

6-25-2020

## Intelligent Evaluation of Simulation Training for Aerial Ammunition Technical Support

Xu Gang

*Battle Support Experiment & Simulation Training Center, Air Force Logistics College, Xuzhou 221000, China;*

Zhang Lei

*Battle Support Experiment & Simulation Training Center, Air Force Logistics College, Xuzhou 221000, China;*

Tian Lei

*Battle Support Experiment & Simulation Training Center, Air Force Logistics College, Xuzhou 221000, 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 Evaluation of Simulation Training for Aerial Ammunition Technical Support

## Abstract

**Abstract:** Quantitative evaluation is an important part of the simulation training of the Aviation Ammunition technical support. In order to realize the automatic evaluation of the simulation training, intelligent evaluation technology is introduced, and a prediction model based on Sigmoid regression is proposed. On the basis of analyzing the linear relationship of the sample data of the performance indicators, a subset of the characteristic indicators is selected as the input of the prediction mathematical model. In order to avoid the gradient descent method falling into the local solution problem, the gradient descent + PSO algorithm is presented. After testing the result samples, the algorithm can find the global optimal solution under the given precision. The prediction results have no over-fitting and under-fitting problems. In the actual practice, it is no longer necessary to input the subjective results of the examiners and experts, and the advantages of the computer-based simulation training automatic quantitative evaluation are brought into play.

## Keywords

aerial ammunition, simulation training; intelligent evaluating, particle swarm optimization, gradient descent method

## Recommended Citation

Xu Gang, Zhang Lei, Tian Lei. Intelligent Evaluation of Simulation Training for Aerial Ammunition Technical Support[J]. Journal of System Simulation, 2020, 32(6): 1103-1116.

## 航空弹药技术保障模拟训练智能评估

徐刚, 张磊, 田磊

(空军勤务学院 作战保障实验与模拟训练中心, 江苏 徐州 221000)

**摘要:** 量化评估是航空弹药技术保障模拟训练的一个重要环节, 为了实现模拟训练自动评估, 引入智能评估技术, 从中提出一种基于 Sigmoid 回归的预测模型。在分析成绩指标样本数据线性关系基础上, 选择特征指标子集作为预测数学模型的输入, 为了避免梯度下降法陷入局部解问题, 给出“梯度下降+粒子群”求解算法。经过成绩样本测试, 求解算法能够寻找到全局最优解, 而且基于 Sigmoid 模型预测效果没有发生过拟合和欠拟合问题。在实际应用时, 可以不需要依赖主观评估成绩, 发挥基于计算机技术的模拟训练自动量化评估优势。

**关键词:** 航空弹药; 模拟训练; 智能评估; 粒子群算法; 梯度下降法

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2020) 06-1103-14

DOI: 10.16182/j.issn1004731x.joss.18-0672

## Intelligent Evaluation of Simulation Training for Aerial Ammunition Technical Support

Xu Gang, Zhang Lei, Tian Lei

(Battle Support Experiment &amp; Simulation Training Center, Air Force Logistics College, Xuzhou 221000, China)

**Abstract:** Quantitative evaluation is an important part of the simulation training of the Aviation Ammunition technical support. In order to realize the automatic evaluation of the simulation training, intelligent evaluation technology is introduced, and a prediction model based on Sigmoid regression is proposed. On the basis of analyzing the linear relationship of the sample data of the performance indicators, a subset of the characteristic indicators is selected as the input of the prediction mathematical model. In order to avoid the gradient descent method falling into the local solution problem, the gradient descent + PSO algorithm is presented. After testing the result samples, the algorithm can find the global optimal solution under the given precision. The prediction results have no over-fitting and under-fitting problems. In the actual practice, it is no longer necessary to input the subjective results of the examiners and experts, and the advantages of the computer-based simulation training automatic quantitative evaluation are brought into play.

**Keywords:** aerial ammunition; simulation training; intelligent evaluating; particle swarm optimization; gradient descent method

## 引言

航空弹药技术保障是一项技术性很强的工



收稿日期: 2018-10-12 修回日期: 2018-12-03;  
基金项目: 空军勤务学院重点青年基金 (KY2018F006A);  
作者简介: 徐刚(1977-), 男, 辽宁开原, 博士, 副教授, 研究方向为军事装备系统建模与仿真; 张磊(1978-), 男, 安徽桐城, 硕士, 实验师, 研究方向为空军勤务保障仿真实验。

作, 具有技术要求严格、保障活动繁琐、作业过程危险等特点, 为了提高保障人员技能, 需要不断增强日常军事训练。航空弹药技术保障训练包括实兵实装训练和模拟训练 2 种方式, 而评估是航空弹药技术保障训练重要环节, 它是对航空弹药技术保障的制定计划、启封分解、检查测试等勤务过程模拟训练的效果综合评价。

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

• 1103 •

为全面评估航空弹药技术保障模拟训练效果,按传统的做法,需要建立评估指标体系,如制定计划的“保障资源配置合理性、方案规范性”评价,指挥员“指挥时机、人员调配”组织指挥能力评价,保障分队成员的“装备操作熟练性、协同作业顺畅性”保障能力评价等指标内容,这种综合评估方法使得定性与定量交织在一起,在实施考核评估时,几乎各个评估环节都需要考官和专家凭借经验主观参与打分,这样势必给组织施训的筹措、调配人员增加一定工作量,没有充分发挥基于计算机技术的模拟训练自动化评估优势。

