 在这个动态的预测——观察过程中, 指挥员主观感受到的态势不确定性就越大, 越出乎指挥员的意料。

描述随机变量状态转换过程中的不确定性, 可以用香农的信息论来描述<sup>[21]</sup>。态势要素  $\omega_i$  从  $t_0$  到  $t_1$  状态转换过程中带来的不确定性可以用自信息量  $-\log p_{01}^i$  来表示。在  $t_0$  到  $t_T$  时间段, 将态势要素  $\omega_i$  状态转换过程中产生的自信息量用曲线连接起来, 就得到了图 1 中所示的“态势不确定性 H 动态变化曲线”, 该曲线描述了态势要素  $\omega_i$  从  $t_0$  到  $t_T$  时间段态势的不确定性变化情况。

在  $t_0$  到  $t_T$  时间段上总的自信息量可以用自信息量的和来表示, 如公式(1)。

$$I_{t_0 \rightarrow T}(p^i, T) = -\sum_{j=1}^T \log(p_{j-1,j}^i) \quad (1)$$

公式(1)中  $I_{t_0 \rightarrow T}$  越大, 表示在这个时间段内指

挥员主观感受的不确定性越大, 相对于指挥员来说态势变化越剧烈。然而,  $I_{t_0 \rightarrow T}$  为严格不减函数, 随着时间的增加,  $I_{t_0 \rightarrow T}$  只反映了态势不确定性的累积。而实际战场, 指挥员主观感受到的态势不确定性程度有增有减。这主要是因为观测时间长度不同带来的度量失真。因此, 为了消除时间的影响, 本文采用态势变化速度来反映单位时间内态势变化的剧烈程度。

**定义 1** 态势变化速度: 单位时间内认知主体主观感受的态势不确定性程度。

通过定义 1 和公式(1)可以定义态势变化速度计算公式, 如公式(2)所示。

$$v(p^i, T) = I_{t_0 \rightarrow T}(p^i) / (t_T - t_0) = -\sum_{j=1}^T \log(p_{j-1,j}^i) / (t_T - t_0), p_{j-1,j}^i \neq 0 \quad (2)$$

公式(2)定义了态势要素  $\omega_i$  相对于指挥员而言单位时间内平均动态不确定性。其单位可以是 bit/s 或 bit/次。需要强调的是: 公式(2)定义的态势变化速度具有主观性和相对性。对于不同的指挥员, 面对同样的战场环境, 态势变化速度可能不同。就像猎人眼中周围的世界“很慢”, 在相同的战场环境下, 指挥员主观感受的态势变化速度越慢, 说明其对态势的认知能力越强。

实际上, 态势要素给认知主体带来的不确定性可能具有瞬时性, 即突然发生, 作用很快结束。这种情况可以将公式(2)中的时间间隔  $t_T - t_0$  变为每次作用的时间总和  $\sum_j \Delta t_j$ 。此时, 可以得到态势变化速度公式为:

$$v(p^i, T) = I_{t_0 \rightarrow T}(p^i) / \sum_{j=1}^T \Delta t_j = -\sum_{j=1}^T \log(p_{j-1,j}^i) / \sum_{j=1}^T \Delta t_j, p_{j-1,j}^i \neq 0 \quad (3)$$

同理, 态势要素给认知主体带来的不确定性也可能具有后效性, 即发生后其不确定性一直对认知主体产生作用。这种情况可以对每次不确定性进行折扣后累加。此时, 态势变化速度公式变为:

$$v(p^i, T) = \frac{I_{t_0 \rightarrow t_T}(p^i)}{t_T - t_0} = \frac{-\sum_{t=1}^T (\gamma^{t-1} \cdot \sum_{j=t}^T \log(p_{j-1,j}^i))}{t_T - t_0}, \quad p_{j-1,j}^i \neq 0 \quad (4)$$

