

# Journal of System Simulation

---

Volume 32 | Issue 8

Article 2

---

8-13-2020

## Intelligent Effectiveness Evaluation and Optimization on Weapon System of Systems Based on Deep Learning

Li Ni

1. School of Automation Science, Beihang University (BUAA), Beijing 100191, China;;

Yuhong Li

1. School of Automation Science, Beihang University (BUAA), Beijing 100191, China;;

Guanghong Gong

1. School of Automation Science, Beihang University (BUAA), Beijing 100191, China;;

Xiaodong Huang

2. Naval Aviation University, Yantai 264001, 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.

---

# Intelligent Effectiveness Evaluation and Optimization on Weapon System of Systems Based on Deep Learning

## Abstract

**Abstract:** In the process of conventional WSoS (Weapon System of Systems) operational effectiveness evaluation, multiple complex steps including reconfiguring the scenario, rerunning the WSoS simulation system, and conducting effectiveness evaluation model calculations are taken. For the problems of conventional effectiveness evaluation method, such as the complex process and time-consuming, *the intelligent evaluation method of WSoS combat effectiveness based on machine learning regression is proposed, and the optimization process of combat effectiveness based on evolutionary strategy is introduced.* Taking the full connection depth regression network as the prediction model, the guiding selection principles of network hidden layer number and sample size are given on the basis of the test results of multiple data sets. The optimal output is obtained by the genetic algorithm to adjust the network input, and the high iterative performance is got. Case study of a simulation system preliminarily verifies the effectiveness and value of the prediction model and the optimization method.

## Keywords

weapon system of systems, intelligent evaluation of operational effectiveness, intelligent optimization of operational effectiveness, regression prediction, deep regression network

## Recommended Citation

Li Ni, Li Yuhong, Gong Guanghong, Huang Xiaodong. Intelligent Effectiveness Evaluation and Optimization on Weapon System of Systems Based on Deep Learning[J]. Journal of System Simulation, 2020, 32(8): 1425-1435.

# 基于深度学习的体系作战效能智能评估及优化

李妮<sup>1</sup>, 李玉红<sup>1</sup>, 龚光红<sup>1</sup>, 黄晓冬<sup>2</sup>

(1. 自动化科学与电气工程学院北京航空航天大学, 北京 100191; 2. 海军航空大学, 山东 烟台 264001)

**摘要:** 采用仿真模拟评估方法进行体系作战效能评估包括配置想定、多次运行仿真系统和调用效能评估模型计算多个复杂步骤。针对此流程复杂、耗时长的问题, 提出一种基于深度学习回归思想的体系作战效能智能评估方法, 引入基于进化策略的作战效能优化流程。以全连接深度回归网络为预测模型, 通过多个数据集的试验结果给出网络隐层数和样本量选择的指导原则。进一步结合遗传算法调整网络输入得到优化输出, 迭代性能较好。以某仿真系统为例初步验证了其有效性和使用价值。

**关键词:** 武器装备体系; 作战效能智能评估; 作战效能智能优化; 回归预测; 深度回归网络

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2020) 08-1425-11

DOI: 10.16182/j.issn1004731x.joss.20-0353

## Intelligent Effectiveness Evaluation and Optimization on Weapon System of Systems Based on Deep Learning

Li Ni<sup>1</sup>, Li Yuhong<sup>1</sup>, Gong Guanghong<sup>1</sup>, Huang Xiaodong<sup>2</sup>

(1. School of Automation Science, Beihang University (BUAA), Beijing 100191, China; 2. Naval Aviation University, Yantai 264001, China)

**Abstract:** In the process of conventional WSoS (Weapon System of Systems) operational effectiveness evaluation, multiple complex steps including reconfiguring the scenario, rerunning the WSoS simulation system, and conducting effectiveness evaluation model calculations are taken. For the problems of conventional effectiveness evaluation method, such as the complex process and time-consuming, the intelligent evaluation method of WSoS combat effectiveness based on machine learning regression is proposed, and the optimization process of combat effectiveness based on evolutionary strategy is introduced. Taking the full connection depth regression network as the prediction model, the guiding selection principles of network hidden layer number and sample size are given on the basis of the test results of multiple data sets. The optimal output is obtained by the genetic algorithm to adjust the network input, and the high iterative performance is got. Case study of a simulation system preliminarily verifies the effectiveness and value of the prediction model and the optimization method.

**Keywords:** weapon system of systems; intelligent evaluation of operational effectiveness; intelligent optimization of operational effectiveness; regression prediction; deep regression network

## 引言

武器装备体系(Weapon System of Systems,



收稿日期: 2020-06-15 修回日期: 2020-07-27;  
基金项目: 国家自然科学基金(61773032);  
作者简介: 李妮(1980-), 女, 湖南衡阳, 博士, 教授,  
研究方向为系统仿真与混合现实; 李玉红(1988-), 女,  
河南商丘, 博士, 研究方向为复杂系统的建模、仿真、  
优化及评估; 龚光红(1968-), 女, 土家族, 四川石柱,  
博士, 教授, 研究方向为系统仿真与虚拟现实。

WSoS)是一个由多种武器装备系统组成的复杂分布式巨系统<sup>[1]</sup>, 各系统之间呈松耦合关系、自主性较强<sup>[2]</sup>。WSoS 作战效能定义为给定条件下体系完成特定作战任务的有效程度的度量<sup>[3]</sup>。对其进行准确评估是评价体系针对特定作战条件实现目标作战任务效果、检验和优选想定方案的重要手段<sup>[4]</sup>。

对装备系统作战效能进行评估, 美国提出了 ARINC(Aeronautical Radio Inc.)、陆军的 AAM

(Army Aviation Missile)、WSEIAC(Weapon System Effectiveness Industry Advisory Committee)等许多典型模型。国内,一些大学和兵工单位大多综合采用如 ADC (Availability、Dependability、Capacity) 法<sup>[5]</sup>、指数法<sup>[6]</sup>和作战环评估方法<sup>[7]</sup>等模型驱动评估法<sup>[8]</sup>、专家评价法和层次分析法 (Analytic Hierarchy Process, AHP) 等的经验驱动评估方法<sup>[9]</sup>和作战模拟驱动的仿真模拟评估方法<sup>[10]</sup>,结合定性定量的指标处理方法,开展多种效能的综合评估计算。WSoS 使命任务、子模型复杂多样,影响因素众多,模型驱动、经验驱动的效能评估方法用于 WSoS 作战效能评估 (WSoS Operational Effectiveness Evaluation, WSOEE) 时存在许多局限性<sup>[11-15]</sup>。在模型、数据较为充分的情况下,仿真模拟效能评估方法能够引入作战环境的影响,更清楚地描述体系各组分间的关系,适用于 WSOEE,但是该方法流程缺乏智能性、耗费时间长。