模拟训练考核评估方法较多,根据其考核评估机制可分为以下 3 类:单因素评估法、综合评估法和智能评估法<sup>[1]</sup>。智能评估是指应用人工智能理论、方法和技术的自动化评估<sup>[2]</sup>。智能评估法能很好的解决考核评估中存在的一些难题,随着各行业对模拟训练需求的增加,智能评估法的研究也取得了一些成果<sup>[2-4]</sup>。文献[2]利用 BP 神经网络和深度学习算法对获取的“发电机组频率差、电压差、相位差、操作时间等”大量数据样本反复训练后得到较好的评估模型,实现了船舶机舱协作式模拟训练智能评估。文献[3]通过模拟器识别复杂的飞行动作等飞参数据,根据这些数据利用专家系统按照评分规则进行评判,实现了飞行模拟器飞行训练质量的计算机智能评估。文献[4]将轮机模拟器节点状态“电网频率、电压、转移负载、额定功率”等作为客观评估指标集,基于模糊综合评判设计并开发了轮机模拟器的智能评估功能。上述代表文献共同特点:首先是具备大量的数据样本为评估模型提供支撑,其次是评估特征指标都为客观数据,如“飞参、电压”等评估指标,这些指标数据可以通过硬件采集设备很容易获取和得到。而本研究指标体系是客观与主观指标共同组成,且样本数量少,不能形成自动化考核评估环境。因此,上述文献所采用方法和模型有各自的应用背景和目的,并不完全适合在航空弹药技术保障模拟训练智能评估应用。

关于综合评估法和智能评估法尤其在军事后勤模拟训练应用和研究相关文献却为鲜见,文献[5]虽然将后勤保障模拟训练的评估问题分解为后勤保障模拟训练系统效能评估和后勤保障模拟训练组织与实施效能评估,为本研究指明了方向,但没有指出采用何种方法或技术手段。在训练科目给定情况下,装备数量和设备工作时间可以认为是基本不变量,那么弹药技术保障的指挥员组织能力、分队队员间协同性、队员操作熟练程度能够直接或间接反映完成任务总时间长短变化,所以基于这种变化特点可以对指标集降维处理,替换这些主观指标,再通过智能技术(尤其是机器学习技术)实现模拟训练的智能评估。

## 1 航空弹药技术保障训练评估概述

航空弹药技术保障活动是以保障分队为单位,成员间实施协同作业,保障人员在不熟练掌握技术规范情况下不能进行保障活动,需要先单兵学习、训练,后进行分队训练和考核评估。对于单兵训练,主要侧重个人的技能训练,掌握和熟练操作规范,对于分队训练,主要熟练成员间协同配合,在安全作业前提下提高保障效能。

单兵模拟训练考核评估主要采用扣分法和加分法<sup>[1]</sup>,通过模拟训练系统对单兵保障流程正误自动判断,累加正确步骤分值计算评定结果。毕竟单兵模拟训练不能代替真实的训练,然后还要在真实的装备上体验和检验,熟练各种工具的使用;实装单兵考核主要侧重对工具使用熟练程度的考核,采用考官和专家主观打分。

在分队综合保障训练中,由于受场地和训练装备限制,分队实兵实装训练只能对简单内容的科目进行训练与评估,如:某弹型检测准备阶段作为训练科目等,考核科目种类受到限制,考核过程中采用考官和专家打分方式。而模拟训练科目内容虽然具有不受装备和场地限制的优势,但模拟训练对分队保障技术安全规范性评估不容易量化,这类评估放到单兵训练和分队实装训练更

为妥当。

综上所述, 每种训练方式都有其优点和局限性, 考核评估指标内容和指标权重不能一概而论, 应各有侧重点进行考核评估, 评估方法或形式也应有所区分, 发挥各自评估手段的优势, 如图 1 所示, 对于实兵实装采用主观评估方法, 主要对技术保障规范、安全操作等方面评价, 而模拟训练充分利用计算机技术优势采用自动化评估, 对保障流程、协同作业等方面评价。本文主要是对航空弹药技术分队综合保障模拟训练评估方法研究, 对于单兵模拟训练评估不做本文研究范围。

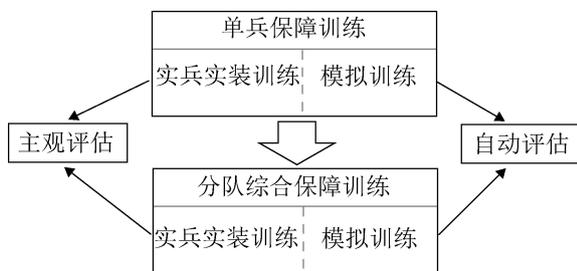


图 1 训练评估方式

Fig. 1 Training and assessment methods

## 2 评估数据分析与特征指标选择

### 2.1 数据分析

航空弹药技术保障是否能高效、安全、快速、可靠地完成军事任务受多种因素的影响, 如: 保障装备的数量、单个装备效能、保障人员数量、人员操作装备的熟练程度、组织指挥的决策部署等。在航空弹药技术保障模拟训练中某科目的分队模拟训练评估共有 6 个指标, 分别是“人员配置  $X_1$ ”、指挥员的“指挥时机  $X_2$ 、人员调配  $X_3$ ”、队员的“作业协同性  $X_4$ 、装备操作熟练性  $X_5$ ”和装备操作的“步骤正确率  $X_6$ ”, 对应的权重值是  $W=\{0.2, 0.1, 0.1, 0.1, 0.1, 0.4\}$ , 分队模拟训练综合评分  $Z$  则是指标的加权和, 即:

$$Z = W \cdot X^T = W_1X_1 + W_2X_2 + \dots + W_6X_6 \quad (1)$$

从模拟训练系统中抽取前 5 条评分记录, 指标集与记录数据对应关系如表 1 所示。

表 1 某科目的评估指标和前 5 条记录

评估 总分	人员 配置	指挥 时机	人员 调配	作业 协同性	操作 熟练性	步骤 正确率
	0.2	0.1	0.1	0.1	0.1	0.4
0.958	0.9	0.95	0.95	0.95	0.93	1
0.616	0.55	0	0	0.7	0.76	0.90
0.745	0.65	0.65	0.65	0.73	0.8	0.83
0.927	0.8	0.9	0.9	0.92	0.95	1
0.907	0.75	0.88	0.9	0.89	0.9	1

