

12-12-2019

Characteristic Index Digging of Combat SoS Capability Based on Machine Learning

Yongli Yang

1.College of Joint Operation, National Defense University, Beijing 100091, China;;2. PLA 65183 troops, Liaoyang 111200, China;

Xiaofeng Hu

1.College of Joint Operation, National Defense University, Beijing 100091, China;;

Rong Ming

1.College of Joint Operation, National Defense University, Beijing 100091, China;;

Xiaojing Yin

1.College of Joint Operation, 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.

Characteristic Index Digging of Combat SoS Capability Based on Machine Learning

Abstract

Abstract: Aiming at the two difficulties in characteristic index digging of combat system of systems (CSoS), namely operation data generation and digging method selection, *this paper proposes a new digging method, that is, using the simulation testbed to generate operation data, then adopting the machine learning to dig characteristic index*. Two methods of characteristic index digging based on machine learning are researched: (1) *the method based on network convergence*, divides the communities for fundamental indexes based on their relationship, and obtains the characteristic indexes by principal component analysis (PCA); this method is applied to dig the characteristic indexes of air defense ability. (2) *the method based on ensemble learning*, generates test data by bagging, trains model by CART decision trees, and obtains the characteristic indexes by PCA; this method is applied to dig the characteristic indexes of air defense breakthrough ability.

Keywords

combat system of systems (SoS), capability, characteristic index digging, simulation testbed, machine learning

Authors

Yongli Yang, Xiaofeng Hu, Rong Ming, Xiaojing Yin, and Wenxiang Wang

Recommended Citation

Yang Yongli, Hu Xiaofeng, Rong Ming, Yin Xiaojing, Wang Wenxiang. Characteristic Index Digging of Combat SoS Capability Based on Machine Learning[J]. Journal of System Simulation, 2019, 31(6): 1048-1054.

基于机器学习的作战体系能力特征指标挖掘

杨永利^{1,2}, 胡晓峰¹, 荣明¹, 殷小静¹, 王文祥²

(1. 国防大学联合作战学院, 北京 100091; 2. 65183 部队, 辽宁 辽阳 111200)

摘要: 针对当前作战体系能力特征指标挖掘存在的两个困难: 作战数据生成和挖掘方法选择, 提出“先采用仿真试验床生成作战数据, 再利用机器学习挖掘特征指标”的方法。研究了 2 种基于机器学习的特征指标挖掘方法: 基于网络聚合的方法, 依据基础指标的相关性进行社团划分, 利用主成分分析法得到特征指标, 应用该方法挖掘防空能力的特征指标; 基于集成学习的方法, 利用装袋法生成测试数据集和 CART 决策树训练模型, 利用主成分分析法得到特征指标, 应用该方法挖掘防突入能力的特征指标。

关键词: 作战体系; 能力; 指标挖掘; 仿真试验床; 机器学习

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X(2019)06-1048-07

DOI: 10.16182/j.issn1004731x.joss.19-0238

Characteristic Index Digging of Combat SoS Capability Based on Machine Learning

Yang Yongli^{1,2}, Hu Xiaofeng¹, Rong Ming¹, Yin Xiaojing¹, Wang Wenxiang²

(1. College of Joint Operation, National Defense University, Beijing 100091, China; 2. PLA 65183 troops, Liaoyang 111200, China)


Abstract: Aiming at the two difficulties in characteristic index digging of combat system of systems (CSoS), namely operation data generation and digging method selection, *this paper proposes a new digging method, that is, using the simulation testbed to generate operation data, then adopting the machine learning to dig characteristic index.* Two methods of characteristic index digging based on machine learning are researched: (1) *the method based on network convergence*, divides the communities for fundamental indexes based on their relationship, and obtains the characteristic indexes by principal component analysis (PCA); this method is applied to dig the characteristic indexes of air defense ability. (2) *the method based on ensemble learning*, generates test data by bagging, trains model by CART decision trees, and obtains the characteristic indexes by PCA; this method is applied to dig the characteristic indexes of air defense breakthrough ability.