深度学习不需要人工设计特征提取器,能够自动进行最优特征的提取,对特征具有更强的抽象、学习能力。{想定参数,作战效能}样本数据较多时,采用深度学习能够基于输入的想定参数直接得到效能评估结论,加快评估的速度。国防科学技术大学、大连海事大学等采用深度信念网络 (Deep Belief Network, DBN)<sup>[16-17]</sup>、深度自编码回归模型<sup>[17]</sup>,对体系弹道导弹的突防效能、轮机实操效果实现了预测,预测误差较小。防化研究院提出了使用全连接深度神经网络 (Deep Neural Network, DNN)<sup>[18]</sup> 进行 WSOEE 的架构。针对深度学习参数选取难的问题,有研究试验了不同隐层数、不同神经元数下 DNN<sup>[19]</sup>、DBN<sup>[20]</sup>的回归预测效果。根据测试结果猜想模型隐层数不宜较多,但其没有给出一个模型参数选择的指导原则,亦没有考虑样本量的影响。因此,更多深度学习模型在 WSOEE 问题上的应用还需要更为深入的研究。

进一步考虑 WSoS 作战效能的有效优化问题,对效能优化通常是采用直接计算、索博尔 (Sobol) 指数法<sup>[21]</sup>、克里金 (Kriging) 模型构建法等一些敏

感性分析方法,存在着优化结果不能定量、对复杂问题可信度不高甚至无法拟合、缺乏智能性等一些问题。

因此,针对传统仿真模拟评估方法开展 WSOEE 存在的问题以及现有效能优化方法存在的局限性,本文探索采用深度学习进行 WSOEE 的模型隐层数及样本量的适用指导规律、以及单个和多个效能指标的智能优化问题。

## 1 常规基于仿真的 WSOEE

### 1.1 常规 WSOEE 流程

常规基于仿真的 WSOEE 流程如图 1 所示。

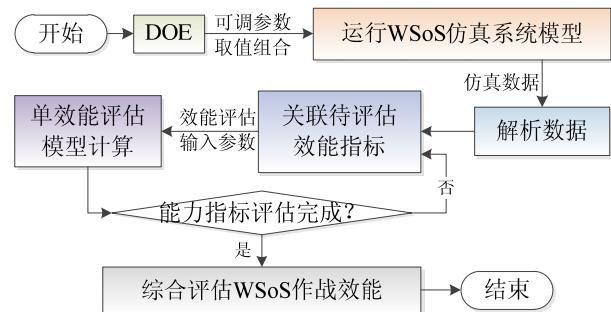


图 1 常规 WSOEE 流程

Fig. 1 Conventional process of WSOEE

该流程包括以下步骤:

step 1: 利用试验设计 (Design of Experiments, DOE) 方法生成一定数目具有代表性的体系想定参数取值组合样本;

step 2: 按照样本中参数取值编辑想定方案,运行体系作战仿真系统,得到的多个仿真数据文件存于数据库中;

step 3: 解析仿真数据;

step 4: 从解析数据中确定效能评估模型所需输入参数数据取值,计算单个效能评估值;

step 5: 重复 step 4,求得多个作战效能的评估值,若需要可进一步利用综合评估方法对多个单效能进行综合评估,得到总体的 WSOEE 值。

能够看到,此流程本身很复杂,尤其是仿真子模型、仿真系统模型和评估模型的构建,其间还涉

及大量仿真数据的生成、存储及解析工作。随着现代武器装备的多样化、复杂化以及战场对抗的复杂化、不确定性增加,此过程更加复杂、求解时间更加漫长。

## 1.2 想定参数和作战效能取值特点

WSoS 作战仿真初始的想定参数可包括参与仿真的兵力类型、数量、携带弹药等兵力装备参数,大气条件、降雨、可见度、自然光照、环境风等作战环境参数,参战单位在编队中是否独立机动、上级编队接受指控命令的次序、观测器和武器装备的初始朝向、编队类型、航路点、队形、间距、初始位置等兵力部署和指控参数。

想定参数的取值属性分为 2 种情况:(1) 数值型取值,如飞机的飞行高度,当这类参数的离散取值间隔很小时,可以认为是连续取值;(2) 枚举型取值,如飞机机型取值 J-10A, J-10B 两种情况。要评估的作战效能为连续数值型,如“舰艇拦截导弹的概率”指标可取为[0.0, 1.0]范围内的任一数值。

## 2 基于深度学习的回归预测

采用全连接 DNN 模型构建适用于 WSOEE 的预测模型。在多个包含高维特征、不同目标变量的类似 WSOEE 数据集上进行预测实验,分析该模型在这类问题上适合的样本量、模型隐层数规律,为基于深度回归模型的 WSOEE 提供模型隐层数选择和样本量选择上的指导。

### 2.1 深度回归模型构建

一般情况下深度学习的样本量较大。假设 WSOEE 样本数据包含  $n$  个样本、 $m$  个想定参数、 $M$  个待预测的作战效能,为提高模型的学习效率,本文采用批处理方式进行模型的训练。记每批参与训练的样本数为  $batch\_size$ ,全样本训练完记为一个 epoch。

采用全连接 DNN 模型构建适合于 WSOEE 的

回归模型,模型结构如图 2 所示。输入层的神经元个数为  $m$ 。隐层有多个,越靠近输入层的隐层其神经元个数较多,反之较少。模型输出层不加激活函数,输出层神经元数为待预测的作战效能数目  $M$ 。