在表 1 中有 0 分情况, 主要由人员配置不合理所导致, 比如在表 2 中第 2 条记录角色 1 是指挥员, 由于人员配置没有分配指挥员角色, 导致整体评分低的结果。

表 2 某科目的人员配置评分前 5 条记录

人员配 置评分	角色 1 数量	角色 2 数量	角色 3 数量	角色 4 数量
0.9	1	1	4	1
0.55	0	1	4	1
0.65	1	1	6	0
0.8	1	0	4	1
0.75	1	1	5	1

在上述指标中, 主观数据有: 人员配置、指挥时机、人员调配、作业协同性和装备操作熟练性, 在评估环节根据模拟训练情况由考官主观评分; 客观数据有: 步骤正确率和各个角色人员数量, 其中步骤正确率是由模拟训练系统判断操作步骤正误自动累计计分得到; 另外, 运用模拟训练系统进行模拟时, 计算机也记录了模拟训练完成任务时间; 从模拟训练系统抽取 80 条记录, 分别查看“完成任务时间  $X_0$ ”与上述指标评分关系分布情况, 如图 2 所示。

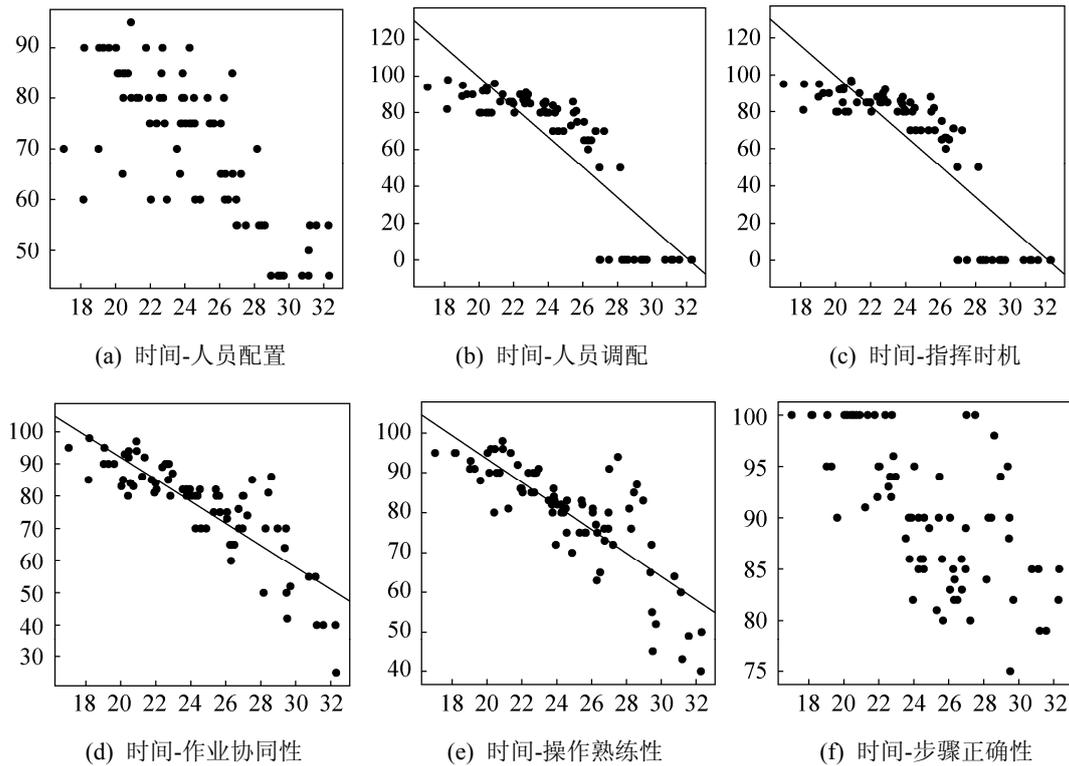


图 2 完成任务时间-各个指标成绩关系散点分布

Fig. 2 Completion of task time - scatter distribution of performance scores for each index

图 2(a)~(f)中横坐标表示“完成任务时间(分钟)”，纵坐标表示各个指标评分结果，分别表示“人员配置评分见图 2(a)、人员调配评分见图 2(b)、指挥时机评分见图 2(c)、作业协同性评分见图 2(d)、操作熟练性评分见图 2(e)和步骤正确性评分见图 2(f)”。在  $X_0$  与各个“指标值”关系散点分布图中，较为直观反映“完成任务时间”与“指挥时机、人员调配、作业协同性和操作熟练性”的线性程度，要高于“完成任务时间”与“人员配置、步骤正确率”线性程度。根据式(2)计算各个指标间的相关系数  $\rho_{xy}$ ：

$$\rho_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (2)$$

式中： $\rho_{xy}$ 为任意 2 个指标  $x, y$  的线性相关系数，描述指标样本间的线性相关程度，分别计算指标间  $\rho_{xy}$  绝对值，其线性相关系数分布情况如图 3。

图 3 中的坐标数字代表：0 为完成任务时间、1 为人员配置、2 为指挥时机、3 为人员调配、4

为作业协同性、5 为装备操作熟练性、6 为步骤正确率；不难发现，相关系数  $\rho_{23}$  和  $\rho_{45}$  值基本接近 1，而且  $\rho_{02}$ ， $\rho_{03}$ ， $\rho_{04}$  和  $\rho_{05}$  数值在 0.85 左右，明显高于  $\rho_{01}=0.76$  和  $\rho_{06}=0.68$ ，其中“2, 3, 4, 5”指标与“0”存在较大程度线性相关性，在训练模型时容易产生数据冗余，不利于模型训练，因此有必要对它进行降维处理。

