

Journal of System Simulation

Volume 31 | Issue 11

Article 5

12-13-2019

Knowledge Representation Method of Joint Operation Situation Based on Knowledge Graph

Baokui Wang

National Defense University of PLA, Beijing 100091, China;

Wu Lin

National Defense University of PLA, Beijing 100091, China;

Xiaofeng Hu

National Defense University of PLA, Beijing 100091, China;

Xiaoyuan He

National Defense University of PLA, Beijing 100091, China;

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.

Knowledge Representation Method of Joint Operation Situation Based on Knowledge Graph

Abstract

Abstract: Lacking of common knowledge for understanding and judging complex situation of operation by machines is one of the difficulties in intelligent situation cognition. The knowledge representation methods based on knowledge graph are reviewed. *The characteristics and difficulties of joint operation situation knowledge representation are analyzed. Moreover, the concept of scenario knowledge graph is presented, as well as the knowledge sources and basic content of scenario knowledge graph are described. This paper also points out that the joint knowledge representation method based on discrete symbols and continuous vectors in specific scenario is an effective way to express joint operation situation knowledge.*

Keywords

knowledge representation, joint operation situation, situation intelligence cognition, knowledge graph, scenario knowledge graph

Recommended Citation

Wang Baokui, Wu Lin, Hu Xiaofeng, He Xiaoyuan. Knowledge Representation Method of Joint Operation Situation Based on Knowledge Graph[J]. Journal of System Simulation, 2019, 31(11): 2228-2237.

基于知识图谱的联合作战态势知识表示方法

王保魁, 吴琳, 胡晓峰, 贺筱媛

(中国人民解放军国防大学, 北京 100091)

摘要: 机器缺乏理解和判断复杂作战态势的基本知识是态势智能认知的难点之一。概述了基于知识图谱的知识表示方法, 分析了联合作战态势知识表示的特点和难点, 提出了场景知识图谱的概念, 描述了场景知识图谱的知识来源和基本内容, 指出了面向特定作战场景的离散符号与连续向量相融合的知识联合表示方法是表示联合作战态势知识的有效途径。

关键词: 知识表示; 联合作战态势; 态势智能认知; 知识图谱; 场景知识图谱

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X(2019)11-2228-10

DOI: 10.16182/j.issn1004731x.joss.19-FZ0304

Knowledge Representation Method of Joint Operation Situation Based on Knowledge Graph

Wang Baokui, Wu Lin, Hu Xiaofeng, He Xiaoyuan

(National Defense University of PLA, Beijing 100091, China)

Abstract: Lacking of common knowledge for understanding and judging complex situation of operation by machines is one of the difficulties in intelligent situation cognition. The knowledge representation methods based on knowledge graph are reviewed. The characteristics and difficulties of joint operation situation knowledge representation are analyzed. Moreover, the concept of scenario knowledge graph is presented, as well as the knowledge sources and basic content of scenario knowledge graph are described. This paper also points out that the joint knowledge representation method based on discrete symbols and continuous vectors in specific scenario is an effective way to express joint operation situation knowledge.

Keywords: knowledge representation; joint operation situation; situation intelligence cognition; knowledge graph; scenario knowledge graph

引言

复杂作战态势是战争复杂系统的外在表现^[1]。态势智能认知是一种捕捉自底向上的形式化知识与自顶向下的非形式化知识相结合的作战态势认知方法^[2]。其核心是让机器能够达到或接近人类的认知能力, 辅助指挥员更快、更全、更准、更深地

认知战场态势, 进而实现快速高效地指挥决策和作战控制^[3]。

对复杂作战态势的认知本质上是对战争复杂系统的认知。人类指挥员可以迅速从纷繁复杂的作战态势信息中捕捉关键态势要素知识, 快速理解和掌握作战态势要素之间的交互作用关系, 而机器却难以做到, 这一点在联合作战态势智能认知上更为突出^[4]。其根本原因在于机器缺乏对复杂作战态势进行理解和判断的基本知识, 无法完成从作战数据到战场信息再到态势知识的转化。传统基于离散符号的作战态势知识表示方法善于表征作战规则、指



收稿日期: 2019-05-30 修回日期: 2019-07-11;
基金项目: “十三五”装备预研共用技术(41412030401),
国家青年科学自然基金(81500856);
作者简介: 王保魁(1982-), 男, 山东即墨, 博士生,
工程师, 研究方向为运筹分析与军事智能决策、态势
智能认知。

挥约束、决策信息等显性的形式化知识,但知识稀疏,不易融合扩展。基于连续向量的作战态势知识表示方法擅长捕捉作战态势优劣、敌方行动意图、敌情威胁大小等隐性的非形式化知识,但难以解释和迁移使用。因此,需要进一步深入探索作战态势形式化知识和非形式化知识的联合表示方法,通过建立复杂作战态势的可计算知识模型,将作战态势知识表示为计算机易于表示、学习和处理的形式,为态势智能认知提供坚实的基础知识支撑。