公式(4)中 $\gamma$ 为折扣系数。该值越大,表示不确定性的后效性越强。当 $\gamma=0$ 时表示完全没有后效性,则公式(4)退化为公式(2)。

上述公式中限定了 $p_{j-1,j}^i \neq 0$ ,即所有的状态转移情况都是已知的。如果 $p_{j-1,j}^i = 0$ ,则表示状态 $S_j$ 事先是未知的状态,是一种“黑天鹅”现象。由于概率为0的事件的自信息量无穷大,因此其不确定性也为无穷大,实际使用中可以将 $\log(p_{j-1,j}^i)$ 设定一个非常大的正数来表示“黑天鹅”带来的巨大不确定性。

如果态势要素 $\omega_i$ 的状态变量为连续型随机变量,则其态势变化速度可以用公式(5)表示。

$$v(p^i, t) = \frac{d(I_t(p^i))}{dt} = \frac{-\int \log(p(t))}{t} dt \quad (5)$$

公式(5)计算的是实时态势变化速度。

## 2 面向马尔科夫链的态势变化速度计算案例分析

在现实战场态势空间中,大多数态势要素都具有马尔科夫性。为了演示上述方法的计算过程,不妨假设态势要素 $\omega_i$ 具有马尔科夫性。即态势要素 $\omega_i$ 下一个时刻的状态只依赖于当前时刻所处的状态,而与过去历史曾处的状态无关。指挥员主观预测的态势要素 $\omega_i$ 的状态转移为一个马尔科夫链,如图2所示。假设态势要素 $\omega_i$ 初始位于状态1。




图2 态势要素状态转移  
Fig. 2 Situation elements state transfer

**情况1:**假设实际观察到的态势要素的状态转移顺序依次是①②③④⑤,与之对应的转移概率向量为: $\vec{p}_1 = (p_{12}, p_{23}, p_{34}, p_{45}) = (0.8, 0.6, 0.8, 0.8)$ ,将向量 $\vec{p}_1$ 表达式带入公式(2),得到情况1的态势平均变化速度为:

$$v(p^i, T) = -\sum_{j=2}^5 \log(p_{j-1,j}^i) / 4 = \frac{-\log 0.8 + \log 0.6 + \log 0.8 + \log 0.8}{4} = 1.7 \text{ bit/次} \quad (6)$$

**情况2:**假设实际态势要素的状态发生顺序依次是①③②②⑤,与之对应的转移概率向量为: $\vec{p}_2 = (p_{13}, p_{32}, p_{22}, p_{25}) = (0.1, 0.1, 0.1, 0.2)$ 。将向量 $\vec{p}_2$ 的表达式带入到公式(2),得到此时的态势平均变化速度为:

$$v(p^i, T) = -\sum_{j=2}^5 \log(p_{j-1,j}^i) / 4 = \frac{-\log 0.1 + \log 0.1 + \log 0.1 + \log 0.2}{4} = 12.3 \text{ bit/次} \quad (7)$$

上述公式提供了一种定量计算态势变化速度的方法,该公式将态势变化速度的量纲统一到了bit/次或bit/s,虽然与信息的传输速率相统一,但与其物理意义不同。信息的传输速率表示的是每秒传输的信息量大小,而态势变化速度表示态势要素平均每次状态转换或每秒输出的不确定度大小。

对于指挥员而言,情况2比情况1态势变化速度要快得多。即如果观测到情况2,指挥员面临的态势环境的动态不确定性较高。从公式(7)可以看出,其不确定性较高的原因是小概率事件发生的多,即出乎指挥员意料的情况多。之所以出现情况2,是因为指挥员主观对态势要素趋势的预测与客观态势要素的实际趋势不一致。因此,增强指挥员对态势要素趋势判断的准确性,等价于降低主观态势变化速度。这就好比一个猎人通过不断的学习,在他的主观感受中态势变得越来越慢,应对周围的动态环境就会游刃有余。下一节探索一种基于深度学习的智能模型,通过像猎人一样不断学习,使其面对的态势变化速度逐渐慢下来,从而提高其预测能力。