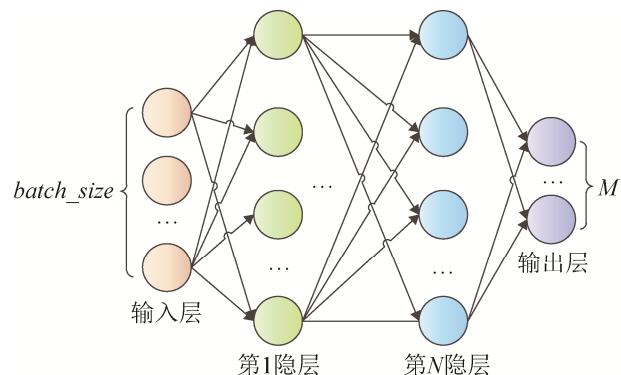


图 2 全连接 DNN 回归模型结构  
Fig. 2 Structure of fully connected DNN regression model

模型每次训练时将  $batch\_size$  个样本依次输入到模型中,进行  $n/batch\_size$  次训练后完成一个 epoch,直至满足结束条件模型训练结束,最后输入测试样本得到对应  $M$  个作战效能的预测值。

### 2.2 深度回归预测

DTLZ 系列函数<sup>[22-23]</sup>为典型的高度非线性多目标优化测试函数,其自变量和目标变量取值分别为离散数值型和连续数值型。本文选取其中的 DTLZ1 函数,自定义因子个数  $m$ 、目标变量个数  $M$  分别取为 30, 50 和 100 三种情况和 3, 5 和 10 三种情况,DOE 后得到样本数  $n$  为 1 000, 5 000, 10 000, 20 000 的 36 个不同的样本数据集。基于该函数进行测试分析可用于参考并建立效能预测网络结构。

初始化图 2 所示全连接 DNN 回归模型,对该模型隐层数为 1~10 的 10 种结构进行试验,分析不同隐层结构下模型取得的回归预测决定系数( $R^2$ )指标值,研究模型隐层数和样本量大小对该模型回归预测效果的影响,  $R^2$  的计算公式如下:

$$R^2 = 1 - \left( \sum_{i=1}^n [y_i - \hat{f}(x_i)]^2 \right) / \left( \sum_{i=1}^n [y_i - \bar{y}]^2 \right) \quad (1)$$

式中:  $x_i$  为第  $i$  个样本点;  $y_i$  为在点  $x_i$  处的实际输出值;  $\hat{f}(x_i)$  为对应  $y_i$  的拟合值;  $\bar{y}$  为所有  $y_i$  的平均值,  $R^2$  值越大表示取得的回归预测效果越好。

隐层神经元数目采用常规做法, 第一个隐层的神经元个数为 1 024, 后续隐层的神经元个数依次呈比例 2 递减, 每个隐层的神经元个数最少为 32。模型激活函数均选用 ReLU 函数, 初始化 epoch 为 300, batch\_size 为 100。不同  $m, M$  取值组合下每个样本量  $n$  对应 9 个 DTLZ1 样本数据集, 10 种不同隐层数的该模型在同一  $n$  取值下的 9 个样本数据集上取得的  $R^2$  值如图 3 所示。

