



基于强制稀疏自编码神经网络的防空作战体系效能回溯分析方法

郭圣明*, 贺筱媛, 吴琳, 胡晓峰

中国人民解放军国防大学联合作战学院, 北京 100091

* 通信作者. E-mail: guosm04@mails.thu.edu.cn

收稿日期: 2017-12-31; 接受日期: 2018-01-28; 网络出版日期: 2018-07-19

国家自然科学基金 (批准号: 61273189, 71401168, 61174156, 61403401, 61374179) 和军民共用重大研究计划联合基金 (批准号: U1435218) 资助项目

摘要 针对传统数据挖掘方法无法深入分析防空体系复杂关联关系和体系能力涌现生成机理的问题, 提出一种基于强制自编码神经网络的防空作战体系能力回溯分析方法. 以使命任务指标为牵引, 利用大数据关联关系分析, 复杂网络社团分析及主成分分析等方法, 获取相对完备且具有明确军事含义的防空作战指标体系结构, 以此先验知识为结构框架, 构建结构约束的强制自编码深度学习网络模型, 形式化地描述防空体系能力指标之间的级联涌现关系, 并在此基础上深入分析体系能力生成机理及贡献度, 最后通过仿真实验数据对模型进行了验证. 实验结果表明, 相对于传统的数据分析方法和深度学习方法, 所提模型对防空体系能力指标涌现过程的形式化描述, 不仅体现了涌现过程的非线性、不确定性等复杂性特征, 同时还赋予指标体系相对明确的物理含义, 为辅助指挥员深入认知并管控复杂作战体系提供了可行的方法手段.

关键词 作战体系, 效能评估, 深度学习, 涌现, 体系指标, 贡献度

1 引言

防空作战体系是由侦察预警、火力拦截、指挥控制、全维防护和综合保障等系统构成的复杂体系, 其体系能力是体系在完成作战任务过程中各组分系统间交互涌现出的整体性“相变”结果. 因此描述防空体系作战能力的指标应该为相应各组分系统的能力指标的涌现“和”^[1~3], 涌现过程具有防空作战体系自适应性、非线性、不确定性、因果关系不明等复杂性特点, 而传统能力评估方法往往基于独立性假设的“指标树”, 通过基于线性还原论的“简单和”方式得到具有确定性结论的“单一值”, 无法实现对复杂体系整体涌现性的描述, 这成为阻碍人们深度认知、进而管控复杂系统的主要障碍. 为此,

引用格式: 郭圣明, 贺筱媛, 吴琳, 等. 基于强制稀疏自编码神经网络的防空作战体系效能回溯分析方法. 中国科学: 信息科学, 2018, 48: 824-840, doi: 10.1360/N112017-00303

Guo S M, He X Y, Wu L, et al. Backtracking analysis approach for effectiveness of air defense operation system of systems based on force-sparsed stacked-autoencoding neural networks (in Chinese). Sci Sin Inform, 2018, 48: 824-840, doi: 10.1360/N112017-00303

文献 [1] 提出体系能力评估方法要能够体现从“指标树”到“指标网”,从“简单和”到“涌现和”,从“单一值”到“结果云”的评估理念.

目前基于数据的体系能力评估已经形成共识,无论是基于仿真实验还是实战或演习,体系能力评估的起点应该是数据^[4~6].面向大数据的回溯分析^[6,7]直接面向相关关系,回避复杂系统因果关系难找的难题,变简单分析为深度分析,为深入研究体系能力涌现性机理、找到影响体系能力的关键因素提供了新的途径.不同于预测分析,回溯分析更关注对体系能力涌现过程和形成机理的深层次分析,因此对体系能力涌现过程的形式化描述是关键.然而,传统的大数据分析方法和理念还停留于统计分析和数据挖掘层面,虽然可以确定防空体系内部交互涌现的复杂关联关系,但却难以将其形式化表示出来;基于复杂网络的体系能力分析同样被证明是解决体系效能评估的有效手段,作者团队前期在网络化指标体系建模方面进行了有益的探索^[3,8~12],局限于传统数据挖掘方法无法对复杂系统级联涌现关系进行形式化描述的局限,因此不能实现对体系涌现性指标取值范围及其对使命任务的贡献度等重点问题的量化分析.

AlphaGo、德州扑克 AI 等的成功^[13,14],使人们越来越认识到深度学习在复杂系统建模评估中具有的巨大应用潜力^[15~18],并已在基于大数据的复杂体系模式识别和预测分析方面取得显著进展^[19~24].与传统的大数据处理方法相比,采用深度学习分析方法分析防空作战体系具有如下优势:一是以防空作战的使命任务为牵引进行的有监督学习,可以实现不同组分系统能力对体系能力汇聚过程及贡献度的描述;二是通过逐层自主抽取体系能力指标,而非依靠专家经验判断,可以客观、全面、高效地描述指标之间的非线性、不确定性的复杂涌现关系;三是隐含层得到面向整个体系的全局能力指标,取代面向分系统能力的局部描述指标,具有更强大的全局评估效果.然而,深度学习的黑箱模型让我们很难得到中间隐含节点,即模型所涌现出的体系能力指标的军事内涵,这成为深度学习应用于防空作战体系涌现性机理回溯分析的最大困难.

同时,深度学习目前的发展正开始朝着结合各类体系分析方法,引入诸如注意力机制^[25]、记忆机制^[26]、增强机制^[13,27]等模式的方向发展,其本质上是人类认知复杂体系的经验作为先验知识赋予深度学习网络模型,以提高其计算效率和发现复杂系统规律的能力,同时增强模型的可解释性.如何通过获取先验知识改进深度神经网络的黑箱特性,或许是防空作战体系能力涌现性回溯分析的可行途径.

基于以上分析,为实现防空作战体系能力涌现性机理的深度分析,本文提出一种基于强制稀疏自编码神经网络(force-sparsed stacked-encoding neural networks, FS-SAE)的体系能力回溯分析方法.该方法创新性地将基于大数据的关联关系分析、复杂网络的功能结构分析和基于深度学习的指标逐层涌现描述相结合,构建了描述防空体系作战能力的“指标网”,形式化描述了体系能力的“涌现和”,得到不同条件下面向使命任务的体系能力“结果云”,实现了对防空作战体系各功能模块对使命任务完成度的影响机理和体系贡献度分析,为辅助指挥员深入认知复杂作战体系能力形成机制提供了理论基础和技术手段.

2 防空体系能力回溯分析研究思路

防空体系能力指标是度量防空体系在完成作战任务过程中所能支配的资源和所具备的运用资源手段和效果的工具,是防空体系作战能力评估的基础.防空体系能力回溯分析的目的是深入分析防空体系各能力指标与使命任务完成度之间的作用和影响机制,为指挥员调整优化防空部署提供决策支持,其本质就是建立防空体系各能力指标集与使命任务完成度指标之间的函数映射关系.因此,防空体系