### 3 基于 CNN 的态势变化速度预测模型

#### 3.1 问题描述

以二维网格中的态势要素机动方向预测为例, 来探索通过降低主观态势变化速度的方法。基本想定如图 3 所示, 以  $18 \times 18$  的 2 维网格来模拟战场环境, 战场环境中的态势要素为两个攻击者, 用红色和蓝色方块表示。每个攻击者可以向上、向下、向左、向右机动。每个时间步两个攻击者同时机动, 每次机动后进入一个新的相邻的空白格子, 不能进入黑色的陷阱格子, 也不能超出边界。

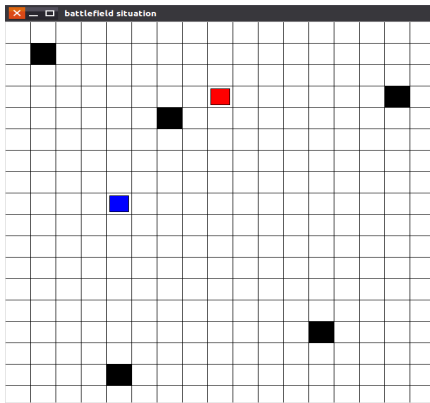


图 3 基本想定  
Fig. 3 Basic scenario

假设攻击者按照某种规则随机生成下一时刻 4 个机动方向的概率, 并按照概率随机选择一个方向来机动, 以此来模拟攻击者机动行为的不确定性。指挥员不知道攻击者下一步的机动方向, 也不知道攻击者下一时刻 4 个机动方向的概率分布情况。但指挥员能够对 2 个攻击者的历史机动情况进行观察并记录。

设蓝色和红色攻击者分别为态势要素  $\omega_1$  和  $\omega_2$ ,  $t$  时刻在网格中的坐标分别为  $(x_t^1, y_t^1)$  和  $(x_t^2, y_t^2)$ 。 $\omega_1$  在  $t$  时刻向 4 个方向机动的概率向量为  $p_t^1 = [p_t^1(\text{up}), p_t^1(\text{down}), p_t^1(\text{left}), p_t^1(\text{right})]$ ,  $\omega_2$  在  $t$  时刻向四个方向机动的概率向量为  $p_t^2 = [p_t^2(\text{up}), p_t^2(\text{down}), p_t^2(\text{left}), p_t^2(\text{right})]$ 。 $\omega_1$  和  $\omega_2$  按照如下方法生成向各个方向的机动概率  $p_t^1$  和  $p_t^2$ 。

Step 1 在  $[0,1]$  按照均匀分布为  $\omega_1$  和  $\omega_2$  生成 4

个方向的随机机动概率向量  $p_t^1(\text{random})$  和  $p_t^2(\text{random})$ , 如果向某个方向机动后会导致超出网格, 那么该方向的机动概率向量值为 0。对  $p_t^1(\text{random})$  和  $p_t^2(\text{random})$  归一化;

Step 2 按照规则计算  $\omega_1$  和  $\omega_2$  向 4 个方向移动的强度值向量  $A_t^1$  和  $A_t^2$ :

$$A_t^1(\text{up}) = y_t^1 + 0.2(y_t^1 - y_t^2) \quad (8)$$

$$A_t^1(\text{down}) = y_t^2 + 0.2(y_t^1 - y_t^2) \quad (9)$$

$$A_t^1(\text{left}) = x_t^1 + 0.2(x_t^1 - x_t^2) \quad (10)$$

$$A_t^1(\text{right}) = x_t^2 + 0.2(x_t^1 - x_t^2) \quad (11)$$

如果向某个方向机动后会导致超出网格, 那么该方向的机动强度值为 0。设  $\omega_2$  与  $\omega_1$  在机动规则上具有对称性, 公式(8)~(11)中的坐标值对称调换即可求得  $A_t^2$ 。

Step 3 计算  $\omega_1$  和  $\omega_2$  向 4 个方向机动的规则概率向量  $p_t^1(\text{rule})$  和  $p_t^2(\text{rule})$ :  $p_t^1(\text{rule}) = \text{softmax}(A_t^1)$ ,  $p_t^2(\text{rule}) = \text{softmax}(A_t^2)$ ;