Keywords: combat system of systems (SoS); capability; characteristic index digging; simulation testbed; machine learning

引言

随着作战形态的演化、武器装备的发展, 作战

体系构建及其能力评估已成为军事领域研究的重点和热点^[1]。作战体系能力特征指标是指与作战体系具体能力关系密切、蕴含信息量大的指标, 对于作战体系能力研究起到聚焦关键中心、降低问题维度的作用。特征指标来源于基础指标, 但与体系能力关系更为紧密, 更具代表性。现代作战体系庞大复杂, 指标数量众多, 指标间的关联关系错综复杂^[2-3], 不能再依靠经验总结得到特征指标, 而应



收稿日期: 2019-05-28 修回日期: 2019-06-10;
基金项目: “十三五”装备预研项目(41401030303);
作者简介: 杨永利(1988-), 男, 山西新绛, 博士后, 工程师, 研究方向为作战模拟、军事运筹; 胡晓峰(1957-), 男, 山东栖霞, 硕士, 教授, 博导, 少将, 研究方向为军事运筹与军事系统工程、战争模拟等; 荣明(1978-), 男, 山东淄博, 博士生, 高工, 上校, 研究方向为计算机战争模拟, 军事运筹等。

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

• 1048 •

从“整体、动态、对抗”的角度, 将定性研究与定量研究相结合来获得。从这个角度来讲, 作战体系的特征指标挖掘亟需解决 2 个问题: (1) 如何生成反映作战体系特征的数据; (2) 选择何种方法对作战数据进行挖掘。

作战数据的来源主要包括战争、实兵演习演练、兵棋推演、仿真试验床等。其中, 仿真试验床基于精准模型数据(包括装备、气象、地理等参数), 能够按需求、高效率、低成本、全要素地模拟作战过程, 并完整地记录各类数据, 成为生成作战数据的有力手段。由国防大学胡晓峰教授团队研发的 XXXX 体系仿真试验床(简称“体系仿真试验床”), 考虑体系的复杂性、非线性和涌现性, 从“整体、动态、对抗”的角度, 实现对作战体系的装备及其自主行为、装备间的复杂网络关系进行建模仿真^[4]。基于体系仿真试验床, 通过构建想定模型、实施想定仿真、记录想定数据, 能够生成反映体系特征的作战数据。

体系仿真试验床生成的作战大数据蕴含丰富的作战体系知识, 包括指标间的关联关系、体系能力的特征指标等。单纯依靠人工很难挖掘作战大数据的潜在信息, 机器学习提供一种新途径。机器学习融合统计学、运筹学、计算机等多个学科, 依靠计算机强大的计算能力, 利用有监督或无监督的算法分析样本数据特征, 学习样本蕴含知识, 能够模拟人的思考或者按照人设计的方法(可公式化表达)思考, 实现了智能推理、识别等功能。机器学习在部分领域展示出超人的能力, 如 AlphaGo 在围棋上的造诣。机器学习的常用算法包括回归算法、贝叶斯方法、基于核的算法、聚类算法、人工神经网络、集成算法等, 已成为国内外研究的重点^[5]。

作者所在的课题组在此方面进行了深入研究^[2-3,6-7], 在利用体系仿真试验床生成作战数据的基础上, 探索了两种机器学习算法(网络聚合和集成学习)在特征指标挖掘上的应用, 下面予以介绍。

1 基于网络聚合的作战体系能力特征指标挖掘

大多数复杂系统, 如电力系统、社交系统、交通系统等, 可看作复杂网络进行建模分析。复杂网络由众多节点以及节点间的连边构成, 节点代表系统中的个体, 连边代表个体间的关系, 具有小世界特性和无标度特性。作战体系作为典型的复杂系统, 内部存在复杂关系。把作战指标视为节点, 把指标间关系用量化的连边表示, 将复杂网络的研究成果应用于作战体系研究, 能够挖掘更多潜在信息。