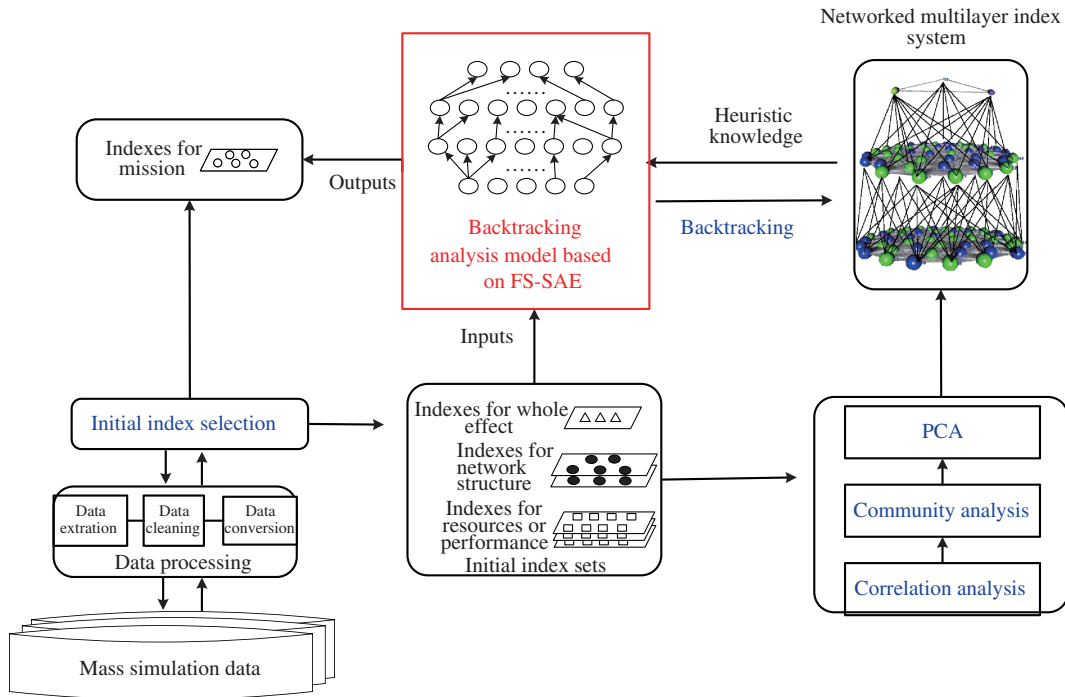


图 1 (网络版彩图) 基于 FS-SAE 的防空体系能力回溯分析思路
 Figure 1 (Color online) The idea of backtracking analysis approach based on FS-SAE

能力回溯分析主要有两个步骤, 一个是确定防空体系能力指标体系, 二是形式化表示指标体系之间的涌现关系.

深度神经网络通过逐层抽象特征实现对复杂系统规律的形式化表示和认知, 如果我们将各层神经网络的节点作为指标, 其网络结构内各节点就构成了反映复杂系统各方面能力特性的一整套指标体系, 可表示为

$$Y = f(H(x)), \tag{1}$$

其中 Y 为输出指标集, x 为输入指标集, f 为神经网络等效函数形式, $H(x)$ 为网络化指标体系结构. 神经网络的黑箱模型主要体现在 $H(x)$, 即各隐含节点意义不明确, 因此要“白化”黑箱模型, 需要在指标体系构建上下功夫. 这里, 采用大数据和复杂网络分析的方法, 构建出描述防空作战体系能力的指标网络结构框架, 以此作为先验知识, 采用堆栈自编码神经网络结构 (stacked encoding neural networks), 构建基于 FS-SAE 的防空体系回溯分析模型. 其主要思路如图 1 所示: (1) 对防空体系作战中产生的海量数据进行预处理, 依据使命任务选定初始指标集, 将使命任务指标集作为输出, 其他指标集作为输入; (2) 以大数据分析和复杂网络相结合的方法, 构建层层聚合的网络化能力指标体系结构框架; (3) 构建以初始指标集合为输入节点、以使命任务指标为输出节点、以网络化能力指标体系结构框架为网络结构的 FS-SAE 回溯分析模型, 通过对使命任务的预测判断验证模型的有效性; (4) 最后, 依据 FS-SAE 确定的涌现关系形式化表示, 回溯分析体系能力涌现性机理和体系贡献率.

防空体系交战数据记录越全面, 能力指标集越完备, 指标交互关系分析越深入, 对防空体系能力的回溯分析将越准确.

3 基于 FS-SAE 的防空体系能力回溯分析模型

3.1 FS-SAE 模型输入与输出编码

构建深度学习模型首先要确定模型的输入输出及其编码方式.

输入编码. 从战场数据中提取的信息越多, 输入信息的维度越大, 表达的信息将越多, 对体系效能评估将描述得越全面; 但输入维度太高, 将会给样本集构建、网络训练, 以及存储空间、处理时间等带来很多问题. 因而, 为了便于网络训练和保证体系评估模型的实用性, 在构建样本集时, 既应全面、客观地表示防空作战体系信息, 又应考虑到存储空间、处理时间和易于实现等现实需求. 因此, 在数据预处理时, 应该依据体系分析需要和经验, 从作战数据中抽取关键指标集, 并对指标集进行统一编码, 形成具有统一长度并便于标准化的防空体系作战数据集. 本文主要考虑防空体系中能够通过数据统计或者解析计算得到的资源性能类指标 (如各防空部队实力、主要防空武器性能参数、侦察预警性能、弹药数等)、网络结构类指标 (如防空网络的聚类系数、网络效率、平均时间效率、可达性等)、效果类指标 (防空体系探测识别敌机数量、距离时间、防空体系的情报收集、处理、分发时间、防空体系地面、海上、空中战损装备数量、拦截敌机数量等), 将它们按照固定的顺序统一编码为一维向量集 $X = X(X_1, X_2, \dots, X_k)$, 其中 k 为初始指标数量, 并对数据进行归一化处理.

输出编码. 深度学习主要应用形式是模式识别和分类, 防空作战的使命任务可视为任务是否达成的分类问题, 如目标是否被摧毁, 战损比大于 1 还是小于 1 等. 因此, 本文定义 FS-SAE 模型的输出空间为使命任务指标构成的向量空间 $Y = Y(Y_1, Y_2, \dots, Y_l)$, 其中 l 为使命任务指标维度.

依据输入指标编码和输出指标编码, 抽取防空体系作战数据, 构建样本集 $T = \{(X_1, X_2, \dots, X_k), (Y_1, Y_2, \dots, Y_l)\}_n$, 其中 n 为数据集的组数, 即 n 次防空作战记录的作战数据.

3.2 FS-SAE 模型网络结构的设计

深度学习模型之所以称为黑箱模型, 就是因为其网络结构的构建, 包括隐含层层数及每个隐含层节点数的选取, 尚没有理论指导, 自由度很大, 导致各隐含层节点完全处于自适应状态, 无法赋予其物理含义, 这在只重效益不重过程的评估, 如预测类分析类任务中具有很好的应用, 但对于需要深入分析内部级联涌现机理并以此管理控制复杂系统的回溯分析任务往往无能为力. 这种情况下, 需要结合大数据、复杂网络等复杂体系分析方法, 构建具有明确军事含义的防空作战指标体系框架, 作为先验知识设计神经网络模型, 从而赋予神经网络隐含节点相对明确的物理含义, 实现神经网络模型的“白化”.

本文依次采用指标关联关系分析、功能社团挖掘及社团特征分析方法, 对初始指标集 $X = X(X_1, X_2, \dots, X_k)$ 内指标的关联涌现关系进行深入分析, 聚合出反映体系整体能力的社团特征指标集和体系功能指标集, 得到反映体系指标网络化交互涌现特点的多层指标体系结构框架, 以此作为构建深度学习模型结构的依据. 这样构建的神经网络各隐含层节点间具有相对固定的连接关系和相对明确的物理含义. 设计流程如图 2 所示.