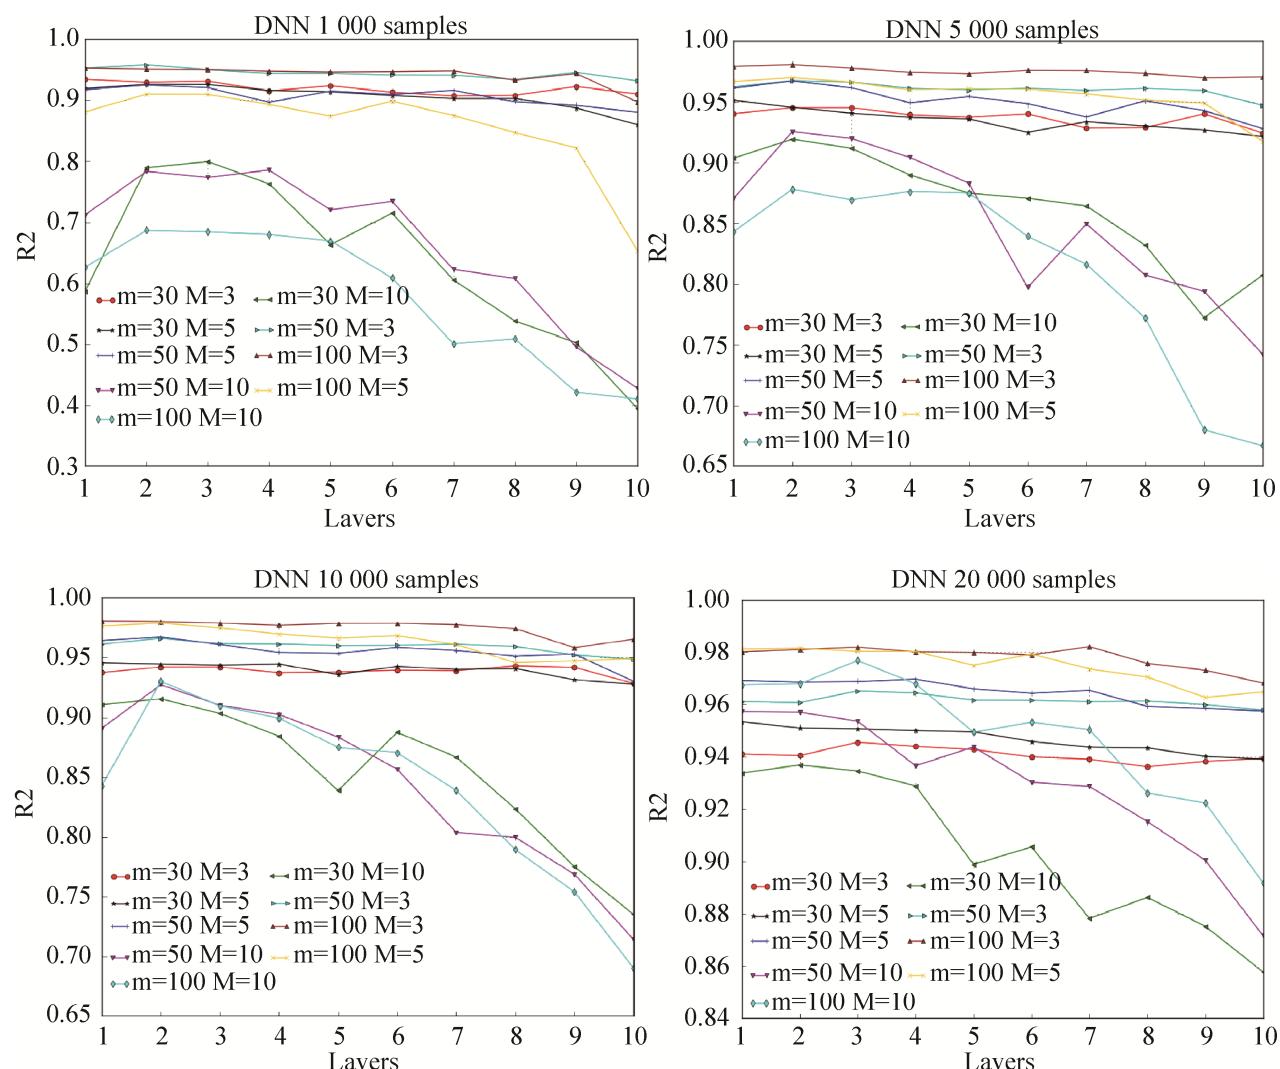


图 3 10 种隐层结构的全连接 DNN 对 4 种样本量的 9 个回归问题的预测效果  
Fig. 3 Prediction effect of fully connected DNN with ten kinds of hidden layer structures on nine regression problems with four sample sizes

能够看到, 本质上  $m, M$  决定了预测问题的复杂度。高质量、足够数目的样本有利于取得较好的预测效果, 当隐层数一定时, 较多的  $n$  能够提升  $R^2$  值, 即网络预测能力。 $n$  一定时,  $m, M$  越多, 一般需要更多隐层, 能够更准确地反映输入、输出的关系, 但隐层较多时学习也易于过拟合, 因此需要根据问题情况选择合适的网络结构。从图 3 中可以看出  $m, M$  相同  $n$  一定时, 隐层数从 1~10 增加过程中  $R^2$  取值先增大、后明显减小, 说明隐层较多时出现了过拟合现象。

因此,在一个 DTLZ1 样本数据上,该模型取得的最好预测效果跟模型隐层数、样本量  $n$  均有很大关系,如表 1 所示。能够看到,并不是模型隐层数越多相应的预测效果越好,另一方面,在条件允许情况下更多有代表性的样本数据通常有助于提高模型的预测效果,  $n$  较大时,隐层无需太多也能有好的训练效果。

表 1 最大  $R^2$ 、所需样本量( $n$ )和模型隐层数  
Tab. 1 Maximum  $R^2$ , sample size ( $n$ ) and number of model hidden layers needed

$m$	$M$			
	30	50	100	
3	隐层数	3	2	7
	$n$	20 000	5 000	20 000
	$R^2$	0.945 5	0.967 3	0.982 0
5	隐层数	1	4	2
	$n$	20 000	20 000	20 000
	$R^2$	0.953 3	0.969 6	0.981 4
10	隐层数	2	1	3
	$n$	20 000	20 000	20 000
	$R^2$	0.936 8	0.957 2	0.976 7

该模型在不同 DTLZ1 样本数据上取得最大  $R^2$  值的训练所用时间如表 2 所示,这里仅列出  $n$  为 1 000, 5 000 的情况。本文所有试验均在 Intel(R) Core(TM) i7-3770 CPU @ 3.40 GHz PC 机上进行。

表 2 DNN 模型训练时间  
Tab. 2 Training Time of DNN model

		30	50	100
$M=3$	$n=1\ 000$	0.562	0.633	0.802
	$n=5\ 000$	3.982	4.893	5.897
$M=5$	$n=1\ 000$	0.780	0.881	1.017
	$n=5\ 000$	3.866	5.077	6.308
$M=10$	$n=1\ 000$	1.053	1.404	1.705
	$n=5\ 000$	3.857	5.294	6.508

能够看出,  $M$  和  $m$  对该模型训练效率的影响较小,而  $n$  的影响较大。总体来讲该模型训练时间较短,如  $n$  为 5 000,  $m$  为 50,  $M$  为 5 时训练用时 5 min 左右。

因此,深度回归模型虽然有较多的调试参数,但在 WSOEE 这类问题上,针对于不同数目的目标

变量预测,通过改变模型隐层数和样本量大小,模型在其隐层数不超过 10 时能够取得较好的预测效果且用时较少。根据结果分析,预测网络的样本数  $n$  和隐层数可遵循表 3 所示的量化原则进行选择。

表 3 不同  $M$  下  $n$  和隐层数的关系  
Tab. 3 Relationship between  $n$  and hidden layers number under different  $M$

$M$	$n$		
	$1\ 000 \leq n \leq 5\ 000$	$5\ 000 < n \leq 10\ 000$	$10\ 000 < n \leq 20\ 000$
3	隐层数 2~6	隐层数 3~6	隐层数 3~7
5	隐层数 2~5	隐层数 2~6	隐层数 2~6
10	隐层数 2~4	隐层数 2~6	隐层数 1~4

### 3 单/多作战效能的智能优化

#### 3.1 单作战效能优化

基于进化策略对体系单作战效能指标取值进行优化,将全连接 DNN 回归模型对单作战效能的预测值作为优化目标值,设置一定的约束条件,经过多次进化迭代寻优,达到终止条件时的想定参数取值组合即是最优解,此时的效能预测值为作战效能最优值,优化流程如图 4 所示。

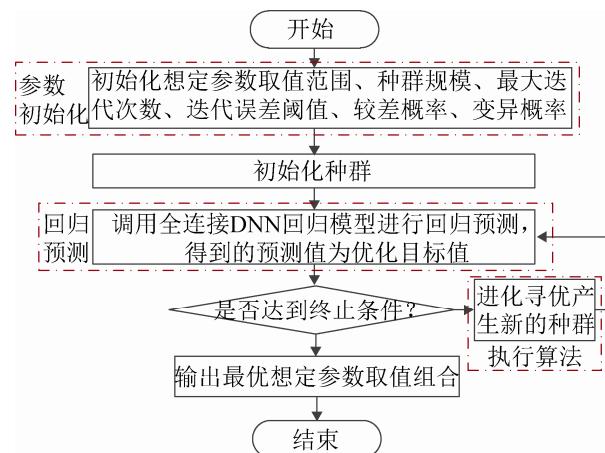


图 4 基于进化策略的单作战效能优化流程  
Fig. 4 Optimization process of single operational effectiveness based on evolutionary strategy