1 知识图谱为联合作战态势知识表示带来新手段

联合作战态势知识(Joint Operational Situation Knowledge, JOSK)是联合作战态势要素的客观实体、属性及其联系在人脑中的主观映像,是对客观联合作战态势的一种主观表征,其核心和重点是联合作战态势要素之间的复杂关联关系^[5]。认知联合作战态势的过程,就是对联合作战指挥决策过程中影响决策和行动的作战态势知识进行不断学习、理解和应用的过程。然而,不同的指挥员在不同作战场景下对态势知识的认知是不同的。首先,不同的指挥员在相同作战场景下对态势知识的理解不同^[6]。指挥员虽然都经过长期严格的训练,但由于不同的指挥员对于特定场景作战态势的知识经验不同,会对特定场景下作战态势知识的理解上存在不同的空间距离,最终导致对特定场景联合作战态势知识的认知不同。其次,相同的指挥员在不同作战场景下对态势知识的解释不同^[7]。态势知识场景化是对联合作战态势知识的具象化过程。由于不同场景下联合作战态势知识的含义和属性不同,指挥员对不同作战场景下态势知识的解释也相应不同。例如,同样是舰艇机动动作,在不同的作战场景下可以分别执行巡航、攻击或搜救等不同的任务。因此,指挥员需要结合具体的作战场景理解作战态势知识。联合作战态势知识表示(Joint Operational Situation Knowledge Representation, JOSKR)就是在特定场景范围内,针对联合作战态势知识进行建

模,使得机器可以学习、处理和运用各种联合作战态势知识。

知识图谱(Knowledge Graph, KG)是一种基于图的现实世界语义描述模型^[8-9],为联合作战态势知识表示带来了新的技术手段。图谱中的节点和边分别表示表示现实世界中的各种实体、概念或属性及其语义关联关系。知识图谱中的基本知识要素通过语义相关联,以图的形式组织在一起,最终形成了知识图谱。从军事大数据治理的角度看,知识图谱能够从实体关系的角度把各种不同类型的作战数据进行关联融合,组织成一个更加完整的军事大数据体系去使用^[10-11]。从军事语义连接的角度看,知识图谱能够将作战态势数据的知识从语义的角度连接在一起,对作战态势进行整体描述,并将其语义信息作为各种智能学习模型的输入,提升智能模型的学习能力^[12]。从军事智能应用的角度看,构建知识图谱有利于深入挖掘实体间的复杂关联关系,建立任务、行动、事件、案例等不同类型知识之间的统一存储和表示架构,辅助整体、动态、对抗条件下的任务筹划、作战规划和案例推演^[13]。

2 基于知识图谱的知识表示方法

军事大数据是联合作战态势知识的主要来源,具有海量和多源异构等特点。联合作战态势知识表示主要研究如何在军事大数据基础上对联合作战态势知识进行建模,使机器可以用一种更加接近于人类认知战争的方式感知和理解联合作战态势知识^[14]。目前基于知识图谱的联合作战态势知识表示方法通常可以采用基于离散符号的知识表示方法和基于连续向量的知识表示方法2种^[15-18]。

2.1 基于离散符号的知识表示方法

2.1.1 传统的知识表示方法

1) 一阶谓词逻辑(First-Order Predicate Logic)

谓词逻辑(Predicate Logic)是以数理逻辑为基础,把命题逻辑作为子系统,进一步分析命题中的个体词、谓词和量词等非命题成分的逻辑关系、推

理形式和规律^[19]。一阶谓词逻辑只包含个体谓词和个体量词，简称一阶逻辑^[20]。使用一阶谓词逻辑描述联合作战态势知识，能够使作战态势知识的表示形式更接近于人类的自然语言，逻辑严密精确，缺点是难以表达联合作战态势知识中的不确定性知识和模糊性知识，知识推理容易发生组合爆炸，推理效率低等^[21]。

2) 产生式规则(Production Rules)

产生式规则以“IF-THEN”规则表示客观事物之间存在的大量因果关系知识，目的是通过捕获人类推理和行为的规律特点来求解问题，善于表示规则性知识。产生式规则的一般形式为：

$$P \rightarrow Q \text{ 或 if } P \text{ then } Q, CF \in [0,1] \quad (1)$$

产生式规则适于表示联合作战态势各种经验性的关联规则知识^[22]，缺点是知识表示形式过于单一，联合作战知识规则的匹配效率较低。

3) 框架表示法(Frame Representation)

框架表示法由 Marvin Minsky 提出，擅长表示结构性知识^[23]。所谓的框架是一种用于描述事物情境模式(Schema)信息的数据结构，可用于表示联合作战态势知识中的元知识，框架的槽或侧面主要包括事物的描述信息和框架的使用信息等，可用于描述联合作战态势要素知识以及如何使用这些知识。框架中的槽值是对现实世界中具体事物的描述，槽值不同代表框架表示的具体事物不同。不同框架知识之间的转换可以用于描述事物推理过程、状态变化等。框架表示法的优点是能够把与联合作战态势要素实体相关的各方面信息较好协调起来，全面完整地描述联合作战态势要素实体各方面的知识，知识库质量高。缺点是框架的构建成本高，作战态势要素相关知识的表示方式不够灵活，难以同其他表示形式的作战态势知识库融合关联使用。

4) 语义网络(Semantic Network)

语义网络能够将联合作战态势要素相关知识的逻辑项及其运算关系映射到有向图上的相应元素进行表达和推理，既可以表示实体及其属性的语义知识，也支持对实体间的语义关联知识进行

推理^[24]。优点是可以直观表示联合作战态势要素的实体概念、属性以及态势要素实体之间的语义联系，能够比较容易地实现基于人类自然语言表达的联合作战态势知识向基于语义网络知识表示方法的转换，知识的表示能力和灵活性较强。缺点是作战态势知识的推理规则不明确，复杂的网络结构常常无法保证基于网络推理的严格性和有效性，而且不便于表达深层次的隐性作战态势知识。