3.2.1 基于最大信息交互算法的关联关系分析, 得到初始指标网络

网络化的作战体系决定了各指标之间网络化的关联关系, 而这种关联关系往往具有非线性、不确定性. 为此, 本文采用最大信息交互算法^[3,28]对初始指标之间的关联关系进行分析. 相对于 Pearson, Spearman 等相关性算法, 最大信息交互算法无预设参数, 具有通用性 (generality, 即对任意关系类型都有较强适用性) 和均匀性 (equitability, 对噪声的鲁棒性) 两大重要性质. 其基本思路是: 如果指标对

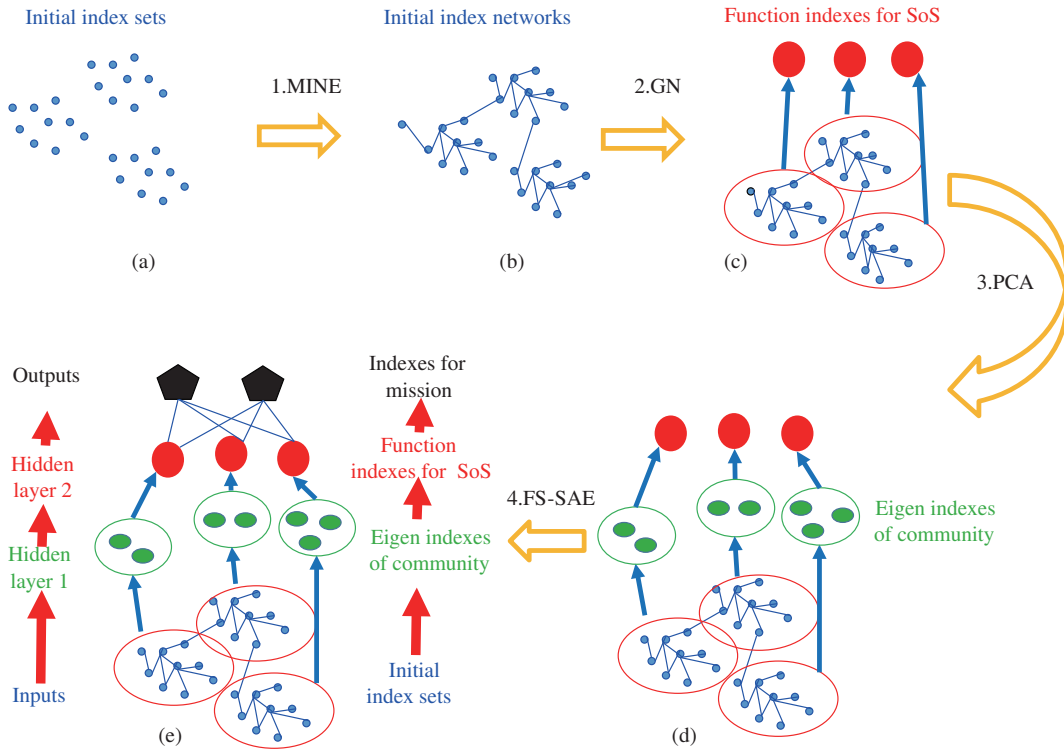


图 2 (网络版彩图) FS-SAE 模型网络结构设计流程

Figure 2 (Color online) The design route for the structure of FS-SAE model. (a) Initial index sets; (b) initial index networks; (c) function indexes for SoS; (d) eigen indexes of community; (e) multilayered structure

(X_i, X_j) 之间存在相关性, 使得所有的数据点分布在该网络的单元格中, 通过不断增加分辨率, 比较每种网格划分下所有网格的互信息值, 再对互信息值进行标准化, 其中最大的互信息标准化值即为最大信息交互系数 (maximal information coefficient, MIC). 其算法可分为以下 3 步.

(1) 如果两个指标之间存在着关联关系, 那么在此指标对的散点图上存在一个“最合适”的网格划分, 使得指标对的大多数数据点集中在该网格的几个单元格中. 因此对于划分指标对 (X_i, X_j) 坐标平面的一种 x 行 \times y 列网格 g , 定义单元格的概率密度 $p(x, y)$ 为其中样本点数量占此指标对样本总数的比例. 为了衡量指标对样本的集中程度, 定义网格 g 的交互信息值 I :

$$I = \int \int p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) dx dy, \quad (2)$$

其中 $I(X_i, X_j)$ 即网格 g 划分条件下指标对之间的关联强度.

(2) 由于网格不必等宽划分, 对于相同 x 和相同 y 的网格有多种划分方法 $G\{g_1, g_2, \dots\}$, 因此定义 G 交互信息特征值为

$$M_{x,y} = \frac{\max(I_G)}{\log(\min(x, y))}, \quad (3)$$

其中 $\max(I_G)$ 对应的网格即为“最合适”的 x 行 \times y 列网格划分方式. 由此, 遍历所有可能的 x 行 \times y 列网格去划分 n 组数据 $T_{ij} = \{(X_i, X_j), (i \neq j)\}$ 的散点图, 其中网格划分的最大分辨率满足 $3 < xy < n^{0.6}$, 可以得到指标对 (X_i, X_j) 的特征值矩阵 $M(X_i, X_j) = (M_{x,y})$.




图 3 GN 算法流程图

Figure 3 The flowchart of GN algorithm

(3) 计算最大信息系数 MIC, 指标对 (X_i, X_j) 最大信息系数即为特征值矩阵中的最大值,

$$\text{MIC} = \max(M_{x,y}), \quad (4)$$

其中 $\text{MIC} \in [0, 1]$, 数值越趋近于 1, 则表明指标间的关联关系越强.

由此, 可以计算每对指标参数之间的关联关系强度, 在此基础上构建出的初始指标网络 $F = (V, E)$, 其中节点为 $V = (X_1, X_2, \dots, X_k)$, 连边权重为 $E = (\text{MIC}_{ij})_{k \times k}$, 反映作战体系中初始指标之间复杂的关联映射关系, 如图 2(b).

3.2.2 基于复杂网络社团分析方法, 涌现得到体系功能指标集

复杂网络往往是由若干社团组成, 每个社团内部的节点之间连接相对紧密, 而各社团之间的连接相对稀疏. 初始指标网络是度量体系能力的基础, 初始指标网络的社团可以认为是作战体系围绕特定使命任务涌现的功能属性, 我们将社团所代表的功能属性定义为体系的功能指标, 因此初始指标网络有几个功能社团就可以聚合出几个高层次的体系功能指标, 如图 2(c). 这里功能社团的划分方法采用 GN 算法^[29], 其基本原理是位于社团之间的边的介数相对较大. 那么, 通过不断将社团之间的连边移除 (即网络中边介数最大的连边), 网络中最终将只剩下孤立的社团, 该算法的流程图如图 3 所示. 算法最终得到的是一个层次树状图 (dendrogram), 图的底部表示树的叶子节点, 图的“根”在顶部, 自顶而下, 随着介数最大的边不断被移除, 网络将逐渐分成多个社团, 实际计算中往往是在计算出完整的层次树状图后, 在此基础上, 寻找模块度最大的社团划分为此时初始指标网的最佳社团 $C = C_1, C_2, \dots$, 以初始指标网络的社团结构作为体系指标功能单元的划分, 获得体系功能指标 C_1, C_2, \dots

3.2.3 基于主成分分析法, 得到每个社团的特征指标集

根据社团划分算法, 社团所包含的初始指标之间具有强关联性, 为更清晰地描述社团指标与其涌现的体系功能指标之间的聚合关系, 降低初始指标之间的耦合性, 我们在社团功能指标与初始指标之间构建社团特征指标, 更紧致地表示两者之间的聚合关系, 如图 2(d). 社团特征指标定义为每个社团的特征向量, 通过主成分分析法 (principal component analysis, PCA) 计算^[30], 其主要思想是通过线性变换, 用数量相对较少的线性无关的向量来表示原始数据中较多的向量, 并且不减少原始数据中包含的主要信息, 也是一种指标聚合方式. PCA 方法能够将高维空间的问题转换为低维空间的问题, 降低了问题维度, 而且得到的特征指标之间线性无关, 又能提供原始数据的绝大部分信息, 避免了主观判断. 按照以下步骤进行计算.