具体步骤为:

step 1: 首先初始化各想定参数的取值范围、种群规模、最大迭代次数、迭代误差阈值、交叉概率和变异概率;

**step 2:** 实数编码染色体，初始化种群，根据想定参数间的约束关系及作战效能的取值约束设置约束条件，每个个体表示想定参数取值组合的一种情况；

**step 3:** 调用全连接 DNN 回归模型预测每个个体对应的作战效能取值，取值越优表示该个体越优；

**step 4:** 判断是否满足迭代误差阈值、最大迭代次数等终止条件，如否执行 **step 5**；如是执行 **step 6**；

**step 5:** 执行进化寻优生成新的种群，循环迭代返回执行 **step 3**，迭代次数加 1；

**step 6:** 得到作战效能指标最优时的想定参数取值组合。

依据 2.2 小节，在 WSOEE 这类预测问题上，当样本量  $n$  在不大于 5 000、目标变量数目  $M$  为 3 时，2~6 隐层数目的全连接 DNN 能取得较好的预测效果。本节选用 2 层全连接 DNN 回归模型为预测模型，在应用于仿真系统之前，先基于典型数据集测试该优化流程的优化性能。以 UCI 数据集中的 Boston 和 ComuniCrime<sup>[24]</sup>2 个回归数据集为例，按照图 4 优化流程结合实数编码的遗传算法 (Genetic Algorithm, GA) 分别对这 2 个数据集目标变量取值进行最优化。

2 个数据集的具体信息如表 4 所示，类似效能预测问题，其特征均为枚举型和数值型取值的变量。原始 Boston 数据集和 ComuniCrime 数据集中目标变量的取值范围分别为 [5.0, 50.0] 和 [0.0, 1.0]。

表 4 数据集信息  
Tab. 4 Dataset information

数据集	样本个数	特征数	特征取值
Boston	506	13	枚举型, 数值型
ComuniCrime	1 994	127	枚举型, 数值型

为验证本方法优化能力，将 Boston 数据集的优化目标设定为取最小值，ComuniCrime 数据集的优化目标设定为取最大值。种群大小取 40，最大

迭代次数为 100 次，迭代误差阈值取 0.05，优化取值结果及优化结果收敛所用时间如表 5 所示。能够看到，全连接 DNN 模型对两数据集特征变量和目标变量间的关系均进行了有效拟合，采用该优化方法得到的目标变量最大和最小取值等于原始数据集中的值，且所用优化时间较少。

表 5 基于 GA 的单目标变量优化结果  
Tab. 5 Single objective variable optimization results based on GA

优化问题	最优值	用时/min	收敛代数	$R^2$
Boston 数据集目标变量值最小化	5.0	5.376	30	0.896
ComuniCrime 数据集目标变量值最大化	1.0	5.002	22	0.642

### 3.2 多作战效能优化

体系多作战效能优化这类问题中，每个待优化的作战效能优化权重不同，取得的多作战效能综合优化性能不同。因此通过给每个待优化的作战效能分配一个优化权重，可将多作战效能优化问题转化为单作战效能优化问题，从而按图 4 所示优化流程实现多作战效能的优化。

## 4 案例应用

以某仿真系统为例，基于提出的效能评估通用框架<sup>[25]</sup>将该系统的作战效能进行指标分解，选取系统作战对抗结束时红方指控能力中“兵力到位率”(记为“效能 1”)和“指挥可达性”(记为“效能 2”)、防护能力中“拦截远程导弹的能力”(记为“效能 3”)、打击能力中“舰艇对导弹的探测能力”(记为“效能 4”) 4 个基础的作战效能指标作为研究对象，来展现上述 WSoS 作战效能智能评估方法和智能优化方法的应用效果。

### 4.1 案例 WSoS 及作战任务描述

该系统是一个多兵种参与的分布式体系对抗仿真应用，涵盖红方、蓝方典型的体系作战要素，包括多兵种、多用途的武器装备，涉及预警指挥、

雷达探测、电子干扰、对空拦截、空空拦截等多种作战样式。

蓝方为进攻方，其预警探测早于红方，蓝方指挥所动态决定攻击的目标，红方的作战任务为防守。按红方空中武器平台可能对蓝方防线的突防过程，该系统中的作战任务分为 4 个阶段。在阶段 1，红方指挥部部署于航母上对其兵力进行指控：组织预警机及侦察卫星对蓝方敌情进行侦察探测、跟踪和战情判断，并进行舰载战斗机编队和电子战飞机编队的兵力部署和任务制定，指挥编队间通信。阶段 2 为雷达预警下指挥部对各兵力进行引导、协调和攻击目标分配，驱逐舰、前哨警戒舰及电子战飞机协同对空远程拦截蓝方导弹。阶段 3 为直接警戒舰、战斗机编队协同中程拦截作战。阶段 4 中直接警戒舰、战斗机编队协同进行末段拦截作战。

## 4.2 WSoS 作战效能智能评估

基于深度学习的 WSOEE 需要一定的样本数据。案例系统对抗过程对应的想定参数全样本空间巨大，且每个参数的水平取值情况不同。本案例选取其中 45 个红方想定参数作为试验因子，这些参数的水平取值均有 2 种或 3 种可能情况，取值属性为离散数值型或枚举型。依据图 1 流程用时 50 天左右得到 5 100 个{想定参数，作战效能}样本数据。想定参数的水平取值为混合型，数量级及度量单位亦有所不同，因此深度学习之前先对样本数据进行数据预处理。全样本中 5 000 个样本用于训练和测试模型，100 个样本用于验证模型。

基于回归模型的 WSOEE 流程如图 5 所示，首先将样本数据随机划分为 80% 的训练集和 20% 的测试集，然后输入训练样本进行模型训练，满足  $MSE$  阈值或  $epoch$  等设定条件时模型训练结束，最后输入测试的想定参数试验样本到训练好的模型，得到作战效能预测值。