2.1.2 基于语义网的知识表示

语义网(Semantic Web)旨在通过 RDF 基础数据模型将传统基于超文本链接的 Web 转化为机器能够识别和理解的实体语义链接的 Web^[25-27]。

1) RDF

RDF 基础数据结构是目前最常见的语义网基础知识模型，其底层知识表达形式是三元组，可以通过节点(Node)和有向弧(Directed-arc)来描述。由节点-弧-节点连接的 RDF 三元组资源集合称为 RDF 图。根据 RDF 模型创建数据集，存储和传输 RDF 数据的方法主要有以下 5 种：

(1) RDF/XML。即采用 XML 格式编码描述 RDF 图数据^[28]。采用 XML 编码描述联合作战态势知识，能够与现行的指挥信息系统进行对接与集成，方便不同类型的作战系统之间交流 RDF 数据。缺点是 XML 编码过于繁琐，不便于人类交流。

(2) N-Triples。N-Triples 是一种行结构的 RDF 图编码，要用于表示 RDF 测试案例及定义 RDF/XML 和 RDF 抽象语法之间的对应关系。每个 N-Triples 文档由一系列纯文本 ASCII 字符组成，语法类似 XML，解析后是 RDF 三元组序列^[29]。N-Triples 格式编码特别适合表示联合作战态势知识的测试案例。缺点是可读性欠佳。

(3) Turtle (Terse RDF Triple Language)。Turtle 文档是一种紧凑的文本化 RDF 图表达方式，允许将联合作战态势知识的 RDF 图表示为紧凑的文本形式，可读性更好^[30]，目前使用最多。

(4) RDFa (The RDF in Attributes)。RDFa 是互

联网上常见的一种基于 RDF 的 XHTML 和 HTML5 扩展表示形式, 能够帮助搜索引擎和 Web 服务更容易解析网站的非结构化页面, 从而获取有用的数据化知识^[31]。读者可以访问 <https://rdfa.info/play/> 直观感受下搜索引擎在嵌入 RDFa 页面中解析出来的结构化信息。

(5) JSON-LD (JSON for Linking Data)。JSON-LD 是一种基于 JSON 格式的轻量级链接数据格式, 旨在提供一种将已经使用 JSON 语法部署的系统平稳升级到 JSON-LD 的途径, 帮助 JSON 数据在 Web 范围内进行互操作, 适用于编程环境、REST Web 服务以及 CouchDB 和 MongoDB 等非结构化数据库^[32]。

虽然, RDF 模型通过上述众多的数据序列化方法构建 RDF 图, 提供了表示联合作战态势知识的基本语义框架。但整体而言, RDF 模型对于联合作战态势知识的表达能力有限, 缺乏对联合作战态势要素的抽象描述能力, 无法从关系/属性的角度定义和描述联合作战态势知识。RDFS 扩展语言和 OWL 本体描述语言的出现在一定程度上解决了 RDF 知识表达能力不足的问题。

2) RDFS 和 OWL

RDFS 是对基本 RDF 词汇表的扩展, 通过为 RDF 数据建立数据建模词汇表, 根据它们所应用的资源类来描述属性。因此, 这种以 RDF 属性为中心联合作战态势知识表示方法允许研究人员对现有联合作战态势知识的描述内容进行扩展^[33]。OWL 是一种用于表示关于事物、事物集合以及事物之间复杂知识及关系的语义网语言, 进一步扩展了类和属性的表达能力, 使得 Web 内容的机器可解释性比 XML、RDF 和 RDFS 更强。使用 OWL 表达的联合作战态势知识可以用于验证知识的一致性, 或显式表达隐性知识。截止到目前, OWL 知识表示语言现在已经发展到了 OWL2 版本, 并根据不同的用户需求以及特定的实现需要, 设计了 3 种具有越来越多知识表示能力的子语言: OWL Lite, OWL DL 和 OWL Full^[34]。

2.2 基于连续向量的知识表示方法

知识表示学习的研究由来已久^[35]。研究人员受自然语言处理中词嵌入技术启发, 将知识图谱中实体及其关系的语义知识映射到统一的连续低维向量空间。通过建立统一的知识表示特征向量空间, 对知识库中实体及其关系的复杂语义关联关系进行统一表达和高效计算^[36]。

1) 结构嵌入距离模型

结构嵌入(Structured Embeddings, SE)对知识图谱中一个事实三元组的实体在 d -维实值向量空间中进行建模, 该 d -维实值向量空间称为嵌入空间(Embedding Space), 如嵌入空间中实体 i 的实值向量为 $E_i \in \mathbb{R}^d$ 。在该嵌入空间中, 对任意给定的实体关系类型都有一个特定的实体相似性度量矩阵来捕获实体之间的关系, 定义关系 k 为:

$$R_k = (R_k^{lhs}, R_k^{rhs}) \quad (2)$$

式中: R_k^{lhs} 和 R_k^{rhs} 均为 $d \times d$ 维矩阵。结构嵌入距离模型通过计算嵌入空间中事实三元组中头实体向量和尾实体向量关系矩阵之间的 1 范数距离(1-Norm Distance), 来度量不同实体之间的语义相似度^[37]:

$$S_k(E_i, E_j) = \|R_k^{lhs}E_i - R_k^{rhs}E_j\| \quad (3)$$

结构嵌入距离模型的优点是能通过寻找不同实体之间距离最近的关系矩阵进行连接预测。不足之处在于对每个三元组的头尾实体分别映射和计算关系矩阵, 无法精确刻画头、尾实体之间的语义关系。