(1) 通过最大信息交互算法得到 k 个指标的相关系数矩阵

$$R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nn} \end{bmatrix}. \quad (5)$$

(2) 对相关系数矩阵进行分解得到特征值和特征向量. 求特征方程 $|\lambda I - R|$ 的特征根, 将特征根从大到小排列得

$$\lambda_1 > \lambda_2 > \cdots > \lambda_n, \quad (6)$$

λ_j 对应的特征向量为

$$C_j = (C_{1j}, C_{2j}, \dots, C_{nj})^T. \quad (7)$$

(3) 计算主成分. 由特征向量组成的主成分为

$$B_j = C_{1j}X_1 + C_{2j}X_2 + \cdots + C_{nj}X_n, \quad j = 1, 2, \dots, n, \quad (8)$$

n 个主成分之间是线性无关的, 且方差是逐渐减小的.

(4) 选取主成分. 选取前 p ($1 \leq p \leq n$) 个主成分为该社团的特征指标, p 值的选择将会对评估产生直接影响, 如果 p 过大, 数据的压缩比就很低, 如果 p 过小, 则数据特征信息丢失可能会较多, 通常用主成分的累计贡献率 (前 p 个主成分对应的方差之和占 n 个方差和的比例) 来判定, 即

$$\omega_p = \frac{\sum_{j=1}^p \lambda_j}{\sum_{j=1}^n \lambda_j}, \quad (9)$$

一般要求 B_1, B_2, \dots, B_n 的方差之和占全部方差比例达到 85% 以上, 这样原有的 n 个指标就转换为 p 个指标.

3.2.4 结合使命任务指标, 得到多层网络化指标体系结构

按照以上步骤, 在具体使命任务指标牵引下, 通过对初始指标集的分析、抽取社团特征指标、定义涌现的体系功能指标, 得到分层网络化指标体系结构模型. 其可形式化表示为

$$H = (V, E), \quad (10)$$

其中节点 $V = (X, B, C, Y)$, 连边 $E = (E_X, E_{XB}, E_{BC}, E_{CY})$, X 表示初始指标层, B 表示特征指标层, C 表示体系功能指标层, Y 表示使命任务指标层, E_X 为初始指标层连边, E_{XB}, E_{BC}, E_{CY} 分别为各层间指标之间的连接关系. 体系指标网络结构模型 H 不仅表现了体系初始指标之间的复杂关联关系, 同时反映了初始指标到社团特征指标, 再到体系功能指标, 最后到使命任务指标的级联涌现关系, 为体系效能评估和体系涌现性机理研究提供了模型基础.

3.2.5 FS-SAE 模型的网络结构

以多层网络化指标体系结构为模型框架, 我们构建出如图 2(e) 所示的堆栈自编码神经网络模型 (SAE): 输入层节点为初始指标集 X , 输出层节点为使命任务指标集 Y , 第 1 和 2 隐含层节点分别为

社团特征指标集 B 和体系功能指标集 C , 以此构建出具有明确节点数和网络连接关系的神经网络结构. 与传统神经网络模型的黑箱特征不同, 这里构建的自编码神经网络, 输入层和隐含层、两隐含层之间的连接关系被社团隶属关系强制约束, 即只有社团内初始指标与其对应的社团特征指标、社团特征指标与社团功能指标之间存在连接关系, 而与其他社团的特征指标和社团功能指标之间无连接, 这就意味着两隐含层的隐含节点都与所在社团功能相关, 通过解析分析可以给予相对明确的军事含义. 与一般设置稀疏化参数的稀疏自编码神经网络 (sparsed SAE) [31] 不同, 我们定义这一模型为强制稀疏自编码神经网络模型 (force sparsed SAE, FS-SAE).

3.3 模型学习优化算法设计

FS-SAE 模型的输入层与隐含层之间采用自编码神经网络模型 (auto-encoder neural network, AENN), 从图 2(e) 可以看出, 强制稀疏后整个网络模型相当于 N 个 SAE 模块并联 (N 为输入指标网络的社团数), 然后通过逻辑回归模型 (softmax) 分类, 输出为使命任务指标. 因此, 模型设计和优化的基本单元仍以 AENN 为主.

(1) AENN 层算法设计 [32]. 我们采用 Sigmoid 函数作为 AENN 的激活函数采用, 即对于样本集 $\{x^1, x^2, \dots, x^m\}$ 中的样本 x^i , 其编码后的隐含特征表示 $y^i = f(x^i)$ 变换为

$$f(x^i) = 1/(1 + \exp(-(Wx^i + b))), \quad (11)$$

然后利用解码器对隐含表示进行重构, 计算重构信号 $z^i = f'(y^i)$, 如下所示:

$$f'(y^i) = 1/(1 + \exp(-(W'y^i + b'))), \quad (12)$$

其中, W 和 W' 分别为输入层和隐含层的权重矩阵, 通常满足约束 $W = W'$, b 和 b' 分别为输入层和隐含层的偏置向量, W, W', b 和 b' 为 AENN 的主要参数, 记为 $\theta = \{W, W', b, b'\}$.

采用负对数似然函数 (negative log-likelihood, NLL) 定义重构误差 e^i , $e^i = L(x^i, z^i, \theta)$, 其计算公式为

$$e^i = -\sum_{k=1}^d (x_k^i \log(z_k^i) + (1 - x_k^i) \log(1 - z_k^i)), \quad (13)$$

其中, d 表示样本维度. e^i 为单个样本的误差, 采用平均误差来衡量样本集的重构代价 (cost) \bar{c} , 如下所示:

$$\bar{c} = \frac{1}{M} \sum_{i=1}^M (e^i), \quad (14)$$

其中, M 为一个样本集中样本的数量.

(2) 分类器构建. 本文选择 Softmax 分类器作为隐含层与输出层的逻辑回归函数, Softmax 函数具有收敛速度快、计算精度高和容易与 AENN 网络级联等优点. Softmax 函数的基本原理如式 (15) 所示.

$$h_{\theta}[x(i)] = \begin{bmatrix} p(y^i = 1)|x^i; \theta \\ p(y^i = 2)|x^i; \theta \\ \vdots \\ p(y^i = k)|x^i; \theta \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x(i)}} \begin{bmatrix} e^{\theta_1^T x(i)} \\ e^{\theta_2^T x(i)} \\ \vdots \\ e^{\theta_k^T x(i)} \end{bmatrix}, \quad (15)$$

FS-SAE 模型的优化算法仍然采用 SAE 模型的随机梯度下降算法, 而在训练优化时每个 AENN 子模块各自计算更新参数.

(3) FS-SAE 的优化算法. FS-SAE 模型采用随机梯度下降 (stochastic gradient descent, SGD) 算法^[33], 其核心思想是从全样本空间中随机抽取一个较小的样本子集 $B = \{x^1, x^2, \dots, x^{M_B}\}$, 通过计算子集 B 中 M_B 个样本的梯度, 估计全样本空间梯度的期望值, 如下所示:

$$g = \frac{1}{M_B} \sum_{i=1}^{M_B} \nabla_{\theta} L(x^i, y^i, \theta). \quad (16)$$

可见, 由于样本子集 B 是从样本空间中随机采样得到的, 只要保证样本子集 B 具有良好的分布特性, 就能确保 g 较好地代表全样本空间梯度的期望值; 而通常又存在 $M_B \ll M$, 因而大大降低了算法的计算复杂度.

通过以上构建过程可以看出, FS-SAE 评估模型以大数据和网络分析获取的先验知识为基础进行构建, 通过减少网络模型连边优化模型算法, 得到相对稳定的级联涌现关系, 并实现了对涌现过程的形式化描述, 为进一步分析作战体系效能涌现性机理提供了可能.