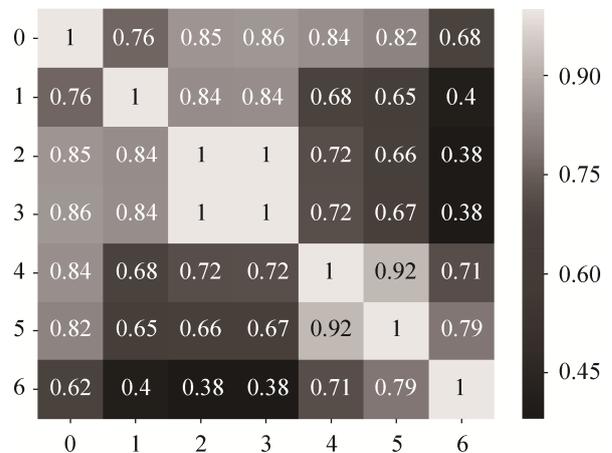


图 3 成绩数据的相关系数分布

Fig. 3 Correlation coefficient distribution of score data

## 2.2 特征指标选择

特征选择是在数据集中查找和选择最有用的特征的过程, 是机器学习的关键步骤<sup>[6]</sup>。这里“特征”是上述所说的成绩评估指标。除了特征选择, 也可以通过特征变换映射的方式(如 PCA、LDA、ICA 等)降维, 将高维特征空间映射到低维空间, 降低计算复杂度。

本文特征指标选择目的除了为减少数据集中特征冗余外, 还希望预测模型不要依赖这些主观特征指标, 在尽可能保留更多信息前提下剔除主观特征指标, 最终实现自动化评估的目的。若采用特征变换映射的方式进行降维, 势必在应用时还是要依赖主观指标进行评估计算。比如采用 PCA(主成分分析)法将一个 2 维矩阵映射到 1 维, 假设输入为  $m \times 2$  矩阵, 首先将该矩阵特征向量中的第一主成分作为转换矩阵, 即得到一个  $2 \times 1$  转换矩阵, 再用输入矩阵右乘转换矩阵得到  $m \times 1$  输出矩阵, 达到映射 1 维目的; 不难知道, 无论是训练模型阶段, 还是测试阶段或应用, 需要给我一个 2 维数据, 我才能用转换矩阵来映射到 1 维, 若这个 2 维数据中有主观特征指标, 岂不是还要依赖这个主观指标计算, 没有剔除主观指标特征目的。因此, 这里就不采用特征指标变换映射的方式进行降维。

另外可以通过选取特征子集的方式也能达到降维目的, 但若选择不合适的特征子集, 容易增加信息的损失, 降低预测模型计算的有效性。在机器学习中常采用线性相关系数判断筛选特征子集<sup>[7]</sup>, 线性相关程度越高, 则可以只选择其中一个特征, 尤其高度相关的特征, 如共线特征, 可以相互表示, 替换掉其中一个不会减弱特征的预测能力, 但要考虑不同程度的线性相关评估指标替换后对模型预测有效性影响。

设  $x, y$  是评估集中任意 2 个不同的特征指标,  $x, y \in X$ , 样本为  $x_i, y_i$ , 且要求  $x, y$  对应样本  $\sum(x_i - \bar{x})^2 \neq 0, \sum(y_i - \bar{y})^2 \neq 0$  条件, 其中  $\bar{x}, \bar{y}$  是

特征指标  $x, y$  均值; 设  $W_x, W_y$  是对应  $x, y$  权重且不等于 0,  $W_x, W_y \in W$ 。同时, 设  $y$  是  $x$  线性表达式为  $y = \alpha + \beta x + e$ , 其中  $\alpha, \beta$  是参数项,  $e$  是误差项或残差项, 对  $y$  的估计为:

$$\hat{y} = \hat{\alpha} + \hat{\beta}x \quad (3)$$

式中:  $\hat{\alpha}, \hat{\beta}$  是参数  $\alpha, \beta$  估计, 那么  $y$  是  $x$  的线性表达式也可以写成:

$$y = \hat{\alpha} + \hat{\beta}x + \hat{e} \quad (4)$$

那么表达式(1)综合评分  $Z$  可以写成:

$$Z = W_x x + W_y y + W' \cdot X'^T = W_y \hat{\alpha} + (W_x + W_y \hat{\beta})x + W' \cdot X'^T + W_y \hat{e} \quad (5)$$

式中:  $W' \cdot X'^T$  是不包含  $x, y$  指标特征的其它项加权和。则对  $Z$  的估计为:

$$\hat{Z} = W_x x + W_y \hat{y} + W' \cdot X'^T = W_y \hat{\alpha} + (W_x + W_y \hat{\beta})x + W' \cdot X'^T \quad (6)$$

求解参数可以采用最小二乘法<sup>[7]</sup>, 联立式(3)~(6)不难推导出其离散随机变量的误差表达式(或损失值表达式)为:

$$Q = \sum(Z_i - \hat{Z}_i)^2 = W_y^2 \sum(y_i - \hat{y}_i)^2 = W_y^2 \sum \hat{e}_i^2 \quad (7)$$

通过求参数偏导, 并偏导为 0, 不难推导出  $\hat{\beta}$  为:

$$\begin{cases} \hat{\beta} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sum(x_i - \bar{x})^2} \\ \hat{\alpha} = \bar{y} - \hat{\beta}\bar{x} \end{cases} \quad (8)$$

在式(7)中, 由于  $W_y$  是不等于 0 的常数项, 那么对  $\hat{Z}_i$  估计的准确程度与  $\hat{y}_i$  相关, 其误差变化主要由残差平方和  $\sum \hat{e}_i^2$  决定, 也就是随机误差  $RSS = \sum(y_i - \hat{y}_i)^2 = \sum \hat{e}_i^2$ , 而对  $\hat{y}$  估计的准确程度可以采用拟合优度  $R^2$  进行评价<sup>[6-7]</sup>, 即:

$$R^2 = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} = 1 - \frac{\sum \hat{e}_i^2}{\sum(y_i - \bar{y})^2} \quad (9)$$