采用复杂网络分析方法构建作战体系能力指标的基本流程是, 首先利用相关性分析方法计算指标间的相关度值, 然后利用社团算法对指标进行聚合, 最后利用主成分分析法得到各社团含有的主成分信息, 最终得到特征指标。该方法充分发挥 3 种算法的优势, 环环相扣, 逐层分解问题, 最终解决问题。

1.1 指标相关性分析方法

相关性分析用于度量各指标(节点)间的相关程度, 分为线性和非线性分析方法。互信息相关系数法是一种非线性相关性分析方法, 对指标间的关系类型要求低, 对噪音不敏感, 得到广泛应用。其基本原理是, 将指标对所在的二维散点图进行网格划分, 寻找使指标对分布最密集的划分^[8], 算法的步骤如下:

(1) 给定划分网格的行数 x 、列数 y , 将待分析数据集划分为网格表, 计算互信息值 I :

$$I(X_i, X_j) = \iint p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) dx dy \quad (1)$$

式中: 概率密度 $p(x, y)$ 为网格内样本点数量占此指标对样本总数量的比例。

(2) 保持 x, y 不变, 不断改变网格划分宽度, 重新划分网格, 以 $I(X_i, X_j)$ 最大为目标选择最优的 x 行 y 列划分, 此时交互信息特征值 $M_{x, y}$ 为:

$$M_{x,y} = \frac{\max I\{I_G\}}{\log \min\{x,y\}} \quad (2)$$

(3) 遍历各种组合的 x 行 $\times y$ 列划分散点图, 得到指标对 $M(X_i, X_j)$ 的特征值矩阵 $M_{x,y}$ 。其中 x, y 需满足 $3 < xy < n^{0.6}$, n 为指标对样本量。

(4) 最后选择最大的交互信息特征值为最大信息交互系数 MIC 。

$$MIC = \max(M_{x,y}) \quad (3)$$

1.2 社团划分方法

社团划分方法是根据网络节点间的关联程度, 将分散的节点划分为若干个社团, 社团内的节点比社团间的节点关联程度高, 同一个社团内的节点可认为具有某种共同特征。社团划分的方法大体分为分裂法和凝聚法。

本文采用的 GN 算法是一种典型的分裂划分方法, 优点是可预设最终社团数量、划分结果较准确, 缺点是算法时间复杂度较高^[9]。其划分社团的依据是社团间的边介数较大, 通过不断计算网络中所有边的介数, 移除社团间的边介数最大的连边, 得到预设数量的孤立社团, 选择模块度 Q 最大的社团划分为最优划分。模块度 Q 的计算方式如下:

$$Q = \frac{1}{2M} \sum_{ij} (a_{ij} - \frac{k_i k_j}{2M}) \delta(C_i, C_j) \quad (4)$$

式中: M 为网络中的边数; k 为节点的度; C 为节点所在社团; 下标 i, j 表示节点。当 2 个节点同在一个社团, δ 值为 1, 否则 δ 值为 0。

1.3 主成分分析法

主成分分析法(PCA)是一种线性降维方法, 通过计算指标矩阵的特征值、特征向量、特征值占比, 并对特征值占比进行排序, 挑选包含信息量最多的部分指标作为特征矩阵。各特征指标之间线性无关, 特征指标选取过程具有客观性^[10]。由于主成分分析法较为常见, 在此不再赘述。

利用互信息相关系数法计算得到各指标间的量化关联度, 再利用 GN 算法对指标网络划分社团, 依据社团内指标间的关联度构建各社团关联系

数矩阵, 最后利用 PCA 挖掘各社团的特征指标。

1.4 应用示例: 防空能力特征指标挖掘

以某地域防空作战为背景设计想定, 采用体系仿真试验床进行建模仿真。红方作战目标是防卫指挥所不被摧毁。为检验不同条件下红方的防空能力, 有选择性地改变装备性能参数(如攻击导弹的发射距离, 空袭集群高度、密度、突入方向, 指挥通信网络, 空袭飞机的性能, 电磁干扰等), 共进行 6 000 次仿真实验。实验生成的数据共包括 168 个基础指标, 包括侦查、情报处理、火力交战、电磁对抗、通信、网络结构等。选取红方指挥所是否被摧毁作为体系防空能力表征指标, 其他 167 个指标作为样本集挖掘特征指标。