3.4 基于 FS-SAE 的防空体系能力回溯分析模型

FS-SAE 模型将防空作战体系的指标与使命任务指标之间的函数映射关系通过神经网络的形式表示出来, 为回溯分析指标涌现机理、体系贡献度, 并进一步管理和控制防空作战体系提供了依据. 下面基于 FS-SAE 模型形式化表示体系指标的涌现关系, 以此为防空体系能力回溯分析模型分析体系涌现性机理, 并对体系贡献度进行分析.

3.4.1 社团功能指标模型涌现性机理分析

依据 FS-SAE 模型定义, 各社团 AENN 层内输入节点对隐含层点的涌现计算公式可形式化表示为

$$h_{nj}^i = f_{nj}(x^i) = 1/(1 + \exp(-(W_{nj}x^i + b_{nj}))), \quad (17)$$

其中 $n = 1, 2$, 分别代表第 1 隐含层社团特征指标和第 2 隐含层体系功能指标. 通过社团指标之间的映射关系, 我们可以确定社团结构内初始指标对社团特征指标, 社团特征指标对体系功能指标的涌现形式. 需要强调的是, 这里隐含节点 h 的取值状态只有两个, 分别为 0 和 1, 而公式计算结果为隐含层涌现性指标取 1 的概率, 因此严格来讲, 公式计算得到的是涌现性指标的期望值, 即

$$E(h_{nj}^i) = 1/(1 + \exp(-(W_{nj}x^i + b_{nj}))). \quad (18)$$

这种概率表现形式很好地表示了复杂体系能力涌现过程的不确定性, 且为分析能力指标取值范围和分布特征 $P(E(h_{nj}^i))$ 提供了方法.

3.4.2 社团功能指标的体系贡献率分析

依据 FS-SAE 防空体系能力回溯分析模型, 体系功能指标与使命任务指标之间的关系可以表达为

$$y_{\theta}^k[h_2(i)] = \frac{e^{\theta_k^T h_2(i)}}{\sum_{j=1}^k e^{\theta_j^T h_2(i)}}, \quad (19)$$

其中 $y_{\theta}^k[h_2(i)]$ 是在样本 x^i 条件下, 使命任务指标 y_{θ}^k 的期望值. 在此基础上, 我们定义隐含层涌现性指标对使命任务指标的相对贡献度为

$$\rho(y_i : h_j) = \frac{\Delta y_i}{y_i \Delta h_{2j}} = \frac{\partial y_i / \partial h_{2j}}{y_i}. \quad (20)$$

可以证明

$$\rho(y_i : h_j) = \theta_i^j (1 - E(y_i)), \quad (21)$$

其中 θ_i^j 为涌现性指标到使命任务指标的连接权值. 因此, FS-SAE 评估模型中, 涌现性指标的体系相对贡献率与指标间的连接权值和使命任务指标的期望值相关, 通过测量体系功能指标与使命任务指标的响应关系, 可以实现对于防空体系使命任务的完成能力的监控, 进而辅助指挥员管理和控制防空作战体系朝着有利的方向发展.

4 基于兵棋仿真数据的实验验证

4.1 数据来源和想定背景

(1) 数据来源. 本文实验数据分别来自于“人在回路”的兵棋演习和“人不在回路”的仿真试验床. 基于“人在回路”的兵棋推演数据包含了体系对抗过程产生的全维度、全要素和全样本数据, 同时包含了人的认知和指控行为、多方博弈产生的对抗数据, 是目前在缺少实际作战数据的情况下最接近实战的作战数据, 但受限于演习场次, 数据量有限; 基于“人不在回路”的体系仿真试验床实验可在既定想定背景下, 通过“增、减、改”焦点装备和关键行动来进行多次快速仿真, 从而获取海量体系对抗数据, 其缺点是对抗过程按照计划执行, 不能很好地反映人的认知. 本文以“人在回路”的兵棋推演确定作战方式、作战行动和使命任务, 以此为基本想定背景和条件, 利用仿真试验床进行大量仿真实验, 获取海量数据实现对作战体系的效能评估.

(2) 想定背景. 以兵棋演习中典型的“要点防护”防空作战为背景, 在仿真试验床平台上构建防空作战想定^[3], 如图 4(a) 所示. 想定中, 红方作战目标是防卫指挥所不被摧毁. 通过不断改变蓝方空袭机群作战飞机的基本性能、挂载的空空导弹和空地导弹的发射距离、空袭机群的高度、密度、突入方向、指挥通信协同网络以及加入预警机指挥、电子战机电磁干扰等因素来检验红方防空体系的自适应和涌现性能力, 进行 6000 次仿真实验.

(3) 指标集和样本集的确定. 仿真实验中, 防空武器装备体系生成的海量数据以各个分系统指标参数的形式记录下来, 指标参数大体可分为侦察预警类数据 (如防空体系探测识别敌机数量、距离时间等)、情报处理类数据 (如防空体系的情报收集、处理、分发时间等)、火力交战类数据 (如防空体系地面、海上、空中战损装备数量、拦截敌机数量等)、电磁对抗类数据 (如防空体系受干扰的各类装备数量及性能变化等) 和通信类数据 (如防空体系通信网数量、通信量等) 等, 同时考虑一些典型的体系能力状态指标 (如各类部队实力数、各类兵器火力的性能对比等) 和网络结构类指标^[8,9,34] (如网络效率、可达性、不同网络模体数量、网络聚集系数、平均时间效率等), 共选取 168 个指标, 其中确定指挥所是否被摧毁作为体系的使命任务指标 (Y), 其余 167 指标作为初始指标集构建数据样本集 $T = \{X_1, X_2, \dots, X_{167}\}_{6000}$, 并对数据样本集进行归一化处理.

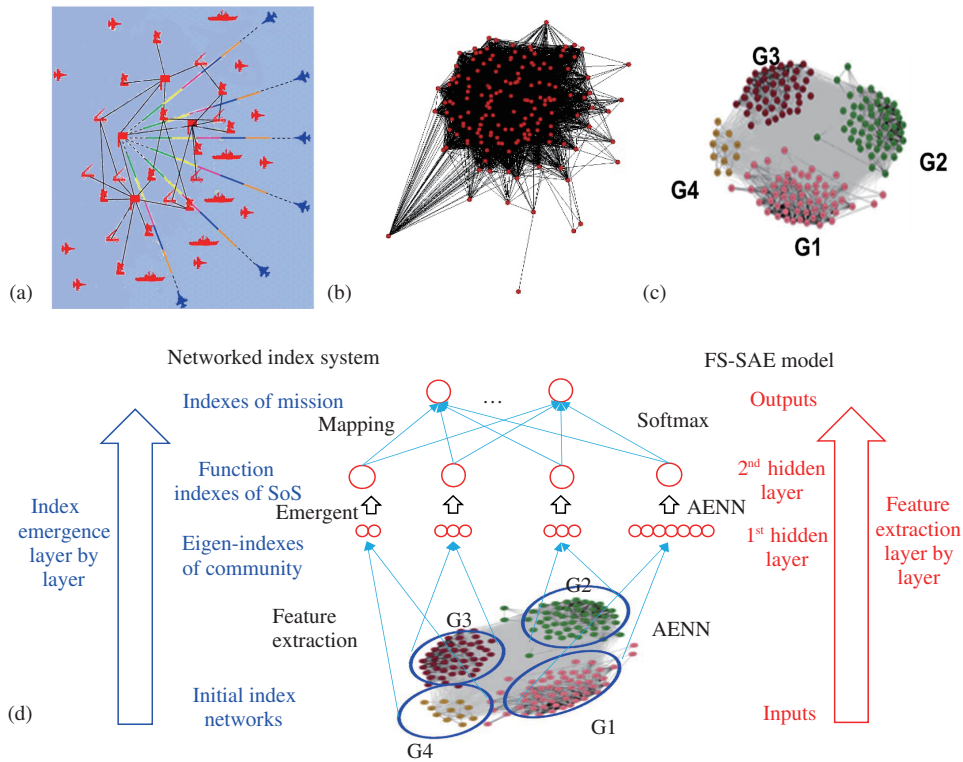


图 4 (网络版彩图) 想定背景及网络指标体系模型构建

Figure 4 (Color online) Scenario setting and the construction of the networked index system of ADSOS. (a) Illustration of scenario setting; (b) initial index networks; (c) index network communities; (d) multilayer networked index system

表 1 防空指标间最大交互信息强度值
Table 1 MICs between the initial indexes

Index	X1	X2	X3	X4	X5	X6	...
X2	0.22279						...
X3	0.24872	0.87671					...
X4	0.23126	0.51958	0.71057				...
X5	0.24557	0.51958	0.55146	0.43817			...
X6	0.95095	0.40619	0.24412	0.50126	0.99107		...
...