式中:  $TSS = \sum(y_i - \bar{y})^2$  是总的平方和,  $\bar{y}$  为  $y$  样

本均值。根据总离差分解<sup>[6]</sup>, 有  $TSS=ESS+RSS$ , 其中  $ESS=\sum(\hat{y}_i-\bar{y})^2$ , 式(9)也可以写成  $R^2=ESS/TSS$ , 对  $\hat{y}$  与  $y$  拟合(回归)结果进行评估:

$$R_{\hat{y}y}^2 = \frac{\sum(\hat{y}_i-\bar{y})^2}{\sum(y_i-\bar{y})^2} = \frac{\sum(\hat{y}_i-\bar{y})^2 \sum(x_i-\bar{x})^2}{\sum(y_i-\bar{y})^2 \sum(x_i-\bar{x})^2} = \frac{\hat{\beta}^2 [\sum(x_i-\bar{x})^2]^2}{\sum(y_i-\bar{y})^2 \sum(x_i-\bar{x})^2} \quad (10)$$

把式(8)中的  $\hat{\beta}$  代入式(10), 得:

$$R_{\hat{y}y}^2 = \frac{[\sum(y_i-\bar{y})\sum(x_i-\bar{x})]^2}{\sum(y_i-\bar{y})^2 \sum(x_i-\bar{x})^2} = \rho_{xy}^2 \quad (11)$$

也就是  $\hat{y}$  与  $y$  一元线性拟合优度等于  $x$ 、 $y$  线性相关系数的平方, 联立式(7)、(9)和(11), 得到表达式为:

$$\sum(y_i-\hat{y}_i)^2 = \sum\hat{e}_i^2 = TSS \cdot (1-\rho_{xy}^2) \quad (12)$$

在给定样本数量一定情况下, 且条件  $\sum(y_i-\bar{y})^2 \neq 0$ , 则  $TSS$  是不等于 0 的常数项, 那么误差  $\sum\hat{e}_i^2$  大小变化主要取决于线性相关系数平方  $\rho_{xy}^2$  的大小。由于  $\rho_{xy}^2 \in [0, 1]$ , 不难推导出  $\sum\hat{e}_i^2 \in [0, TSS]$ , 也就是说指标特征  $x$ 、 $y$  在强相关时, 误差接近于 0,  $\hat{y}$  能对  $y$  准确估计; 当  $\rho_{xy}^2=1$  时, 使得随机误差变量  $\hat{e}=0$ , 所求出的参数估计  $\hat{\alpha}$ 、 $\hat{\beta}$  代入表达式(4)中, 那么特征指标  $x$  无损失地表示了  $y$ , 此时表达式(5)~(6)中的  $Z$  和  $\hat{Z}$  没有区别, 替换掉其中  $y$  不会影响  $\hat{Z}$  预测有效性。但是由表达式(7)和(12)得知: 当随着  $\rho_{xy}^2$  趋于 0 时, 误差增大,  $\hat{Z}$  偏离  $Z$  增大, 导致  $\hat{Z}$  准确性和有效性下降, 信息严重丢失。因此, 在应用时根据实际需要合理设置  $\rho_{xy}$  阈值删选特征指标。

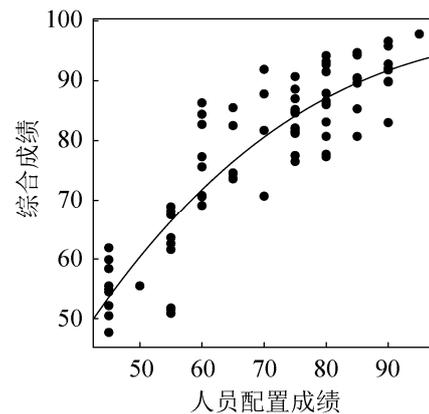
根据 2.1 节的数据分析, 若取  $|\rho_{xy}|>0.8$  作为选择特征指标标准, 那么主观特征指标相关系数符合条件从大到小顺序为  $|\rho_{23}|$ ,  $|\rho_{45}|$ ,  $|\rho_{12}|$  或  $|\rho_{13}|$ , 从中可筛选指标特征有  $X_1$ ,  $X_3$  和  $X_4$ 。又由于客观特征指标“完成任务时间  $X_0$ ”与“人员调配  $X_3$  和作业协同性  $X_4$ ”也有较强的相关性, 即  $|\rho_{03}|$ ,  $|\rho_{04}|>0.8$ , 因此可用  $X_0$  替换  $X_3$  和  $X_4$ 。虽然“人员

配置  $X_1$ ”是主观特征指标, 但可以由“角色扮演数量”配置情况预测, 其配置数量情况属于客观特征指标, 因此保留  $X_1$ 。综上所述, 根据特征指标间的线性相关系数, 把线性相关性较低的“完成任务时间  $X_0$ 、人员配置  $X_1$  和步骤正确率  $X_6$ ”3 个指标作为输入特征指标子集。

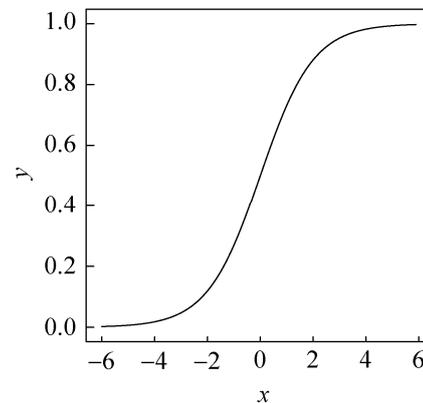
### 3 数学模型

#### 3.1 基于 Sigmoid 回归的预测模型

经过特征评估指标子集选择、指标间的替换, 必然会损失一部分信息, 而且综合成绩  $Z$  与上述三个特征指标也存在一定程度的非线性关系见图 4(a), 使得原综合评分模型表达式(1)不能有效评估结果, 需要产生一个新的预测模型代替。