首先对样本集的 167 个指标进行关联度计算, 然后利用 GN 算法划分得到 4 个社团(见图 1), 分别是: ①G1 社团, 共 59 个指标, 包括防空装备间的指挥通信量、情报传输量及处理效率等在内的与指挥信息相关的指标; ②G2 社团, 共 52 个指标, 包括探测率、防区突防率、拦截率等与体系一体化火力打击相关的指标; ③G3 社团, 共 45 个, 主要包括红方地面防空部队实力、红方出动各型飞机总数等结构力量类指标; ④G4 社团, 共 11 个, 主要包括首次接敌时间和距离、首次开火打击时间和距离等与体系反应能力性能相关的指标。利用 PCA 算法对社团 G1~G4 进行主成分分析, 得到的特征成分数量分别为 6, 3, 2, 3, 对每个主成分取载荷最大的指标, 共得到特征指标 14 个。




图 1 某地域作战体系防空能力指标社团划分
Fig. 1 Communities detection for index of CSoS air defense ability for X region

2 基于集成学习的作战体系能力特征指标挖掘

集成学习是利用多个学习器参与学习, 分享学习成果进而降低预测误差的一种方法。集成学习以其优秀的学习性能被奈飞、KDD 等高水平比赛广泛使用。集成学习分为串行集成方法和并行集成方法, 后者保持了学习器的独立性, 具有收敛性好、过拟合概率低的优点^[11-12]。

基于集成学习进行特征指标挖掘的总体思路是, 先利用集成学习挖掘与具体能力关系最为紧密的指标, 然后利用主成分分析法处理指标间的关联, 挑选包含信息量最大的指标作为特征指标。

2.1 随机森林

随机森林(Random Forest)是典型的并行集成方法, 一般采用袋装法和决策树组合使用。袋装法是从样本集中有放回地随机选择数据样本, 生成与样本集规模相同的多个训练样本集, 利用学习器对每个训练样本集进行训练, 得到与训练样本集数量相等的预测结果, 再利用投票法(针对分类问题)或求均值法(针对回归问题)得到最终预测结果^[13]。使用袋装法时, 大约有 36.8% 的样本集样本未参与训练, 降低了过拟合风险。

决策树充当集成学习中的学习器, 应用较多的是 CART 决策树^[14]。CART 决策树是自上而下的分裂算法, 通过树的不断分裂实现预测和回归。Gini 系数是 CART 决策树分裂的重要参照, 计算方式为

$$Gini(D) = 1 - \sum_{i=1}^m p_i^2 \quad (5)$$

式中: D 为训练数据集; p_i 是样本集中的元素属于 C_i 类的概率, 也可表示为 $|C_i, D|/|D|$; m 是类型数量。

对于二元分裂问题, 如属性 A 的分裂将 D 划分成 D_1 和 D_2 , D 的基尼指数为:

$$Gini_A(D) = \frac{|D_1|}{|D|} Gini(D_1) + \frac{|D_2|}{|D|} Gini(D_2) \quad (6)$$

对于属性 A , 二元划分导致的不纯度降低为

$$\Delta Gini(A) = Gini(D) - Gini_A(D) \quad (7)$$

对于多属性分裂问题, 选择使基尼系数降低最大的属性进行分裂。

当节点 w 分裂为左节点 w_l 和右节点 w_r 时, 目标变量 Y 的不纯度降低为:

$$d_w = \frac{n_w}{n} \left\{ \hat{H}_{Y|w} - \left(\frac{n_{wl}}{n} \hat{H}_{Y|wl} + \frac{n_{wr}}{n} \hat{H}_{Y|wr} \right) \right\} \quad (8)$$