4.2 网络化指标体系的构建

(1) 指标关联关系分析. 基于最大交互信息强度算法, 对表征防空体系的 167 个初始指标进行关联关系挖掘, 得到防空指标间最大交互信息强度值如表 1 所示. 以初始指标为节点, 以关联关系强度为连接权重, 构建出初始指标网络, 如图 4(b) 所示.

(2) 体系功能指标和社团特征指标选取. 采用 GN 模型对输入指标网络进行社团划分, 得到稳定的 4 个社团 G_1, G_2, G_3, G_4 , 如图 4(c) 所示, 分别包含 59, 52, 45, 11 个初始指标. 其中 G_1 社团的指标主要包含防空装备间的指挥通信量、情报传输量及处理效率、防空兵器参战率等与指挥信息相关的

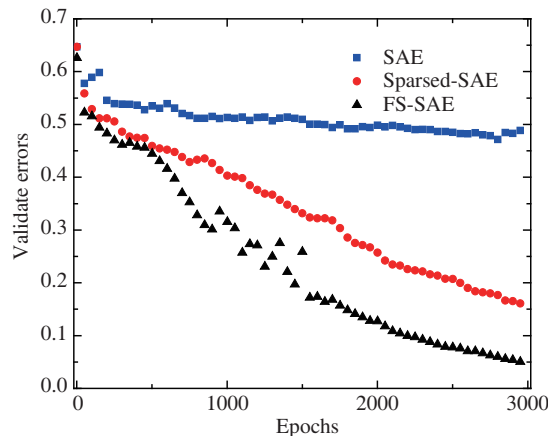


图 5 (网络版彩图) 不同模型算法的收敛性比较

Figure 5 (Color online) Convergence comparison of different algorithms

性能指标参数, G_2 社团主要有探测率、防区突防率、拦截率、战损率、武器平台发射数量等与体系一体化火力打击相关的参数, G_3 社团主要包括红方地面防空部队实力、模体数量、红方出动各型飞机总数、红方感知到的蓝方干扰机开机数量等结构力量类指标, G_4 社团主要包括首次接敌时间和距离、首次开火打击时间和距离、作战 OODA 时间、红方平均对每架飞机采取的行动次数、网络效率等与体系反应能力性能相关的指标. 在方差贡献率阈值为 85% 的条件下, 分别得到 4 个社团特征指标数分别有 6, 3, 2 和 3 个, 而每个特征指标均来自于所在社团输入指标的涌现.

(3) 模型网络结构. 这 4 个社团所代表的功能分别反映了防空体系作战中 4 个关键整体性效能: 体系指控效能、体系一体化打击效能、结构力量效能和体系敏捷性效能. 从中可以看出, 采用复杂网络社团分析方法得到的 4 个社团实际上代表了防空体系高层次抽象的 4 大功能模块, 对应防空体系作战中 4 个体系功能指标, 分别定义为指控效能相关指标 (C_1)、一体化打击效能相关指标 (C_2)、结构力量相关指标 (C_3) 和体系敏捷性效能相关指标 (C_4). 至此, 我们构建出了从初始指标 (X) \rightarrow 社团特征指标 (B) \rightarrow 体系功能指标 (C) \rightarrow 使命任务指标 (Y) 这一防空作战体系效能评估的指标网络化体系结构模型, 如图 4(d) 所示, 在此基础上, 构建 4 层强制稀疏自编码神经网络, 其输入层为 167 维的初始指标集, 第 1 隐含层包含 4 个社团共 14 维的社团特征指标集, 第 2 隐含层包含 4 个社团代表的 4 维体系功能指标集, 输出层为 1 维的使命任务指标 Y , 顶层分类器设计为逻辑回归函数, 将数据样本集 T 随机分为训练集 (4000 组)、测试集 (1000 组) 和验证集 (1000 组).

4.3 FS-SAE 模型的优化训练

作为对比, 我们增加了两个网络结构相同、优化算法不同的对比模型, 一个是未做任何处理的 SAE 模型, 一个是增加稀疏系数的 Sparsed-SAE 模型. 从图 5 可以看到: 稀疏化后的 SAE 模型明显比未作任何处理的模型收敛速度更快、准确率更高; 强制稀疏自编码网络由于加入了符合数据分布特征的先验知识, 模型的性能明显强于传统稀疏自编码神经网络, 其校验误差可以达到 5% 以下.

训练完成的模型对训练样本集和测试样本集中的样本进行识别, 统计 FS-SAE 和 Sparsed-SAE 模型判断准确率, 如表 2 所示.

由表 2 可见, 采用 FS-SAE 模型, 对训练样本的识别准确率达 95%, 具有良好的收敛性能; 同时, 该模型对测试样本的识别准确率达 82%. 对于 Sparsed-SAE 而言, 训练集和测试集的识别精度分别达

表 2 FS-SAE 模型对使命任务判断的准确率
Table 2 The accuracy of FS-SAE models for the mission

Model	Training set accuracy (%)	Testing set accuracy (%)
FS-SAE	95	82
Sparsed-SAE	84	73

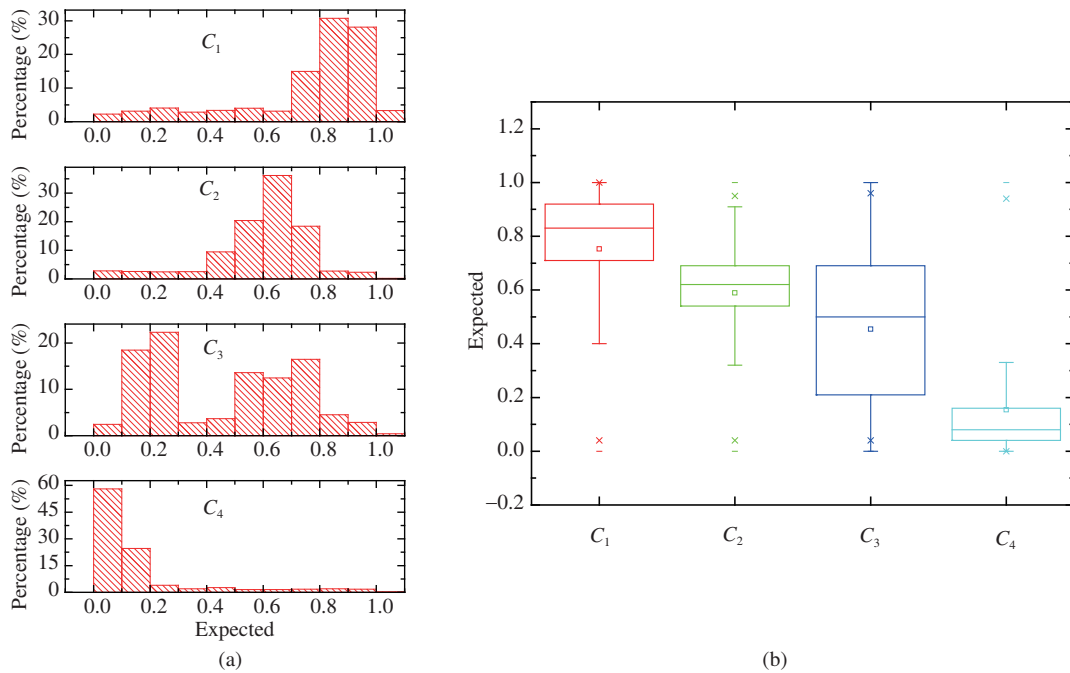


图 6 (网络版彩图) 体系功能指标期望值分布情况

Figure 6 (Color online) The distribution of function index expectation of ADSOS. (a) The probability of function index expectation; (b) the range and the average value of function index expectation