(a) 人员配置成绩-综合成绩



(b) 标准 Sigmoid 曲线

图 4 预测曲线形态对比

Fig. 4 Comparison of predicted curve shapes

对于这种非线性关系, 在机器学习中可以采用多项式回归、决策树回归和神经网络等预测模型, 但实践应用效果并不理想(后面有测试)或存在一定局限。图 4(a)是 3 阶多项式回归曲线, 由于样本数量较少, 用于训练的输入集数据不能涵盖所有可能的定义域范围, 导致测试或应用时预测值有可能超出成绩范围(成绩可缩至[0,1]范围), 例如: 对于“完成任务时间”指标  $t$ , 有  $t > 0$ , 存在定义域上不封顶情况, 在多项式“阶数”较小情况下, 多项式预测值时有可能超过[0,1]范围; 另外, 多项式“阶数”最优值需要反复测试, “阶数”值太大容易过拟合, 过小容易预测值误差偏大, 因此采用多项式回归存在一定局限性。在各个指标与综合成绩数据关系分析中, 不难发现在定义域范围内成绩数据趋近 1 或 0, 并整体呈现单调递增或递减, 这种变化特点与图 4(b)标准 Sigmoid 曲线相似, 所以基于这种成绩数据特点, 选用 Sigmoid 函数作为预测模型, 其标准 Sigmoid 表达式为:

$$g(z) = 1 / (1 + e^{-z}) \quad (13)$$

式(13)的导数, 推导出关系式(14):

$$g(z)' = g(z)(1 - g(z)) \quad (14)$$

为了动态拟合评估数据分布形态, 将航空弹药技术保障模拟训练评估数据映射到 Sigmoid 函数中去, 表达式变为:

$$\begin{cases} h_{\theta}(x) = g(\theta^T x) = \frac{1}{1 + e^{-\theta^T x}} \\ \theta^T x = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n \end{cases} \quad (15)$$

式中:  $\theta = [\theta_0, \theta_1, \theta_2, \dots, \theta_n]^T$  是量化评估指标的系数;  $n$  是指标总数+1,  $x_1, x_2, \dots, x_n$  是指标变量; 降维后的航空弹药技术保障模拟训练评估指标“完成任务时间、步骤正确率和人员配置”分别对应“ $x_1, x_2, x_3$ ”变量, 其系数分别对应“ $\theta_1, \theta_2, \theta_3$ ”,  $\theta_0$  是常数项, 则所求解参数为  $\theta = [\theta_0, \theta_1, \theta_2, \theta_3]^T$ 。

### 3.2 样本数据预处理

考虑若用原始数据,  $\theta^T x$  计算的结果之间跨度相对较大, 不适合直接回归 Sigmoid 函数, 这

样会导致拟合后曲线趋向直线, 失去了 S 型曲线描述数据的有效性, 因此有必要对数据无量纲化处理; 对应百分制评分数据分别乘以 0.01, 对于“完成任务时间”指标数据采用归一化处理, 使其分布较小区域内  $x^{(i)} \in [-1, 1]$ :

$$x^{(i)} = (t_i - \bar{t}) / (t_{\max} - t_{\min}) \quad (16)$$

式中:  $\bar{t}, t_{\max}, t_{\min}$  为时间样本平均值、最大值和最小值,  $x^{(i)}$  为无量纲样本数据。

为了提高模型泛化能力, 考虑实际应用时数据有可能不在训练集的定义域范围内, 表达式(16)的  $x^{(i)} \in [-1, 1]$  只是训练集的范围, 在测试或应用时  $\bar{t}, t_{\max}, t_{\min}$  同样沿用训练集的值。

### 3.3 目标损失函数模型

在机器学习中, 损失函数是描述样本输出值与真实值之间的误差程度, 通过调整该函数中若干待定系数, 使得该函数与已知点集的差别最小<sup>[6]</sup>。在分类或者回归问题中, 通常使用损失函数作为其目标函数, 即目标损失函数, 通过目标损失函数寻找数据的最佳匹配系数。这里采用最小二乘法<sup>[7]</sup>定义目标损失函数:

$$\min J(\theta) = \frac{1}{2} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 \quad (17)$$

式中:  $m$  为样本总数, 是第  $i$  样本的真实值;  $h_{\theta}(x^{(i)})$  为第  $i$  样本的输出值。对于最小二乘无约束优化问题, 可以采用梯度下降法<sup>[8]</sup> (Gradient Descent)求解参数  $\theta$  最优值, 梯度下降是迭代法的一种。在求解  $\theta$  时, 首先对目标损失函数求偏导, 根据式(14), 推导目标损失函数(17)的偏导函数为:

$$\begin{cases} \nabla_{\theta_j} J(\theta) = \frac{\partial J(\theta)}{\partial \theta_j} \\ \frac{\partial J(\theta)}{\partial \theta_j} = \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) h_{\theta}(x^{(i)}) (1 - h_{\theta}(x^{(i)})) x_j^{(i)} \end{cases} \quad (18)$$

式中:  $\nabla_{\theta_j} J(\theta)$  为  $\theta_j$  的梯度值;  $\partial J(\theta) / \partial \theta_j$  为对第  $j$  个系数  $\theta_j$  求偏导;  $x_j^{(i)}$  为系数  $\theta_j$  对应指标的第  $i$  个样本值。