式中: n 是节点的样本大小; H 表示在各节点的不纯度评估值; 式(9)为 $H_{Y|w}$ 的计算方式, $H_{Y|wl}$ 和 $H_{Y|wr}$ 的计算方式与其类似。

$$\hat{H}_{Y|w} = \hat{G}_{Y|w} = 1 - \sum_{k=1}^3 f_{kw}^2 \quad (9)$$

式中: f_{kw} 表示 w 节点的第 k 类值观察的相对频度。

选择目标变量 Y 的不纯度降低为变量重要性度量(variable importance measure, VIM)标准。对于第 t 颗树的节点 j , 当使用变量 X_i 作为分裂变量时, VIM 可以表示为:

$$VIM_{X_i}(t) = \sum_{j \in J} d_{ij} I_{ij} \quad (10)$$

式中: I 为波尔量, 只有采用变量 X_i 作为分裂变量时值为 1, 其他情况值为 0。

整个随机森林的变量重要性为:

$$VIM_{X_i} = \frac{1}{T} \sum_{t=1}^T VIM_{X_i}(t) \quad (11)$$

2.2 算法流程

基于集成学习的作战体系能力特征指标挖掘算法流程如下:

step 1: 生成扩展测量矩阵。为降低数据缺省造成的指标特征缺失, 在算法中构建了扩展的测量矩阵。随机变换基础指标测试矩阵 X 的行顺序, 生成伪指标数据矩阵 Z_r , 构成新的分析矩阵 $X_r' = [X Z_r]$ 。

step 2: 构建初始决策树。从分析矩阵 X_r' 有放回地选取指标, OOB 比例为 1/3, 构建 n_{tree} 个决策树。选取 X_r' 中的 k 个指标作为决策树分裂的依据。

step 3: 生成单个决策树。通过计算各节点基尼系数, 对指标依次进行分类, 要求每次分类所得数据集对应的能力指标 Y 值差别最小, 直至分类无法进行。

step 4: 生成单个随机森林。重复 step 3 n_{tree} 次, 生成 n_{tree} 个决策树, 完成单个随机森林的生成。

step 5: 计算各指标重要性。根据公式(7), 计算指标 X_i 在节点的基尼指数变化 $\Delta Gini_{X_i}(D)$; 对各节点的 $\Delta Gini_{X_i}(D)$ 求和, 即为指标 X_i 在单个决策树的重要性 $VIM_{X_i}(t)$; 对各颗树的 $VIM_{X_i}(t)$ 求平均数, 即为指标 X_i 在单个随机森林的重要性。

step 6: 构建 S 个随机森林。重复 step 1~5 步骤 S 次。

step 7: 计算真实指标 X_i 在单个随机森林的重要性。以指标矩阵 X 为分析矩阵, 以真实指标 X_i 为决策树分裂依据, 重复 step1~6。

step 8: 关键指标挖掘。对 S 个随机森林内真伪指标的重要性求差值的均值, 得到各指标 X_i 的重要性, 对各指标重要性排序, 选出与任务使命关系最大的 g 个指标。

step 9: 根据 step 8 挑选出的 g 个指标构成测量矩阵, 利用主成分分析法, 计算特征值的占比并排序, 最后挑选包含信息量最多的多个指标作为特征指标。

2.3 应用示例：防突入能力特征指标挖掘

以监测红方的防敌机突入能力为目标设计想

定。红方防空装备系统由侦查预警系统、指挥控制系统、拦截武器系统、反击作战系统、信息对抗系统组成, 蓝方的进攻武器包括战斗机、陆基巡航导弹和弹道导弹等。通过设置不同的指挥体制和通信网络、装备比例, 共设置 32 种想定。依靠体系仿真试验床完成建模和仿真, 共采集体系初始指标共 378 个, 选择成功的 OODA 拦截事件次数作为防突入能力的表征指标。设置随机森林总数量为 80, 每个森林的决策树数量为 100。