到 84% 和 73%, 低于相应的 FS-SAE 模型. 可见, FS-SAE 模型能够以较高的精度实现对使命任务完成度的判断. 同时, 该模型结构考虑了基于大数据、复杂网络等体系分析得到的先验知识, 其节点作为涌现类指标, 不仅被赋予了相对明确的军事含义, 还可以通过模型的连接权重量化级联涌现关系, 为解决作战体系能力指标涌现生成机理和体系能力贡献率分析提供了基础.

4.4 基于 FS-SAE 回溯分析模型的体系功能指标模型分析和体系贡献率分析

我们将样本数据输入到训练完成的 FS-SAE 模型中, 利用式 (18) 得到体系功能指标的期望值. 通过数据统计分析的方法, 得到在使命任务指标取值为 1, 即防护要点未被摧毁的情况下, 4 个体系功能指标期望值的分布情况如图 6(a) 所示. 其中 C₁ 为指控效能相关指标, C₂ 为一体化打击效能相关指标, C₃ 为结构力量相关指标, C₄ 为体系敏捷性效能相关指标.

同时, 我们得到 4 个指标期望值的平均值和取值区间, 如图 6(b) 所示. 从图 6 可以看出, 对抗条件下体系功能指标取值不是单一值, 而是具有一定取值区间的结果云, 而结果云的相对集中程度则反映了在数据样本空间分布内体系功能指标对体系任务完成度的评判准确度和对使命任务指标响应的灵敏度. 图 6 可以看出, 基于我们的数据训练得到 FS-SAE 模型, 得到 C₄ 即体系敏捷性功能指标对任

务完成度评估的灵敏性最高.

利用式 (20), 进一步计算体系功能指标对使命任务完成度的相对贡献度, 其主要与 FS-SAE 模型分类器的连接权重系数和指标平均期望值相关, 在训练完成的模型中, softmax 分类器的连接权重 (w_1, w_2, w_3, w_4) 取值为

$$(w_1, w_2, w_3, w_4) = (2.21, 1.17, 0.34, -4.05),$$

而 4 个体系功能指标平均期望值分别为 $(0.75, 0.59, 0.49, 0.15)$, 由此得出 4 个功能指标对使命任务指标的贡献度分别为

$$\rho(y = 1 : C_1) = 0.55,$$

$$\rho(y = 1 : C_2) = 0.48,$$

$$\rho(y = 1 : C_3) = 0.17,$$

$$\rho(y = 1 : C_4) = -3.44.$$

从中可以得出以下结论: 与体系敏捷性相关效能指标 (C_4) 对防空体系贡献最大, 且与使命任务负相关, 而体系结构力量指标相对贡献率较小.

在这里需要强调的是, 这样的结果并不代表实际武器装备体系中结构力量相关效能指标对防空体系不重要, 而恰恰反映出实验结果与背景想定设定和数据采集的一致性. 在仿真实验的想定中, 红方防空体系的力量部署和编成结构基本不变, 变化较大的是蓝方飞行编队的规模、航向、高度等参数及红方防空体系侦察、指控、信息、火力等相关参数. 在这样的对抗中, 防空体系的反应速度和指控效能对体系防空能力的作用相对更加突出, 从而验证了我们模型在回溯分析体系能力形成机制方面的有效性. 从另一个方面来说, 基于仿真大数据和深度学习的体系能力分析往往与想定任务和所采集数据样本分布特征密切相关, 这反映了体系对抗和自适应所带来的体系能力相对性和不确定性, 同时提醒我们数据样本采集的目的性和完备性同样会对体系能力分析带来人为的影响.

5 结论

本文以联合作战条件下的防空体系作战为背景, 以兵棋推演和仿真试验床产生的海量数据为基础, 以大数据和复杂网络分析得到的多层网络化指标体系模型框架作为先验知识, 构建了基于强制自编码神经网络的防空作战体系能力回溯分析模型, 实现了网络化指标体系涌现关系的形式化表示、体系功能指标涌现机理分析及其对使命任务相对贡献度的计算. 通过仿真实验数据验证表明, FS-SAE 模型不仅具有比传统稀疏自编码神经网络 (sparsed SAE) 更高的预测准确率, 同时还赋予了模型隐含节点相对明确的物理含义, 为深度分析认知防空体系各功能模块对使命任务完成度的作用及影响机理提供了一种可行的方案, 为辅助指挥员监控、管理并控制防空作战体系提供了有效手段. 在下一步的工作中, 我们将引入时序机制、注意力机制等模型, 进一步深入分析防空作战体系的动态演化特性及体系指标在动态条件下的涌现性和贡献度问题.

参考文献

- 1 Hu X F. On War System Engineering: Methodology Towards to Information Age's War. Beijing: University of National Defense Press, 2013. 200-413 [胡晓峰. 战争工程论: 走向信息时代的战争方法学. 北京: 国防大学出版社, 2013. 200-413]