Step 4 计算  $\omega_1$  和  $\omega_2$  向 4 个方向的机动概率  $p_t^1$  和  $p_t^2$ :

$$p_t^1 = \lambda p_t^1(\text{random}) + (1 - \lambda) p_t^1(\text{rule}) \quad (12)$$

$$p_t^2 = \lambda p_t^2(\text{random}) + (1 - \lambda) p_t^2(\text{rule}) \quad (13)$$

公式(12)和(13)表示的是  $\omega_1$  和  $\omega_2$  的机动方向一部分是随机的, 无规律可循, 另一部分是根据战场的环境来决定的, 具有确定性特点。现实中很多行动都可能具有确定性成分和概率成分<sup>[22]</sup>。通过对两部分混合来模拟战场上的决策者在做决策时确定性和不确定性兼具的特点。其中  $\lambda$  越大表示随机性越强。

#### 3.2 深度卷积神经网络模型

为了对上述问题中态势要素  $\omega_1$  和  $\omega_2$  的机动方向进行预测, 本文构建一个深度学习模型来学习其机动规律。

首先设计样本的数据格式。将二维网格抽象为一个  $8 \times 8$  像素的图像, 空白格子的像素值用 0 表示,  $\omega_1$  和  $\omega_2$  所在的格子的像素值分别用 1 和 2 表示, 其标签设计为一个  $1 \times 8$  的向量, 前面 4 位表示  $\omega_1$





对比公式(15)与公式(2), 以及在案例分析中的公式(6)和公式(7)可以发现, 这两个公式具有等价性。更为深入的分析可以发现, 对于 3.1 提出的趋势预测问题, 训练 CNN 的每一个样本, 相当于图 1 中所示的态势要素的一次状态转移, 那么  $J$  个样本就相当于进行了  $J$  次状态转移, 平均每次转换的交叉熵就是定义 1 和公式(2)定义的平均态势变化速度, 而且两者量纲统一的。由于 CNN 的训练过程就是不断降低损失函数交叉熵的过程, 因此, CNN 学习预测态势要素  $\omega_1$  机动趋势的过程, 就是不断降低态势变化速度的过程。

上述分析从理论上证明: 预测学习模型的损失函数交叉熵的物理含义就是态势变化速度, 交叉熵和态势变化速度具有完美等价性。学习模型一方面能够预测趋势, 另一方面能够预测态势变化速度。损失函数不再是一个抽象的距离公式, 而是一个有现实含义的量。这个结论的重要意义一方面在于, 用现有的深度学习模型来学习和预测态势变化速度, 无需再定义新的公式可以直接用其损失函数交叉熵; 另一方面也为深度学习的损失函数带来了新的应用。目前大多数的深度学习模型关注的都是预测的准确率, 作为损失函数的交叉熵通常作为中间量被丢弃。而一旦赋予其物理意义, 就可以通过交叉熵得到当前主观感受的态势变化速度。而主观感受的态势变化速度能反应预测环境的不确定程度, 这样不仅能够训练一个模型来进行预测趋势, 还能通过训练后的交叉熵来估计环境的不确定程度。下面通过对上述 3.1 想定的学习结果来分析交叉熵所能体现出的重要物理意义。

为了分析方便, 我们只通过 CNN 学习预测攻击者  $\omega_1$  的机动趋势。根据 3.1 的机动规则和上述样本数据格式, 生成  $\omega_1$  的机动样本数据。 $\lambda$  在 [0,1] 区间上隔 0.1 取一个值, 每个  $\lambda$  值生成训练集样本数据 50 000 个, 测试集样本数据 20 000 个。用生成的样本训练卷积神经网络, 图 6 展示了不同的  $\lambda$  值下, 训练后得到的态势变化速度(损失函数交叉熵)和预测准确性。