利用 2.2 节的算法计算得到各指标重要性评估值, 如表 1 前 2 列所示。由于第 16 个指标的重要性评估值已经很低, 选取前 16 个指标进行主成分分析。图 2 为前 6 个主成分的特征和累积贡献率, 可知前 4 个主成分的特征值大于 1, 对应的累积贡献率为 84.4%, 说明前 4 个主成分代表了 16 个指标的绝大部分信息。表 1 右 4 列为 16 个指标的主成分载荷, 前 1~4 个主成分含量最高的指标分别是: 蓝方对红方空中平台识别总数、蓝方对红方所有平台 OODA 环数量、蓝方地面摧毁红方空中平台总数、蓝方对红方导弹最大 OODA 时间, 这 4 个指标即为体系防突入能力特征指标。

表 1 面向防突入能力的指标重要性评估值和主成分载荷

Tab. 1 Importance estimate values and principal component loads for indexes of air defense breakthrough ability

指标名称	重要性评估值	主成分 1	主成分 2	主成分 3	主成分 4
蓝方对红方所有平台探测率	0.481 901 702	0.375	0.002	0.000	0.014
蓝方探测到红方平台总数	0.455 564 012	0.381	-0.007	-0.019	-0.007
蓝方对红方空中平台识别总数	0.453 929 818	0.382	0.000	-0.003	-0.006
蓝方对红方空中探测率	0.382 505 037	0.380	-0.008	-0.017	-0.002
蓝方对红方空中平台敌我识别正确数量	0.376 970 393	0.179	-0.320	0.358	-0.236
蓝方 OODA 环 Action 阶段平均时间	0.276 264 668	0.179	-0.320	0.358	-0.236
蓝方对红方探测对总数	0.268 291 765	0.234	-0.043	-0.382	0.035
红方空中平台被摧毁总数	0.217 217 245	-0.240	-0.194	-0.412	-0.138
蓝方对红方导弹最大 OODA 时间	0.180 937 669	-0.141	-0.110	0.055	0.598
蓝方地面对红方空中探测对总数	0.176 854 241	0.231	-0.045	-0.439	0.024
蓝方对红方空中 OODA 环数量	0.164 945 296	-0.004	-0.607	-0.016	0.002
蓝方对红方所有平台 OODA 环数量	0.164 364 794	-0.017	-0.612	-0.011	0.036
蓝方对红方所有平台平均 OODA 时间	0.143 268 524	-0.024	0.042	0.067	0.577
蓝方对红方平台识别总数	0.143 073 880	0.208	0.157	-0.018	0.346
蓝方地面摧毁红方空中平台总数	0.137 126 998	-0.113	0.088	-0.577	-0.061
红方对蓝方地面平均 OODA 时间	0.136 287 067	0.053	-0.258	-0.148	0.328




图 2 面向防突入能力的主成分分析

Fig. 2 Principle component analysis for index of air defense breakthrough ability

3 结论

挖掘作战体系能力特征指标, 具有很好的现实意义。特征指标表征体系特定能力的关键影响因素, 分析这些关键因素, 能有效指导体系能力建设; 同时, 借助各种建模工具, 如神经网络、支持向量机、最小二乘法等, 拟合体系能力与特征指标间的关系, 有助于体系能力的评估。

采用“仿真试验床+机器学习”的思路, 利用体系仿真试验床生成作战数据, 再利用机器学习对这些数据进行挖掘, 从而获得能力特征指标, 体现

了“整体、动态、对抗”思想, 综合了定性定量方法, 是一种研究作战体系的新途径。

从本文两种特征指标挖掘方法的原理上看, 基于网络聚合的挖掘方法采用聚类思想, 体现各个组分对整体的影响, 偏重整个体系能力指标的构建, 更适用于能力建模; 而基于集成学习的挖掘方法针对具体能力的指向性强, 更适用于体系能力的监控分析。两种方法各有特色, 有待深入研究。