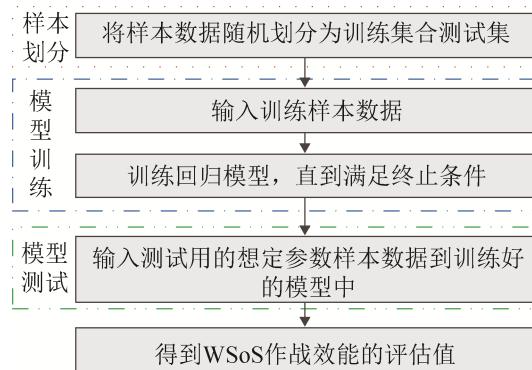


图 5 基于回归模型的 WSOEE 流程  
Fig. 5 Process of WSOEE based on regression model

### 4.2.1 单作战效能智能评估

2.2 小节实验结果表明，当样本量  $n$  在 [5 000, 10 000] 范围、目标变量数目取 3 时，全连接 DNN 回归预测适宜采用 2~6 的隐层。因此，采用该模型进行单作战效能预测时，选取 2~6 的隐层结构，每种结构的该模型对同一作战效能回归预测均运行 10 次，计算均方误差(Mean Squared Error,  $MSE$ )、平均绝对误差(Mean Absolute Error,  $MAE$ )和公式(1)中  $R^2$  3 个回归评价指标的值。 $MSE$  和  $MAE$  的计算公式分别为：

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

式中： $y_i$  和  $\hat{y}_i$  分别为第  $i$  个测试样本的目标变量真实值和模型取得的该目标变量预测值； $n$  为测试样本的总数， $MSE$ ， $MAE$  越小表示取得的预测效果越好。

采用该全连接 DNN 模型对 4 个单作战效能进行预测，取得的 3 指标最小值、平均值和最大值、所用时间等结果如表 6 所示。

能够看到，采用较少的 4~6 隐层的全连接 DNN 模型能够取得较好的单作战效能预测效果， $MSE$ ， $MAE$  值较小， $R^2$  值较大，所用时间在 4 min 左右，以较少的时间代价取得了较好的预测效果。

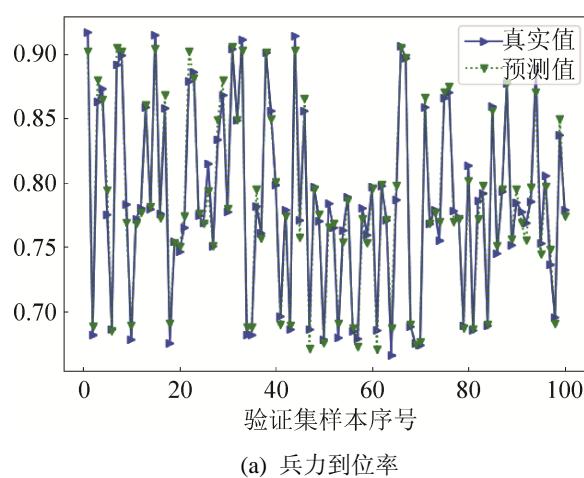
最后，对每个单作战效能，基于 100 个验证数据通过对比取得的效能预测值与相应的常规作战效能评估基准值，来验证全连接 DNN 效能预测结

果的有效性，以“兵力到位率”、“指挥可达性”为例，对比结果如图 6 所示。

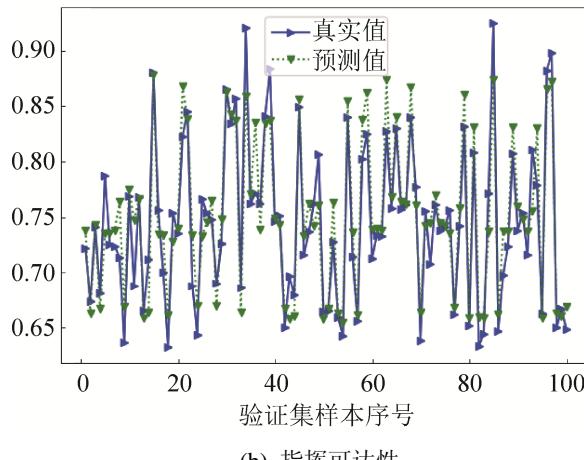
表 6 4 个单作战效能的回归预测效果

Tab. 6 Regression prediction effects for 4 single combat effectiveness

指标	效能 1	效能 2	效能 3	效能 4	
$MSE$	最小	0.000 13	0.000 86	0.000 82	0.000 19
	平均	0.000 14	0.000 88	0.000 88	0.000 20
	最大	0.000 15	0.000 90	0.000 96	0.000 20
$MAE$	最小	0.009 2	0.023 5	0.023 2	0.011 0
	平均	0.009 5	0.023 9	0.023 8	0.011 2
	最大	0.010 0	0.024 3	0.024 8	0.011 3
$R^2$	最小	0.970 1	0.877 1	0.866 4	0.931 1
	平均	0.972 4	0.882 8	0.879 9	0.932 6
	最大	0.974 4	0.905 5	0.894 5	0.933 9
用时/min	4.373	5.564	3.118	5.364	
最佳隐层数	6	6	4	6	



(a) 兵力到位率



(b) 指挥可达性

图 6 不同作战效能的验证对比结果

Fig. 6 Verification and comparison results of different combat effectiveness

相比于效能基准值，该模型在“兵力到位率”、“指挥可达性”、“拦截远程导弹能力”和“舰艇探测导弹能力”4 效能上取得的平均预测相对误差分别在 0.007 5, 0.019 3, 0.033 1, 0.012 5 左右。

#### 4.2.2 多作战效能智能评估

以上述 4 种作战效能综合预测为例进行多效能的评估应用。结果表明 6 隐层的全连接 DNN 模型取得了最佳回归预测效果，2 种模型取得的 3 个指标最小值、平均值和最大值及所用时间如表 7 所示。

表 7 6 隐层 DNN 对 4 作战效能的预测效果

Tab. 7 Prediction effects of DNN with six hidden layers when predicting four combat effectiveness

指标取值	$MSE$	$MAE$	$R^2$	用时/min
最小	0.000 93	0.019 8	0.899 4	
平均	0.000 93	0.019 9	<b>0.911 6</b>	约 4.355
最大	0.001 00	0.020 1	0.924 9	

模型取得最优综合预测效果时，在验证集上得到对应效能 1~4 的单个效能预测的平均预测相对误差分别为 0.011 2, 0.023 2, 0.037 3, 0.017 2。因此，2.2 小节所提取的 WSOEE 这类问题上样本量和隐层关系的量化指导原则，能够适用于案例系统单、多作战效能的预测评估。