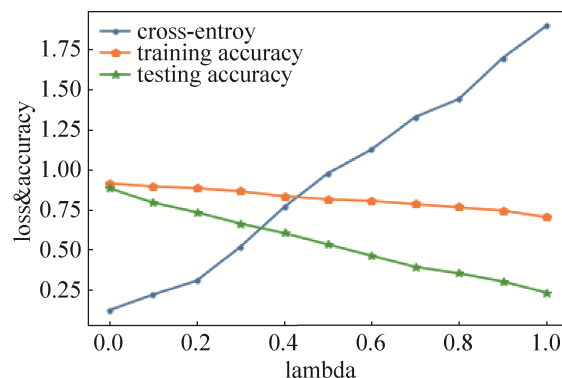


图 6 不同  $\lambda$  值下的 CNN 训练情况  
Fig. 6 CNN training under different  $\lambda$

通过图 6 可以发现, 当  $\lambda=0$  时, 公式(12)变为  $p_i^1 = p_i^1(\text{rule})$ ,  $\omega_1$  的机动方向概率分布完全依赖生成规则, 此时在训练集上的预测准确率和测试集上的准确率接近, 表明 CNN 的泛化能力很好。随着  $\lambda$  值增大, 式(18)中随机性占比越来越大, 可以看到训练集上的准确率和测试集上的准确率不断降低, 并且准确率之间差越来越大, 泛化能力越来越差。这是因为 CNN 过拟合了训练集上的数据, 训练集上的数据本身就含有随机规则, 这些随机规则被 CNN 拟合了, 即本来没有规律的被看成了有规律。

通过图 6 也可以发现, 随着  $\lambda$  增大, 交叉熵在不断增大, 虽然指挥员面对的态势环境和态势要素并没有变, 用于训练的样本数量也没有变, 但预测精度下降了, 即指挥员主观感受是预测变得困难了。前面已经说明, 交叉熵等价于态势变化速度, 因此, 交叉熵增加从侧面反应出指挥员面临的态势变化速度增加了。由此我们可以得到一个重要结论: 如果被预测的态势要素本身具有客观随机性, 对该要素趋势预测的准确性会存在一个极值。无论训练样本数量多大, 无论采用何种学习模型, 都不会突破该极值, 该极值与被预测态势要素态势变化速度成反比。因此, 包括深度学习在内的机器学习方法, 预测的准确度不仅仅与模型学习能力的强弱有关, 还与预测的对象本身的随机性有关。例如上述案例中, 如果  $\lambda=1$ , 则式(12)变为  $p_i^1 = p_i^1(\text{random})$ , 此时  $\omega_1$  的机动方向变成完全随机了, 学习模型将很难准确预测下一步其机动方向。

## 4 结论

基于香农的信息论提出了态势变化速度计算模型,以纯不连续马氏过程为例演示了态势变化速度计算方法。设计了二维网格上态势要素机动预测的案例,建立了一个深度卷积神经网络来学习预测态势要素的机动方向。最终得到2个结论:(1)预测学习模型的损失函数为交叉熵,则其物理含义是通过学习降低平均态势变化速度来增加预测的准确性,交叉熵与本文定义的态势变化速度具有完美等价性,即深度学习等机器学习模型可以在学习过程中一方面预测态势变化速度,另一方面预测态势变化趋势;(2)学习模型对态势要素趋势预测的准确性存在极值,该极值与态势要素的态势变化速度成反比,即态势变化速度越快,预测的准确性越低。