机器学习涵盖众多的类人学习方法, 本文仅以网络聚合和集成学习为代表, 对体系能力特征指标挖掘进行探索, 其他的机器学习算法, 如强化学习、深度学习、生成式对抗学习等, 也可以应用于特征指标的挖掘。

参考文献:

- [1] 李凤雷, 卢昊, 宋闯, 等. 智能化战争与无人系统技术的发展[J]. 无人系统技术, 2018, 1(2): 14-23.
Li Fenglei, Lu Hao, Song Chuang, et al. Development of Intelligent Warfare and Unmanned System Technology[J]. Unmanned Systems Technology, 2018, 1(2): 14-23.
- [2] 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[J]. 军事运筹与系统工程, 2016, 30(2): 26-32.
Wu Wengfeng, Hu Xiaofeng. Capability Evaluation Framework of Networked Operations System Based on Big Data[J]. Military Operations Research and Systems Engineering, 2016, 30(2): 26-32.
- [3] 丁剑飞. 武器装备体系效能指标体系构建方法研究[D]. 北京: 国防大学, 2017.
Ding Jianfei. Research on Construction Method of Weapon Equipment System Effectiveness Index System[D]. Beijing: PLA National Defense University, 2017.
- [4] 张昱, 杨镜宇, 李仁见, 等. 面向武器装备体系仿真的五环聚焦实验框架[J]. 系统仿真学报, 2014, 26(11): 2541-2545.
Zhang Yu, Yang Jingyu, Li Renjian, et al. 5-Loop Framework of Making and Converging Experiments for Simulation of Weapon System of Systems[J]. Journal of System Simulation, 2014, 26(11): 2541-2545.
- [5] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search[J]. Nature (S1476-4687), 2016, 529(7587): 484-489.
- [6] 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[J]. 指挥控制与仿真,

- 2016, 38(1): 94-100.
- Yao Xiaoyi, Guo Shengming, Hu Xiaofeng, et al. Indices Network Construction for Air Defense System of Systems Based on MINE-FNA Assembled Algorithm[J]. Command Control & Simulation, 2016, 38(1): 94-100.
- [7] 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体系能力回溯分析方法研究[J]. 中国科学: 信息科学, 2018, 48(7): 824-840.
- Guo Shengming, He Xiaoyuan, Wu Lin, et al. Backtracking Analysis Approach for Effectiveness of Air Defense Operation System of Systems Based on Force-sparsed Stacked-autoencoding Neural Networks [J]. SCIENTIA SINICA Informationis, 2018, 48(7): 824-840.
- [8] 蒋杭进. 最大信息系数及其在脑网络分析中的应用[D]. 武汉: 中国科学院研究生院(武汉物理与数学研究所), 2013.
- Jiang Hangjin. Maximal Information Coefficient and Its Application to Brain Network Analysis[D]. Wuhan: Graduate University of Chinese Academy of Sciences (Wuhan Institute of Physics and Mathematics), 2013.
- [9] Girvan M, Newman M E J. Community structure in social and biological networks[J]. Proceedings of the National Academy of Sciences (S1091-6490), 2002, 99(12): 7821-7826.
- [10] 魏旭. 基于主成分分析的特征融合及其应用[D]. 成都: 电子科技大学, 2008.
- Wei Xu. Feature Fusion Based on Principal Component Analysis and Its Application[D]. Chengdu: University of Electronic Science and Technology, 2008.
- [11] Dietterich T G. Machine learning research: Four current directions[J]. AI Magazine (S0738-4602), 1997, 18(4): 97-136.
- [12] Zhou Z H, Wu J X, Tang W. Ensembling neural networks: Many could be better than all[J]. Artificial Intelligence (S0004-3702), 2002, 137(1/2): 239-263.
- [13] Breiman L. Bagging predictors[J]. Machine Learning (S0885-6125), 1996, 24(2): 123-140.
- [14] Breiman L. Classification and regression trees[M]. New York: Chapman & Hall/CRC, 1984.