### 4.3 WSoS 作战效能智能优化

#### 4.3.1 单作战效能指标优化

以 2.1 小节中在各个单作战效能上取得最优预测效果的全连接 DNN 回归模型为预测模型，设置种群大小为 40，最大迭代次数为 200，迭代误差阈值为 0.05，根据想定参数间的制约关系设立约束条件。种群执行 GA 进化迭代，直到作战效能的最大预测取值收敛到迭代误差阈值范围内或算法迭代次数达到最大迭代次数，优化过程结束。得到 4 个单作战效能指标的最大取值优化结果及优化所用时间如表 8 所示。

对比各效能的原始最大取值能够看到，此优化方法对每个作战效能取得的最优值均优于相应作

战效能的原最大取值, 优化用时十几分钟。

表 8 单作战效能优化的最优取值及用时

Tab. 8 Optimal value and time spent for optimizing single operational effectiveness

项目类别	效能 1	效能 2	效能 3	效能 4
原样本中效能最大取值	0.926 4	0.920 5	0.914 4	0.926 6
优化取值	<b>0.940 1</b>	<b>0.930 1</b>	<b>0.932 2</b>	<b>0.951 7</b>
用时/min	13.766	14.521	14.374	15.572
收敛代数	102	91	81	175

最后, 将最效能的想定参数取值组合解输入到如图 1 常规 WSOEE 流程中, 得到相应的常规效能评估基准值。与全连接 DNN 回归模型预测下 GA 优化得到的效能最优值对比, 得到效能最优值与相应常规评估基准值间的平均相对误差如表 9 所示。

表 9 平均相对误差  
Tab. 9 Mean relative error

效能指标	效能 1	效能 2	效能 3	效能 4
平均相对误差	0.011 3	0.012 4	0.012 6	0.012 2

可以看出, 以具有较好回归预测效果的全连接 DNN 为预测模型, 该优化方法得到的各作战效能最优值与相应的评估基准值之间的平均预测相对误差较小, 表明了优化结果的有效性。

#### 4.3.2 多作战效能指标优化

以效能一到效能四的四效能同权重优化为例, 设置四效能综合优化时每个效能所占的优化权重均为 1/4。按照图 4 优化流程, 参考 4.2.1 小节以 6 隐层全连接 DNN 回归模型为预测模型, 优化算法参数设置同 4.3.1 小节。求得的四效能最大值分别为 0.930 5, 0.921 6, 0.916 2 和 0.935 4, 与表 8 中该模型预测下优化取得的单作战效能指标最大值对比, 能够发现四效能同权重优化取得的 4 个单效能的最大值均稍小, 但仍比原样本点对应的最效能值要大。

最后, 在验证集上, 将优化取得的效能值与相应的常规效能基准评估值对比, 得到对 4 个单作战

效能的平均预测相对误差均在 0.022 以下, 表明这种加权优化方法具有一定的有效性。这种综合权重优化方法可以为决策者提供多作战效能不同权重优化时想定参数取值组合最优选择的一种手段, 进一步支撑作战使用中想定方案的优化。

#### 4.3.3 常规效能评估和智能化效能评估效率对比

按照图 1 所示常规 WSOEE 流程, 输入一个想定参数取值组合样本到体系仿真系统运行一次需要大约 15 min, 走完整个评估流程得到单效能评估值用时大于 15 min。假设仿真系统一次运行结束和下次运行开始之间没有时间耽搁, 仿真运行 1 000 次就需要大约 250 h, 加上仿真数据解析、效能模型解算, 得到效能评估值用时更长。在取得足够的样本数据完成训练后, 智能化效能评估方法就可以进行不同想定参数组合的快速评估。另外, 常规 WSOEE 流程是一个正向的作战效能评估值求解过程, 不能逆向进行作战效能的优化, 在这方面采用本文的智能化效能评估方法具有优势。

## 5 结论

WSoS 作战效能的评估与优化是建模仿真领域中一大难题, 本文围绕这一主题, 提出了一种基于深度学习解决该问题的方法与途径。本文以全连接 DNN 回归模型为例, 研究后认为在 WSOEE 问题上采用 5 000 样本量、较少模型隐层数可取得效能预测误差较小, 预测训练时间较少, 较常规作战效能评估方式在效率、效能优化可操作性方面具有较大的优势。本文结合回归模型预测提出的 GA 目标变量优化方法可实现单作战效能指标和多作战效能指标的最优化, 相比传统手段可快速找到最效能的想定参数组合取值。

## 参考文献:

- [1] Ding J, Si G, Yang G, et al. Visualization analysis of the capability of weapon system of systems for multi-dimensional indicators[J]. Journal of Systems Engineering and Electronics (S1004-4132), 2017, 28(2): 292-300.