2) 单层神经网络模型

单层神经网络模型(Single Layer Model, SLM)试图通过标准单层神经网络的非线性计算, 来隐式连接实体向量, 以达到缓解距离模型两个实体向量参数无法相互作用的目的。模型中实体 e_1, e_2 在确定性关系 R 情况下的相似性得分函数为:

$$\begin{aligned} g(e_1, R, e_2) &= u_R^T f(W_{R,1}e_1 + W_{R,2}e_2) = \\ &= u_R^T f\left(\begin{bmatrix} W_{R,1} & W_{R,2} \end{bmatrix} \begin{bmatrix} e_1 \\ e_2 \end{bmatrix}\right) \end{aligned} \quad (4)$$

式中: 参数 $f = \tanh$, $W_{R,1}, W_{R,2} \in \mathbb{R}^{k \times d}$, $u_R \in \mathbb{R}^{k \times 1}$ 。

虽然单层神经网络模型改进了结构嵌入距离模型,但标准单层神经网络的非线性计算只提供了两个实体向量之间的弱相互作用,却引入了计算复杂度更高的模型优化问题^[38]。

3) 语义匹配能量模型

语义匹配能量模型(Semantic Matching Energy, SME)通过学习分布式知识表示中每个符号的低维表示向量,来联合捕捉单词、实体以及单词实体组合的多关系语义知识。其语义推断过程分2步执行:一是通过语义角色标注预测语义结构;二是通过语义消歧使学习能量函数最小化^[39]。

4) 隐变量模型

隐变量模型(Latent Factor Model, LFM)是一种基于双线性结构的关系数据模型,能够通过捕捉数据交互的各种顺序以及不同关系之间共享的稀疏隐变量,来提取多关系图数据和自然语言中各种实体和关系有意义的表示,并为有效关系分配高概率,而其他所有关系分配低概率^[40]。隐变量模型考虑了数据中的不确定性,有效描述了实体和关系之间的语义联系,实体关系处理能力和链接预测能力获得大幅提升。

5) 张量神经网络模型

张量神经网络模型(Neural Tensor Network, NTN)提供了一种比标准神经网络层更加强大的实体关系知识建模方法。模型允许每个实体的词之间共享统计强度,采用双线性张量来捕获实体与关系之间的联系,从而显式地关联两个实体向量,使模型能够更加准确地预测实体关系^[38]。实体 e_1, e_2 之间存在确定性关系 R 的可能性函数为:

$$g(e_1, R, e_2) = u_R^T f \left(e_1^T W_R^{[1:k]} e_2 + V_R \begin{bmatrix} e_1 \\ e_2 \end{bmatrix} + b_R \right) \quad (5)$$

式中: $f = \tanh$ 为双曲正切函数, $W_R^{[1:k]} \in \mathbb{R}^{d \times d \times k}$ 为张量, 双线性张量乘积 $e_1^T W_R^{[1:k]} e_2$ 的结果是向量 $h_i = e_1^T W_R^{[i]} e_2, i = 1, 2, \dots, k, h_i \in \mathbb{R}^k$ 。张量神经网络模型更加精确地刻画了实体和关系的复杂语义联系,但计算复杂,学习成本较高。

6) 矩阵分解模型

矩阵分解模型即通过分解关系数据固有结构的张量因子进行知识表示学习。Nickel 等提出的 RESACL 模型,能够通过模型的隐变量张量因子分解进行集体学习^[41]。实验结果表明, RESACL 模型较以往的知识表示学习方法能够在学习效果相同或更好的情况下显著加快计算速度。

7) 翻译模型

2013 年, Bordes 等提出 TransE 模型,通过学习实体在低维嵌入空间的实值向量,来解决多关系数据的处理难题^[18]。模型把知识图谱中不同实体之间的关系看作是实体之间的某种平移向量,将每个三元组(head, relation, tail)中的关系向量 V_r 作为头实体向量 V_h 到尾实体向量 V_t 的平移,通过不断调整 V_h , V_r 和 V_t , 使 $(V_h + V_r)$ 尽可能与 V_t 相等,从而达到学习的目的。训练集中基于边缘的排序标准定义为:

$$L = \sum_{(h, l, t) \in S} \sum_{(h', l, t') \in S'_{(h, l, t)}} [\gamma + d(V_h + V_r, t) - d(V_{h'} + V_r, t')]_+ \quad (6)$$

$$S'_{(h, l, t)} = \{(h', l, t) | h' \in E\} \cup \{(h, l, t') | t' \in E\} \quad (7)$$

式(6)(7)中: $[x]_+$ 为取正值; $\gamma > 0$ 为超参数; E 为实体集合。

TransE 模型能直接建立实体和关系之间的语义联系,模型性能较以往有显著提升,但难以解决实体之间的复杂关系映射问题。因此出现了许多改进模型。其中, TransH 通过引入特定关系超平面映射机制,允许不同的实体关系具有不同的分布式表示^[42]。TransR 模型认为与同一实体相关的不同关系可能分别映射在与实体相关的不同语义空间,通过在不同的实体向量空间和关系向量空间中分别学习实体到相应关系空间的映射,来构建头尾实体之间的翻译关系^[43]。TransD 模型通过进一步考虑实体和关系的多样性,分别设置了实体或关系的含义向量和动态映射向量,以达到优化翻译模型的目的^[44]。TransSparse 模型认为翻译模型应当考虑知识图谱自身结构的异质性特征和不均匀特点,使用稀疏程度由关系连接的实体(或实体对)数量决定的自适应稀疏矩阵来代替翻译矩阵,进一步优化了