- 2 Hu X F, Rong M. Joint operation planning systems: issues and prospects. *J Command Control*, 2017, 3: 273–280 [胡晓峰, 荣明. 关于联合作战规划系统的几个问题. *指挥与控制学报*, 2017, 3: 273–280]
- 3 Yao X Y, Guo S M, Hu X F, et al. Construction for air defense system of systems based on MINE-FNA assembled algorithm. *Command Control Simul*, 2016, 1: 94–100 [姚晓毅, 郭圣明, 胡晓峰, 等. 基于 MINE-FNA 组合算法的防空体系指标网构建方法研究. *指挥控制与仿真*, 2016, 1: 94–100]
- 4 Tolk A. The next generation of modeling & simulation: integrating big data and deep learning. In: *Proceedings of the Conference on Summer Computer Simulation, Chicago*, 2015
- 5 Tannahill B K, Jamshidi M. System of systems and big data analytics — bridging the gap. *Comput Electr Eng*, 2014, 40: 2–15
- 6 Hu X F, He X Y, Xu X L. 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. *Sci Sin Inform*, 2014, 44: 676–692 [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 期新观点新学说沙龙综述. *中国科学: 信息科学*, 2014, 44: 676–692]
- 7 Zhang B, Hu X F, Wang Y, et al. Rudimental research of analysis of system of systems exceptional state. *J Syst Simul*, 2011, 23: 2494–2499 [张斌, 胡晓峰, 王燕, 等. 体系异常状态分析的初步研. *系统仿真学报*, 2011, 23: 2494–2499]
- 8 Wu W F, Hu X F. Capacity evaluation of networked operational system of systems based on big data. *Mil Oper Res Syst Eng*, 2016, 30: 26–32 [伍文峰, 胡晓峰. 基于大数据的网络化作战体系能力评估框架. *军事运筹与系统工程*, 2016, 30: 26–32]
- 9 Wu W F, Hu X F, Guo S M, et al. Analysis of combat SoS coordination based on multi-layered temporal networks. *Complex Syst Complex Sci*, 2017, 14: 1–10 [伍文峰, 胡晓峰, 郭圣明, 等. 基于多层时序网络的作战体系协同分析. *复杂系统与复杂性科学*, 2017, 14: 1–10]
- 10 Yao X Y, Guo S M, Hu X F, et al. Design evaluation indices for air defense systems based on RF-GLR integrated machine learning algorithms. *J Command Control*. 2015, 1: 269–277 [姚晓毅, 郭圣明, 胡晓峰, 等. 基于 RF-GLR 组合机器学习算法的防空体系能力指标挖掘方法研究. *指挥与控制学报*, 2015, 1: 269–277]
- 11 Hu X F, Zhang Y, Li R J, et al. Capability evaluating problem of networking SOS. *Syst Eng Theory Pract*, 2015, 35: 1317–1323 [胡晓峰, 张昱, 李仁见, 等. 网络化体系能力评估问题. *系统工程理论与实践*, 2015, 35: 1317–1323]
- 12 Ding J F, Si G Y, Yang G Q, et al. Visualization analysis of the capability of weapon system of systems for multi-dimensional indicators. *J Syst Eng Electron*, 2017, 28: 292–300
- 13 Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search. *Nature*, 2016, 529: 484–489
- 14 Brown N, Sandholm T. Superhuman AI for heads-up no-limit poker: libratus beats top professionals. *Science*, 2018, 359: 418–424
- 15 Elaraby N M, Elmogy M, Barakat S. Deep learning: effective tool for big data analytics. *Int J Comput Sci Eng (IJCSE)*, 2016, 5: 254–262
- 16 Hu X F, Guo S M, He X Y. Challenges to intelligent command information system: reason and revelation on deep green plan and AlphaGo. *Command Inf Syst Technol*, 2016, 7: 1–7 [胡晓峰, 郭圣明, 贺筱媛. 指挥信息系统的智能化挑战 —— “深绿” 计划及 AlphaGo 带来的启示与思考. *指挥信息系统与技术*, 2016, 7: 1–7]
- 17 Guo S M, He X Y, Hu X F, et al. Challenges and trends in intelligent military information system. *Control Theory Appl*, 2016, 33: 1562–1571 [郭圣明, 贺筱媛, 胡晓峰, 等. 军用信息系统智能化的挑战与趋势. *控制理论与应用*, 2016, 33: 1562–1571]
- 18 Tao J Y, Wu L, Hu X F. Principle analysis on AlphaGo and perspective in military application of artificial intelligence. *J Command Control*, 2016, 2: 114–120 [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. *指挥与控制学报*, 2016, 2: 114–120]
- 19 Goodfellow I, Bengio Y, Courville A. *Deep Learning*. Cambridge: MIT press, 2016
- 20 Lee M, Bressler S, Kozma R. Advances in cognitive engineering using neural networks. *Neur Netw*, 2017, 92: 1–2
- 21 Chen Q J, Song X, Yamada H, et al. Learning deep representation from big and heterogeneous data for traffic accident inference. In: *Proceedings of the 30th AAAI Conference on Artificial Intelligenc*, Phoenix, 2016. 338–344
- 22 Angermueller C, Pärnamaa T, Parts L, et al. Deep learning for computational biology. *Mol Syst Biol*, 2016, 12: 878
- 23 Zhang L, Liu Z, Zhang J Q, et al. Reduction method of weapon system of systems assessment index system based on autoencoder. *J Cent South Univ (Sci Technol)*, 2013, 44: 4130–4137 [张乐, 刘忠, 张建强, 等. 基于自编码神经网络的装备体系评估指标简约方法. *中南大学学报*, 2013, 44: 4130–4137]

- 24 Ou W, Liu S J, He X Y, et al. Tactical intention recognition algorithm based on encoded temporal features. *Command Control Simul*, 2016, 38: 36–41 [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. *指挥控制与仿真*, 2016, 38: 36–41]
- 25 Luong M T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation. In: *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, Lisbon, 2015. 1412–1421
- 26 Sukhbaatar S, Weston J, Fergus R. End-to-end memory networks. In: *Proceedings of Advances in Neural Information Processing Systems*, Montreal, 2015. 2440–2448
- 27 Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning. *Nature*, 2015, 518: 529–533
- 28 Reshef D N, Reshef Y A, Finucane H K, et al. Detecting novel associations in large data sets. *Science*, 2011, 334: 1518–1524
- 29 Girvan M, Newman M E J. Community structure in social and biological networks. *Proc Natl Acad Sci USA*, 2002, 99: 7821–7826
- 30 Martinez A M, Kak A C. PCA versus LDA. *IEEE Trans Pattern Anal Mach Intel*, 2001, 23: 228–233
- 31 Meng L H, Ding S F, Zhang N, et al. Research of stacked denoising sparse autoencoder. In: *Neural Computing and Applications*. Berlin: Springer, 2016. 1–18
- 32 Bengio Y. Deep Learning Tutorial. 2014. <http://deeplearning.net>
- 33 Zhou X, Guo J Q, Wang S L. Motion recognition by using a stacked autoencoder-based deep learning algorithm with smart phones. In: *Proceedings of International Conference on Wireless Algorithms, Systems, and Applications*, Qufu, 2015. 778–787
- 34 Wu W F, Hu X F, Guo S M, et al. Methods of analyzing combat SoS coordination pattern based on temporal motif. In: *Proceedings of Asian Simulation Conference*, Beijing, 2016. 544–554

Backtracking analysis approach for effectiveness of air defense operation system of systems based on force-sparsed stacked-autoencoding neural networks

Shengming GUO*, Xiaoyuan HE, Lin WU & Xiaofeng HU

Joint War College, National Defense University of PLA, Beijing 100091, China

* Corresponding author. E-mail: guosm04@mails.thu.edu.cn

Abstract To reduce the difficulty of traditional data-mining methods in deep analysis of emerging capacity index mechanisms for a complex air defense system of systems (ADSOS), a novel backtracking analysis approach based on force-sparsed stacked-autoencoding (FS-SAE) neural networks is proposed. Using the method of big-data correlation analysis, community structure analysis in complex networks, and principle component analysis based on the mission task, the networked structure of an index system for ADSOS, which was a relatively complete architecture with a well-defined meaning, was obtained. An FS-SAE backtracking analysis model was build based on heuristic knowledge from the obtained networked index system structure. The emerging relations between the capacity indices of an ADSOS were formalized. Then, the formation mechanism and contribution rate of capacity indices were studied, and the validity of this approach was validated by the simulation data. The experimental results show that formalized presentation for the emergence process of capacity indices of ADSOS based on the proposed model not only reflects the complexity characteristics of nonlinearity and uncertainty in the emergence process, but also give a general defined meaning for the index structure of the ADSOS. It provides a feasible method for commanders to deeply understand, manage, and control the complex operation system of systems.

Keywords operational system of systems, effectiveness assessment, deep learning, emergence, indices, contribution rate



Shengming GUO was born in 1981. He received a Ph.D. degree in physics from Tsinghua University, Beijing, in 2009. He is a post-doctor in Joint War College, National Defense University in China. His research interests include situation awareness, war gaming simulation, military operation research, and intelligent decision-making.



Xiaoyuan HE was born in 1968. She received a Ph.D. degree in military operation research from the National Defense University, Beijing, in 2009. Currently, she is a professor at the Joint War College, National Defense University in China. Her research interests include war gaming simulation, military operation research, and intelligent decision-making.



Lin WU was born in 1974. He received a Ph.D. degree in military operation research from the National Defense University, Beijing, in 2004. He is a professor at the Joint War College, National Defense University in China. His research interests include war gaming, military information systems, and complex systems and networks.



Xiaofeng HU was born in 1957. He is a professor at the Joint War College, National Defense University in China. His research interests include military simulation, military information systems and complex system engineering.