- [2] 沈雪石, 吴集, 安波, 等. 装备技术体系设计理论与方法[M]. 北京: 国防工业出版社, 2014.  
Shen Xueshi, Wu Ji, An Bo, et al. Design Theory and Method of Equipment Technology System of Systems[M]. Beijing: National Defense Industry Press, 2014.
- [3] Joint C.o.S. CJCSI 3170-01B Operation of the Joint Capabilities Integration and Development System.[S/OL]. 2007. [http://www.dti.cmil/cjcs\\_directives/index.htm](http://www.dti.cmil/cjcs_directives/index.htm)
- [4] Gray F, L'Hommedieu W. A Combat-Effectiveness Approach to Information Assurance[C]. US Air Force T&E Days 2010. 2010: 355-362.
- [5] 孟庆德, 张俊, 魏军辉, 等. 基于 ADC 法的舰炮武器系统作战效能评估模型[J]. 火炮发射与控制学报, 2015, 36(1): 73-76, 85.  
Meng Qingde, Zhang Jun, Wei Junhui, et al. Operational Effectiveness Evaluation Model of Naval Gun Weapon System Based on ADC[J]. Journal of Gun Launch & Control, 2015, 36(1): 73-76, 85.
- [6] 张平, 李曙光, 肖南, 等. 基于指数法的装甲救护车作战效能评估[J]. 兵器装备工程学报, 2016, 37(11): 171-175.  
Zhang Ping, Li Shuguang, Xiao Nan, et al. Effectiveness Evaluation for Armored Ambulance Combat Capability Based on Index Method[J]. Journal of Ordnance Equipment Engineering, 2016, 37(11): 171-175.
- [7] 王子齐, 刘高峰. 基于 SEM 的近程反导舰炮武器系统作战能力评估[J]. 指挥控制与仿真, 2017, 39(4): 85-91.  
Wang Ziqi, Liu Gaofeng. Combat Capability Evaluation of Short Range Antimissile Naval Gun System Based on SEM[J]. Command Control & Simulation, 2017, 39(4): 85-91.
- [8] 魏海龙, 李清, 黄诗晟, 等. 模型驱动的武器装备系统效能评估方法[J]. 清华大学学报(自然科学版), 2019, 59(11): 925-933.  
Wei Hailong, Li Qing, Huang Shisheng, et al. Model-driven MOE method for weapon systems[J]. Journal of Tsinghua University (Science and Technology), 2019, 59(11): 925-933.
- [9] 李太平, 陈艳, 陈亮. 基于层次分析法的效能评估方法研究[J]. 电子技术与软件工程, 2016(11): 96-97, 210.  
Li Taiping, Chen Yan, Chen Liang. Research on Efficiency Evaluation Method Based on AHP[J]. Electronic Technology & Software Engineering, 2016 (11): 96-97, 210.
- [10] 许一帆, 曾杨智, 朱万红. 电磁防护对装甲车辆效能评估的影响[J]. 兵工自动化, 2018, 37(12): 71-73.  
Xu Yifan, Zeng Yangzhi, Zhu Wanhong. Effect of Electromagnetic Protection on Effectiveness Evaluation of Armored Vehicles[J]. Ordnance Industry Automation, 2018, 37(12): 71-73.
- [11] 马庆跃. 武器装备体系作战效能综合评估技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2015.  
Ma Qingyue. Research on the Comprehensive Evaluation Technology of Combat Effectiveness of Weapon System of Systems[D]. Harbin: Harbin Institute of Technology, 2015.
- [12] 肖利辉, 黄玉章. 一种基于系统论思想的作战体系效能评估方法[J]. 军事运筹与系统工程, 2016, 30(1): 18-22.  
Xiao Lihui, Huang Yuzhang. An Effectiveness Evaluation Method of Combat System of Systems based on System Theory[J]. Military Operations Research and Systems Engineering, 2016, 30(1): 18-22.
- [13] 梁家林, 熊伟. 基于作战环的武器装备体系能力评估方法[J]. 系统工程与电子技术, 2019, 41(8): 1810-1819.  
Liang Jialin, Xiong Wei. Capabilities Assessment of the Weaponry System based on Combat ring[J]. Systems Engineering and Electronics, 2019, 41(8): 1810-1819.
- [14] 张永利, 周荣坤, 计文平, 等. 基于模糊综合评判法的航母编队舰载机群体系作战效能评估[J]. 舰船电子工程, 2015, 35(10): 117-121.  
Zhang Yongli, Zhou Rongkun, Ji Wenping, et al. Efficiency Evaluation for Carrier Formation Swarming Aircraft Based on Fuzzy Synthetic Evaluation Method[J]. Ship Electronic Engineering, 2015, 35(10): 117-121.
- [15] 代耀宗, 沈建京, 郭晓峰. 作战效能评估方法研究[J]. 国防科技, 2017, 38(5): 104-109.  
Dai Yaozong, Shen Jianjing, Guo Xiaofeng. Review of Combat Effectiveness Evaluation Methods[J]. National Defense Science & Technology, 2017, 38(5): 104-109.
- [16] 任俊, 李宁. 基于堆栈自编码降维的武器装备体系效能预测[J]. 军事运筹与系统工程, 2017, 31(1): 61-67.  
Ren Jun, Li Ning. Effectiveness Prediction of Weapon System of Systems based on Stack Coding and Dimension Reduction[J]. Military Operations Research and Systems Engineering, 2017, 31(1): 61-67.
- [17] 段尊雷, 任光, 李烨. 基于深度信念网络的轮机实操智能评估方法[J]. 大连海事大学学报(自然科学版), 2017, 43(3): 89-94.  
Duan Zunlei, Ren Guang, Li Ye. Intelligent Evaluation Method of Marine Engineering Operation based on Deep Belief Network[J]. Journal of Dalian Maritime University (Natural Science Edition), 2017, 43(3): 89-94.
- [18] 左钦文, 张杰民, 刘晓宏, 等. 基于大数据及机器学习

- 的智能作战评估方法[J]. 兵器装备工程学报, 2020, 41(2): 107-110.
- Zuo Qinwen, Zhang Jiemin, Liu Xiaohong, et al. Intelligent Combat Evaluation Method based on Big Data and Machine Learning[J]. Journal of Weapon Equipment Engineering, 2020, 41(2): 107-110.
- [19] Tian K, Shao M Y, Wang Y, et al. Boosting Compound-protein Interaction Prediction by Deep Learning[J]. Methods (S1046-2023), 2016 (110): 64-72.
- [20] Qiu F, Zhang B, Guo J. A Deep Learning Approach for Vm Workload Prediction in the Cloud[C]. 2016 17th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD). New York: IEEE Press, 2016: 319-324.
- [21] Becker W, Paruolo P, Saisana M, et al. Handbook of uncertainty quantification: Weights and Importance in Composite Indicators: Mind the Gap[M]. Berlin: Springer, 2015: 1-30.
- [22] Deb K, Thiele L, Laumanns M, et al. Scalable Test Problems for Evolutionary Multiobjective Optimization [M]. Berlin: Springer, 2005.
- [23] Abraham A, Jain L C, Goldberg R. Evolutionary Multiobjective Optimization: Theoretical Advances and Applications[M]. Berlin: Springer, 2005.
- [24] Redmond M. UCI Machine Learning Repository[EB/OL]. (2009-07)[2020-06-10].<http://archive.ics.uci.edu/ml>.
- [25] Li Y, Gong G, Li N. A Comprehensive Performance Evaluation Framework of Complex Products Based on a Fuzzy AHP and DS Theory[J]. International Journal of Modeling, Simulation, and Scientific Computing (S1793-9623), 2016, 7(3): 1-18.