翻译模型的知识表示学习能力^[45]。TransG 模型认为知识图谱中的同一个关系可能具有多重语义, 通过关联实体对来自动发现关系的语义集群, 并借助多重关系组件的混合来翻译实体对, 以及利用特定关系组合向量的混合来嵌入事实三元组^[46]。KG2E 模型认为知识图谱中不同实体和关系的语义表达可能包含不同的确定性, 使得相同的确定性不足以进行建模, 提出通过学习知识图谱中每个实体/关系在多维高斯分布空间中的表示, 对实体和关系的确定性进行显式建模^[47]。上述改进模型均不同程度提升了翻译模型处理实体间复杂关系的能力。

然而, 上述以 TransE 为代表的知识表示学习模型仅利用了知识图谱的显性结构信息, 没有利用关系路径等隐含信息, 许多相关研究仍处于起步阶段。Wang 等认为, 现有的知识表示方法没有很好利用知识图谱中对于实体的简明描述信息, 提出使用三元组的描述信息进一步联合学习实体的语义知识^[48]。Zhong 等认为多源异构信息融合的关键问题是对于齐模型, 需要确保实体、关系和单词的表示向量在同一特征空间, 提出实体的嵌入向量要同时满足知识库的结构化约束和等于文本描述中的嵌入向量^[49]。Lin 等认为知识图谱中的多步关系路径同样包含实体间丰富的推理模式, 提出通过关系嵌入的语义组合表示关系路径, 设计了一个路径约束资源分配算法来度量关系路径的可靠性^[50]。García-Durán 等也认为应充分利用知识图谱中的图结构, 提出通过扩展 TransE 模型, 添加相应翻译向量来学习关系的显式组合, 从而提高单个关系以及关系组合的预测能力^[51]。Guu 等认为, 近年来在向量空间中嵌入知识图谱结构来填充缺失事实的知识补全模型, 应用于回答路径查询时存在级联错误, 提出采用知识表示学习组合训练模型来提高基于关系路径的知识表示能力^[52]。

上述研究分别从复杂关系处理、多源信息融合、关系路径建模 3 个角度研究了基于连续向量的知识表示学习, 在许多评测任务中取得了重要进展, 但仍存在巨大挑战。

3 针对联合作战态势知识的特点进行知识表示

联合作战态势知识表示的核心问题是如何针对联合作战态势知识的特点, 将战场感知数据、指挥决策信息、作战条令规则等形式化知识, 以及战场态势判断、敌方意图识别和敌情威胁分析等非形式化知识组织起来, 进行统一表达, 从而完成从战场感知数据到战场态势信息到作战态势知识的转变, 为态势智能认知提供知识支撑。这需要从联合作战态势知识的具体应用场景出发, 在已有研究的基础上, 进一步深入探索显性知识与隐性知识在特定场景语义空间中的统一映射方法, 进而对联合作战态势的形式化知识与非形式化知识进行联合表示。但联合作战态势知识的联合表示并非易事。

首先, 联合作战态势知识包括联合战场传感器捕获的数据、报告、图片、音频、视频等结构化数据、半结构化数据和非结构化数据, 具有 4V 特点, 是典型的军事大数据, 导致态势要素在时间、空间、实体类型、实体属性等方面都具有极高的维度, 这为作战态势知识的表示带来了极大困难, 需要针对态势各要素属性的维度特征进行聚合和降维处理, 选择特定场景内作战态势知识恰当的认知维度, 为构建面向不同任务场景的联合作战态势认知样本知识库提供支持。

其次, 以满足联合作战态势智能认知应用需求为出发点的联合作战态势知识表示, 既要完整反映实际作战情况, 又必须在满足实际指挥作战需求的基础上, 保证在特定联合作战场景下呈现给各级指挥员的作战态势知识具有客观一致性和相对完备性, 使得探索突破统一框架下联合战场的一致性态势知识表示方法非常困难。这需要在掌握各种战场态势数据和获得战场态势感知信息的基础上, 将作战态势信息与指挥决策信息相关联, 迅速整合转换为全面的联合作战态势知识, 形成作战态势知识库, 从而获得更加准确和精确的一致性作战态势知识表达。

最后,实现人机共同认可的联合作战态势知识表达仍然存在较大困难。以满足军事需求为背景的知识表示应当是人类可以理解和信任的机器语言,这包含2方面内涵:(1)以态势智能认知为应用起点的联合作战态势知识表示,是一种用于表达特定场景内的客观事物及其关系,且能够满足机器高效处理要求的机器标识,其表示形式应当人类可理解;(2)战争是高对抗高风险的特殊的人类实践活动,对战争建模需要模型本身安全可靠可控。这两个方面决定了联合作战态势智能认知模型背后的学习和推理逻辑需要更多的可解释性,即以联合作战态势知识表示为起点,在机器实时高效处理的基础上,从指挥员认知的角度,将人容易理解的符号逻辑知识植入到神经网络中,深入研究辅助指挥员指挥决策的联合作战态势知识表示方法,并能够显性解释学习的结果。