对于  $\theta$  参数, 可以采用梯度下降法求解, 具体算法步骤如下:

step 1: 处理样本数据, 进行无量纲计算  $x_i$  值。

step 2: 变量初始化, 包括: 学习率或步长( $\alpha$ )、收敛精度( $e$ )、最多迭代次数( $K$ )、形状参数( $\theta$ )。

step 3: 计算梯度下降距离, 并判断精度是否满足条件, 若满足要求则退出迭代。下降距离表达式如式(19)所示:

$$d = \alpha * \nabla J(\theta) \quad (19)$$

step 4: 按梯度的反方向更新  $\theta$  参数, 然后判断是否满足迭代次数, 满足迭代次数退出循环, 否则重复 step 3。其表达式如式(20)所示:

$$\theta := \theta - d \quad (20)$$

#### 4 模型参数寻优算法——梯度下降+粒子群

考虑目标损失函数  $J(\theta)$  的 Hessian 矩阵很难判断其“正定性”, 不能确定在全域范围内都是“凸集”, 采用梯度下降法寻优受初始值影响, 其解不能确保全局最优, 但梯度下降法又容易满足精度。粒子群优化算法是一种进化计算技术, 1995年由 Eberhart 博士和 Kennedy 博士提出, 源于对鸟群捕食的行为研究, 利用群体中的个体对信息的共享使整个群体的运动在问题求解空间中产生从无序到有序的演化过程, 追随当前搜索到的最优值来寻找全局最优<sup>[9]</sup>; 该算法有较高的收敛速度, 而且容易寻找到全局最优。所以, 为了满足给定精度下寻找全局最优解, 将梯度下降法结合粒子群算法来求解模型参数。

根据回归优化原理, 可以把目标问题的可行解空间假想为粒子的  $D$  维搜索空间,  $D$  代表该问题中的变量数目。目标问题的所有可行解如同散布在空间中的离散点, 粒子在某时刻所处的位置  $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$  对应问题的一个可行解, 其中  $p_{ij}(i=1, 2, \dots, N; j=1, 2, \dots, D)$  的值表示粒子  $i$  所对应的 Sigmoid 函数中第  $j$  个参数数值, 也就是说粒子和某个 Sigmoid 函数相对应, 而粒子的每一维

的坐标和 Sigmoid 函数中每个参数数值所对应:  $N$  表示初始粒子群中的粒子数;  $[p_{j,\min}, p_{j,\max}]$  表示粒子在第  $j$  维空间上的活动范围, 其中  $p_{j,\min}$  表示参数  $j$  的最小值,  $p_{j,\max}$  表示参数  $j$  的最大值。粒子通过不断地进化, 不断地改变位置, 逐渐到达处于最佳适应度值的位置, 即参数的最优值, 这是采用粒子群算法的一般过程。由于受粒子速度的影响, 在更新粒子最优位置时有可能跳过要求精度的位置, 也就是当前最优解可能不能满足精度要求, 因此, 在粒子群最优解基础上继续进化, 利用梯度下降法逼近所要求的精度; 梯度下降+粒子群寻优算法实质就是寻找粒子群中粒子个体样本方差最小和梯度下降距离值最小的过程。图 5 为结合 2 种方法的算法流程图。

(1) 初始化粒子群和梯度参数: 初始化内容主要包括粒子群粒子个数( $N$ )、学习因子( $c_1, c_2$ )、惯性权重最大值和最小值( $W_{\max}, W_{\min}$ )、粒子群速度的最大值和最小值( $V_{\max}, V_{\min}$ )、步长( $\alpha$ )、收敛精度( $e$ )、最多迭代次数( $K$ ), 计算粒子的随机初始位置( $p_{ij}$ )和随机初始速度( $v_{ij}$ ), 其中 rand 是产生 0~1 之间随机数函数:

$$\begin{cases} p_{ij} = (p_{j,\max} - p_{j,\min}) * \text{rand} + p_{j,\min} \\ v_{ij} = (V_{\max} - V_{\min}) * \text{rand} + V_{\min} \end{cases} \quad (21)$$

(2) 更新粒子个体最优值: 是通过比较粒子群个体适应度值(个体样本方差值)来更新粒子个体最优值, 即: 与上一迭代  $k-1$  粒子群的粒子个体最优适应度值  $pBest(i, k-1)$  比较, 比较结果的最小值作为  $k$  代的个体最优适应度值  $pBest(i, k)$ , 将粒子个体最优位置存储在  $pB_{ij}$  中。

(3) 更新全局最优位置: 通过比较  $m$  代粒子群的个体最优适应度值, 将最小值  $pBest(i, k)_{\min}$  与上一代  $m-1$  粒子群全局最优值  $gBest(k-1)$  比较, 结果的最小值作为  $m$  代粒子群的全局最优值  $gBest(m)$ , 将粒子全局最优位置存储在  $g$  中。

(4) 更新粒子速度和位置: 其算式为:

$$\begin{cases} v_{ij} := w * v_{ij} + c_1 * \text{rand} * (pB_{ij} - p_{ij}) + c_2 * \text{rand} * \\ (g - p_{ij}) \\ p_{ij} := p_{ij} + v_{ij} \\ w = W_{\max} - (W_{\max} - W_{\min}) * k / K \end{cases} \quad (22)$$