## 参考文献

- [1] Endsley M R. Measurement of Situation Awareness in Dynamic Systems[J]. *Human Factors* (S0018-7208), 1995, 37(1): 65-84.
- [2] Endsley M R. Toward a Theory of Situation Awareness in Dynamic Systems[J]. *Human Factors* (S0018-7208), 1995, 37(1): 32-64.
- [3] Endsley M R. Situation awareness misconceptions and misunderstandings[J]. *Journal of Cognitive Engineering & Decision Making* (S1555-3434), 2015, 9(1): 4-32.
- [4] Endsley B M R, Garland D J. *Situation Awareness: Analysis and Measurement*[J]. Crc Press, 2000, 6(2): 1740-1741.
- [5] Strater L, Bolstad C. *Simulation-based situation awareness training*[M]//*Human Factors in Simulation and Training*, 2008.
- [6] Muehlethaler C M, Knecht C P. Situation Awareness Training for General Aviation Pilots using Eye Tracking[J]. *Ifac Papersonline* (S2405-8963), 2016, 49(19): 66-71.
- [7] Endsley M R. *Designing for Situation Awareness: An Approach to User-Centered Design*, Second Edition[J]. *Ergonomics* (S0018-7208), 2013, 56(4): 727.
- [8] Salmon P, Stanton N, Walker G, et al. Situation awareness measurement: a review of applicability for C4I environments[J]. *Applied Ergonomics* (S0003-6870), 2006, 37(2): 225-238.
- [9] Endsley M R. *Towards a New Paradigm for Automation: Designing for Situation Awareness*[J]. *IFAC Proceedings Volumes* (S1474-6670), 1995, 28(15): 365-370.
- [10] Parasuraman, Raja, Sheridan, et al. Situation Awareness, Mental Workload, and Trust in Automation: Viable, Empirically Supported Cognitive Engineering Constructs[J]. *Journal of Cognitive Engineering & Decision Making* (S1555-3434), 2008, 2(2): 140-160.
- [11] Holsopple J, Sudit M, Nusinov M, et al. Enhancing situation awareness via automated situation assessment[J]. *IEEE Communications Magazine* (S0163-6804), 2010, 48(3): 146-152.
- [12] David S Alberts. *The Agility Advantage: A Survival Guide for Complex Enterprises and Endeavors*[M]. CCRP, 2013.
- [13] 陶九阳, 吴琳, 胡晓峰. AlphaGo 技术原理分析及人工智能军事应用展望[J]. *指挥与控制学报*, 2016(2): 114-120. Tao Jiuyang, Wu Lin, Hu Xiaofeng. Principle Analysis on AlphaGo and Perspective in Military Application of Artificial Intelligence[J]. *JOURNAL OF COMMAND AND CONTROL*, 2016(2): 114-120.
- [14] Dekker S W A, Hummerdal D H, Smith K. Situation awareness: Some remaining questions[J]. *Theoretical Issues in Ergonomics Science* (S1463-922X), 2010, 11(1/2): 131-135.
- [15] John Patrick, Philip L M. Approaches to understanding, analysing and developing situation awareness[J]. *Theoretical Issues in Ergonomics Science* (S1463-922X), 2010, 11(1): 41-57.
- [16] Sirkin D, Martelaro N, Johns M, et al. Toward Measurement of Situation Awareness in Autonomous Vehicles[C]//*CHI Conference on Human Factors in Computing Systems*. ACM, 2017: 405-415.
- [17] Loia V, D'Aniello G, Gaeta A, et al. Enforcing situation awareness with granular computing: a systematic overview and new perspectives[J]. *Granular Computing* (S2364-4966), 2016, 1(2): 127-143.
- [18] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search[J]. *Nature* (S0028-0836), 2016, 529(7587): 484-489.
- [19] Endsley M R, Kaber D B. Level of automation effects on performance, situation awareness and workload in a dynamic control task[J]. *Ergonomics* (S0018-7208), 1999, 42(3): 462-492.
- [20] Endsley M R. The effects of level of automation and adaptive automation on human performance, situation awareness and workload in a dynamic control task[J]. *Theoretical Issues in Ergonomics Science* (S1463-922X), 2004, 5(2): 113-153.
- [21] 朱雪龙. *应用信息论基础*[M]. 北京: 清华大学出版社有限公司, 2001. Zhu Xuelong. *Fundamentals of Applied Information Theory* [M]. Beijing: Tsinghua University Press, 2001.
- [22] Javier Pinto, Cristina Sernadas, Paulo Mateus. Non-determinism and uncertainty in the situation calculus[J]. *International Journal of Uncertainty, Fuzziness and Knowledge- Based Systems* (S0218-4885), 2000, 8(2): 127-149.