知识图谱企图以一种基于大规模复杂知识网络的结构化知识表达方式,将联合作战态势知识以图的形式组织起来描述现实世界中各种实体之间的关系^[36],但仍未脱离以“实体及其关系”为核心的知识表示方法,缺乏对事件关联知识以及场景描绘知识的表示与挖掘,未能从根本上解决联合作战态势知识的时空关联推理、复杂突发事件因果关系描述以及复杂作战场景下态势事件间的关联关系描述等难题^[53-55]。因此,以联合作战背景下的态势智能认知为应用目标的联合作战态势知识表示,应该从“整体、动态、对抗”的角度,区分不同的作战场景和作战层次,对态势知识表示按应用场景和应用需求进行定制。基于特定场景的作战态势知识表示方法,不仅要包括相对客观的“态”的作战知识的描述,还应包括与指挥员主观认知相关的“势”的作战知识的描述。基于以上分析,我们认为面向态势智能认知的联合作战态势知识表示方法,应该是一种超越现代知识图谱和事理图谱知识表示方法的新一代知识图谱,即场景知识图谱(Scenario Knowledge Graph, SKG)。

场景知识图谱是从态势智能认知的特定应用

场景和需求出发,以想定联合作战场景内的军事力量部署知识、武器装备体系知识、指挥关系知识、作战支撑保障知识等核心作战态势知识为主要内容,通过对联合作战背景下的具体作战场景进行解析和态势要素关联,来描绘联合战场的整体图景。场景知识图谱中作战态势知识的基本来源是基于场景的军事知识体系和联合作战态势军事大数据,通过将作战态势知识的内容概念化分解、结构语义化描述、关系动态化调整,以及知识的体系化服务,为联合作战态势知识的采集、组织、验证和运用打下基础。场景知识图谱中作战态势知识表示的基本模型是基于离散符号和基于连续向量相融合的知识联合表示。其中,基于离散符号的知识表示方法能够显性表示作战态势的形式化知识。基于连续向量的知识表示方法可以进一步挖掘作战态势的非形式化隐性知识。两者关联对应,统一在特定场景的底层语义特征空间内进行一致性表达。

4 结论

面向态势智能认知的联合作战态势知识表示是对联合作战态势进行认知建模的基础。综述了基于知识图谱的联合作战态势知识表示方法,分析了知识图谱和事理图谱对于表示联合作战态势知识存在的困难和不足。提出了场景知识图谱的概念,描述了场景知识图谱基本内容和知识来源,阐述了应当采取基于场景的离散符号和连续向量相融合的知识联合表示方法,来统一表达面向态势智能认知的联合作战态势知识。然而,知识联合表示方法的研究仍处于起步阶段,手段十分有限,需要不断探索和验证面向态势智能认知的联合作战态势知识联合表示方法的计算复杂性和有效性。

本文工作不仅为开展战场态势智能认知研究提供支持,而且可为开展辅助决策分析、自主决策等其他问题的研究奠定知识表示基础。

参考文献:

- [1] 胡晓峰, 司光亚, 吴琳, 等. 战争模拟原理与系统[M]. 2版. 北京: 国防大学出版社, 2009.

- Hu Xiaofeng, Si Guangya, Wu Lin, et al. War Gaming & Simulation Principle and System[M]. 2th Edition. Beijing: National Defense University Press, 2009.
- [2] 胡晓峰, 贺筱媛, 陶九阳. 认知仿真: 是复杂系统建模的新途径吗? [J]. 科技导报, 2018, 36(12): 46-54.
Hu Xiaofeng, He Xiaoyuan, Tao Jiuyang. Cognitive Simulation: Is it a New Approach for Complex System Modeling? [J]. Science & Technology Review, 2018, 36(12): 46-54.
- [3] 朱丰, 胡晓峰, 吴琳, 等. 从态势认知走向态势智能认知[J]. 系统仿真学报, 2018, 30(3): 761-771.
Zhu Feng, Hu Xiaofeng, Wu Lin, et al. From Situation Cognition Stepped into Situation Intelligent Cognition[J]. Journal of System Simulation, 2018, 30(3): 761-771.
- [4] 胡晓峰, 贺筱媛, 陶九阳, 等. 态势智能认知的问题与探索[J]. 论证与研究, 2018, 34(4): 1-12.
Hu Xiaofeng, He Xiaoyuan, Tao Jiuyang, et al. Issues and Exploration of Situation Intelligent Cognition[J]. Demonstration And Research, 2018, 34(4): 1-12.
- [5] 李加祥, 李建平. 作战态势的知识及获取的逻辑过程研究[J]. 海军大连舰艇学院学报, 2002, 25(6): 21-23.
Li Jiaxiang, Li Jianping. Research on the Knowledge of Combat Situation and the Logic Process of Acquisition[J]. Journal of Dalian Naval Academy, 2002, 25(6): 21-23.
- [6] 戈尔茨坦. 认知心理学[M]. 3 版. 北京: 中国轻工业出版社, 2015: 71-81.
Goldstein E B. Cognitive Psychology[M]. 3rd Edition. Beijing: China Light Industry Press, 2015: 71-81.
- [7] Majid A, Bowerman M, Kita S, et al. Can Language Restructure Cognition? The Case for Space[J]. TRENDS in Cognitive Sciences (S1364-6613), 2004, 8(3): 108-114.
- [8] Singhal A. Introducing The Knowledge Graph: Things, Not Strings [EB/OL]. [2019-05-04]. <http://googleblog.blogspot.be/2012/05/introducing-knowledge-graph-things-not.html>.
- [9] 徐增林, 盛泳潘, 贺丽荣, 等. 知识图谱技术综述[J]. 电子科技大学学报, 2016, 45(4): 589-606.
Xu Zenglin, Sheng Yongpan, He Lirong, et al. Review on Knowledge Graph Techniques[J]. Journal of University of Electronic Science and Technology of China, 2016, 45(4): 589-606.
- [10] 刘丽, 张超, 李华莹. 基于知识图谱的军事数据组织技术研究[C]//第六届中国指挥控制大会论文集(上册). 北京: 电子工业出版社, 2018: 392-396.
- Liu Li, Zhang Chao, Li Huaying. Research On Military Data Organization Technology Based On Knowledge Graph[C]// Proceedings of the 6th China command and control congress (volume one). Beijing: Publishing House of Electronics industry, 2018: 392-396.
- [11] 丁君怡, 赵青松, 夏博远, 等. 基于开源数据的武器装备知识图谱构建方法研究[J]. 指挥控制与仿真, 2018, 40(2): 22-26.
Ding Junyi, Zhao Qingsong, Xia Boyuan, et al. The Method Study of Armament Knowledge Graph's Establishment Based on Open Source Data[J]. Command Control & Simulation, 2018, 40(2): 22-26.
- [12] 张倩倩, 刘俊, 杨晓冬. 语义网在军事领域的应用综述[J]. 计算机与数字工程, 2013, 41(3): 402-406.
Zhang Qianqian, Liu Jun, Yang Xiaodong. Review of the Semantic Web Applications in Military Field[J]. Computer and Digital Engineering, 2013, 41(3): 402-406.
- [13] 周丽娜, 马志强. 基于知识图谱的网络信息体系智能参考架构设计[J]. 中国电子科学研究院学报, 2018, 13(4): 378-383.
Zhou Lina, Ma Zhiqiang. Knowledge Graph based Architecture Design of Networked Information System of Systems[J]. Journal of China Academy of Electronics and Information Technology, 2018, 13(4): 378-383.
- [14] 李涓子, 侯磊. 知识图谱研究综述[J]. 山西大学学报(自然科学版), 2017, 40(3): 454-459.
Li Juanzi, Hou Lei. Reviews on Knowledge Graph Research[J]. Journal of Shanxi University (Natural Science Edition), 2017, 40(3): 454-459.
- [15] 刘知远, 孙茂松, 林衍凯, 等. 知识表示学习研究进展[J]. 计算机研究与发展, 2016, 53(2): 247-261.
Liu Zhiyuan, Sun Maosong, Lin Yankai, et al. Knowledge Representation Learning: A Review[J]. Journal of Computer Research and Development, 2016, 53(2): 247-261.
- [16] Newell A, Simon H A. Computer Science as Empirical Inquiry: Symbols and Search[J]. Communications of the ACM(S0001-0782), 1976, 19(3): 113-126.
- [17] Mikolov T, Chen K, Corrado G, et al. Efficient Estimation of Word Representations in Vector Space[J]. arXiv:1301.3781[cs.CL].
- [18] Bordes A, Usunier N, Garcia-Durán A, et al. Translating Embeddings for Modeling Multi-relational Data[C]// Advances in Neural Information Processing Systems 26 (NIPS 2013), 2013.
- [19] 陈慕泽, 余俊伟. 数理逻辑基础[M]. 北京: 中国人民大学出版社, 2018: 1-250.

- 大学出版社, 2003.
- Chen Muze, Yu Junwei. Foundations of Mathematical Logic[M]. Beijing: China Renmin University Press, 2003.
- [20] 顾恒. 一阶逻辑的一种全面扩张: 语形和语义[D]. 重庆: 西南大学逻辑与智能研究中心, 2013.
- Gu Heng. An Omnidirectional Extension of the First-order Logic: Syntax and Semantics[D]. Chongqing: Southwest University Center for logic and intelligence, 2013.
- [21] Kowalski R, Steve S. Logic for Problem Solving[J]. ACM SIGSOFT Software Engineering Notes (S0163-5948), 1982, 7(2): 61-62.
- [22] 柳少军. 军事决策支持系统理论与实践[M]. 北京: 国防大学出版社, 2005.
- Liu Shaojun. Military decision support system theory and practice[M]. Beijing: National Defense University Press, 2005.
- [23] 于中华, 唐常杰. 自然语言句法结构的框架树表示方法[J]. 小型微型计算机系统, 1999, 20(8): 583-586.
- Yu Zhonghua, Tang Changjie. Tree Representation for Syntax Structure of Natural Languages[J]. Mini-micro Systems, 1999, 20(8): 583-586.
- [24] Lehmann H. Semantic Networks[J]. Computers & Mathematics with Applications(S0898-1221), 1992, 23(2): 1-50.
- [25] Berners-Lee T, Fischetti M. Weaving the Web: The Original Design and Ultimate Destiny of the World Wide Web by Its Inventor[M]. SanFrancisco, DIANE Publishing Company, 2001.
- [26] McGuinness D L, Harmelen F V. OWL Web Ontology Language Overview[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/owl-features/>.
- [27] Hayes P. RDF Semantics[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/rdf-mt/>.
- [28] Gandon F, Schreiber G. RDF 1.1 XML Syntax[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/rdf-syntax-grammar/>.
- [29] Grant J, Beckett D. RDF Test Cases[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/rdf-testcases/#ntriples>.
- [30] Beckett D, Berners-Lee T, Prud'hommeaux E, et al. RDF 1.1 Turtle: Terse RDF Triple Language[EB/OL]. [2014-02-25]. <https://www.w3.org/TR/turtle/>.
- [31] Herman I, Adida B, Sporny M, et al. RDFa 1.1 Primer-Third Edition: Rich Structured Data Markup for Web Documents[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/rdfa-primer/>.
- [32] Sporny M, Longley D, Kellogg G, et al. JSON-LD 1.0: A JSON-based Serialization for Linked Data[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/json-ld/>.
- [33] Brickley D, Guha R V. RDF Schema 1.1[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/rdf-schema/>.
- [34] McGuinness D L, Harmelen F V. OWL Web Ontology Language: Overview[EB/OL]. [2019-05-04]. <https://www.w3.org/TR/owl-features/>.
- [35] Bengio Y, Courville A, Vincent P. Representation Learning: A Review and New Perspectives[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence (S0162-8828), 2013, 35(8): 1798-1828.
- [36] 中国中文信息学会. 知识图谱发展报告(2018)[R]. 北京: 中国中文信息学会, 2018.
- Chinese Information Processing Society of China. Knowledge Graph Development Report(2018)[R]. Beijing: CIPSC, 2018.
- [37] Bordes A, Weston J, Collobert R, et al. Learning Structured Embeddings of Knowledge Bases[C]// Twenty-Fifth AAAI Conference on Artificial Intelligence. Hyatt Regency San Francisco, USA: AAAI Press, 2011: 301-306.
- [38] Socher R, Chen D, Manning C D, et al. Reasoning With Neural Tensor Networks for Knowledge Base Completion[C]//Neural Information Processing Systems 2013. Lake Tahoe, USA: Curran Associates, Inc., 2013: 926-934.
- [39] Bordes A, Glorot X, Weston J, et al. A Semantic Matching Energy Function for Learning with Multi-Relational Data[J]. Machine Learning (S0885-6125), 2014, 94(2): 233-259.
- [40] Jenatton R, Nicolas L R, Bordes A, et al. A Latent Factor Model for Highly Multi-Relational Data[C]//Neural Information Processing Systems 2012. Lake Tahoe, USA: Curran Associates, Inc., 2012: 3167-3175.
- [41] Nickel M, Tresp V, Kriegel H. A Three-Way Model for Collective Learning on Multi-Relational Data[C]// Proceedings of the 28th International Conference on Machine Learning. Washington, USA: Omnipress, 2011: 809-816.
- [42] Wang Z, Zhang J, Feng J. Knowledge Graph Embedding by Translating on Hyperplanes[C]//Twenty-Eighth AAAI Conference on Artificial Intelligence. Québec, Canada: AAAI Press, 2014: 1112-1119.
- [43] Lin Y, Liu Z, Sun M, et al. Learning Entity and Relation Embeddings for Knowledge Graph Completion[C]//

- Twenty-Ninth AAAI Conference on Artificial Intelligence. Austin, USA: AAAI Press, 2015: 2181-2187.
- [44] Ji G, He S, Xu L, et al. Knowledge Graph Embedding via Dynamic Mapping Matrix[C]//Annual Meeting of the Association for Computational Linguistics. Beijing, China: Association for Computational Linguistics, 2015: 687-696.
- [45] Ji G, Liu K, He S. Knowledge Graph Completion with Adaptive Sparse Transfer Matrix[C]//Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, USA: AAAI Press, 2016: 985-991.
- [46] Xiao H, Huang M, Zhu X. TransG: A Generative Model for Knowledge Graph Embedding[C]//Annual Meeting of the Association for Computational Linguistics. Berlin, Germany: Association for Computational Linguistics, 2016: 2316-2325.
- [47] He S, Liu K, Ji G, et al. Learning to Represent Knowledge Graphs with Gaussian Embedding[C]//24th ACM International Conference on Information and Knowledge Management. Melbourne, Australia: ACM, 2015: 623-632.
- [48] Xie R, Liu Z, Jia J, et al. Representation Learning of Knowledge Graphs with Entity Descriptions[C]// Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, USA: AAAI Press, 2016: 2659-2665.
- [49] Zhong H, Zhang J, Wang Z, et al. Aligning Knowledge and Text Embeddings by Entity Descriptions[C]// Conference on Empirical Methods in Natural Language Processing. Lisbon, Portugal: Association for Computational Linguistics, 2015: 267-272.
- [50] Lin Y, Liu Z, Luan H, et al. Modeling Relation Paths for Representation Learning of Knowledge Bases[J]. arXiv: 1506.00379v2 [cs.CL], 2015.
- [51] García-Durán A, Bordes A, Usunier N. Composing Relationships with Translations[C]//Conference on Empirical Methods in Natural Language Processing. Lisbon, Portugal: Association for Computational Linguistics, 2015: 286-290.
- [52] Guu K, Miller J, Liang P. Traversing Knowledge Graphs in Vector Space[J]. arXiv: 1506.01094v2 [cs.CL], 2015.
- [53] Duan J, Ding X, Liu T. Learning Sentence Representations over Tree Structures for Target-dependent Classification [C]// Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. New Orleans, USA: Association for Computational Linguistics, 2018: 551-560.
- [54] Li Z, Ding X, Liu T. Constructing Narrative Event Evolutionary Graph for Script Event Prediction[J]. arXiv: 1805.05081v2 [cs.CL], 2018.
- [55] Zhao S, Wang Q, Massung S, et al. Constructing and Embedding Abstract Event Causality Networks from Text Snippets[C]//Tenth ACM International Conference on Web Search and Data Mining. Cambridge, United Kingdom: ACM, 2017: 335-344.