式中:  $w$  是  $k$  代粒子群的惯性权重。

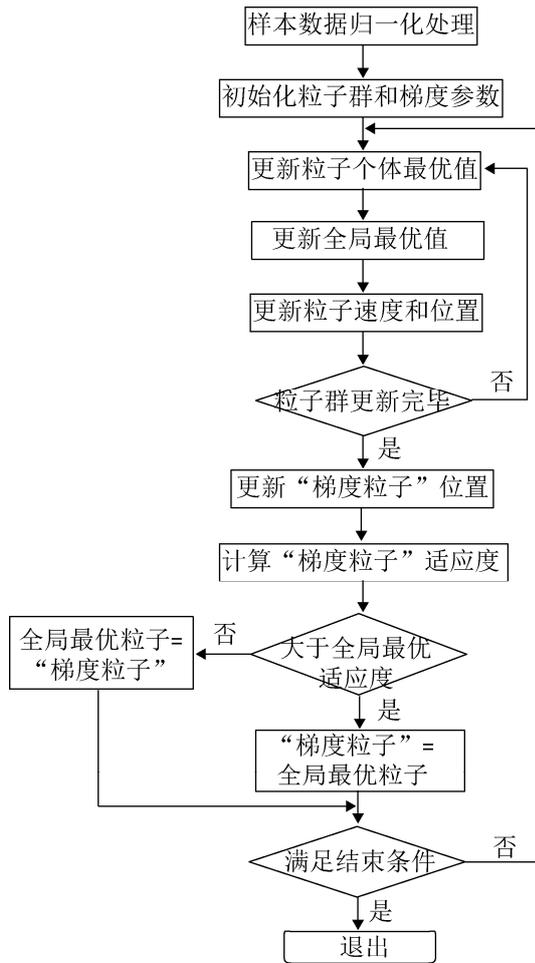


图 5 算法流程图

Fig. 5 Algorithm flow

(5) 更新“梯度粒子”位置: 梯度粒子是粒子群特殊个体, 除了具备粒子的位置和速度属性外, 还具有粒子个体的梯度和适应度计算功能; 更新梯度粒子的位置主要有 2 种方式: 一是通过式(18)~(20)计算粒子位置, 先计算梯度下降距离, 然后按梯度的反方向更新粒子的位置; 二是通过与全局最优粒子个体比较, 最优的结果作为梯度粒子的最新位置。

(6) 计算“梯度粒子”适应度: 将梯度粒子的最新位置代入到目标损失函数(17)中计算适应度值  $pJ$ , 若  $pJ > gBest$ , 更新梯度粒子位置, 否则更新全局最优粒子位置。

(7) 退出条件: Fans van den Bergh 指出粒子群优化算法的收敛是指粒子群中的某个粒子最终停留在搜索空间的某一个固定位置<sup>[10]</sup>。粒子群的历史最佳适应度值  $gBest$  是迭代信息  $k$  的一个函数, 随  $k$  的变化,  $gBest(k)$  不断地变化, 且当  $k \rightarrow \infty$  时,  $gBest(k)$  趋向于一个固定的值。因此, 可以选择 2 种方式选择退出, 一是设置较大的迭代次数  $K$ , 当  $k > K$  时寻优退出; 二是设置条件精度  $E$ , 这里引进梯度下降距离判断是否满足精度作为程序终止条件, 来提高收敛速度, 减少不必要的计算, 即:  $|d| < E$ ; 当不能满足精度条件, 设置一个最大进化代数  $K_{\max}$ , 使得程序运行  $k > K_{\max}$  代后自动终止, 把当前找到的最优解作为全局最优解。

## 5 算例及测试

从航空弹药技术保障模拟训练科目评分数据库中抽取 80 个样本, 分成 2 组, 其中一组 60 个样本作为训练集, 另一组 20 个样本作为测试集, 分别进行测试。

### 5.1 算法寻优测试

(1) 梯度下降法寻优: 设置算法迭代次数  $K=25\ 000$ , 步长  $\alpha=0.2$ , 随机设定初始值集合为:  $\theta = \{[1, 1, 1, 1], [-1, -1, -1, -1], [-2, -2, 2, 2]\}$ , 分别对集合中初始参数测试, 得到结果如表 3 所示。

表 3 初始值对结果的影响

Tab. 3 Effect of initial values on results

初始参数 $\theta$	结果参数 $\theta$	精度 $e$	训练集 $R^2$	测试集 $R^2$
[1, 1, 1, 1]	[6.62, -5.63, -3.38, -3.07]	0.122	0.749	0.515
[-1, -1, -1, -1]	[9.77, -7.17, -5.27, -5.00]	0.195	0.603	0.191
[-2, -2, 2, 2]	[-2.42, -1.64, 2.42, 2.39]	0.016	0.968	0.966

表 3 的第 3 行结果明显优于前 2 行, 损失值精度更小, 拟合优度更接近于 1, 说明只采用梯度下降法求解参数时, 受初始值设置影响很大, 容易陷入局部最优解。

(2) 粒子群算法测试及对比: 设置算法初始参数为: 学习因子( $c_1=1.5, c_2=0.5$ )、惯性权重最大值和最小值( $W_{\max}=1.5, W_{\min}=0.3$ )、粒子群速度的最大值和最小值( $V_{\max}=5, V_{\min}=-5$ )、迭代次数( $K=200$ )、粒子个体的位置最大和最小值( $p_{j,\max}=10, p_{j,\min}=-10$ ), 粒子个数分别为  $N=\{5,10,15,20,30,50,70,100\}$  时, 对比测试“梯度下降+粒子群”算法损失值精度的情况; 由于粒子群算法是一种随机算法, 相同参数每次计算结果可能不同, 为了减少这种随机性影响, 同种参数运行 100 次试验, 取其平均值作为最终损失值精度。比较的结果如图 6 所示。

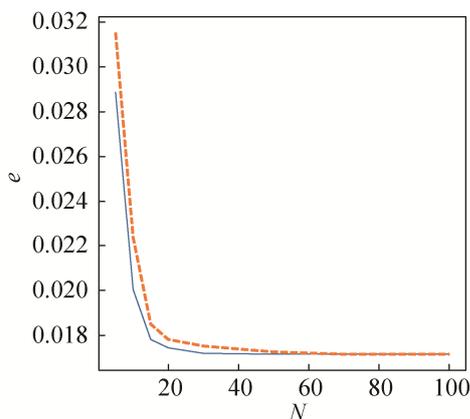


图 6 粒子群个数对损失值精度的影响  
Fig. 6 Influence of number of particle groups on the accuracy of loss value

图 6 中的虚线是粒子群算法的精度变化曲线, 实线是“梯度下降+粒子群”算法的精度变化曲线, 当粒子数大于 60, 2 种算法寻优并无明显区别, 都能找到全局最优解; 当粒子数目较少时, “梯度下降+粒子群”算法寻优精度略占优势。

(3) 梯度下降+粒子群算法测试: 设置粒子个数  $N=20$ , 步长  $\alpha=0.5$ , 迭代次数  $K=200$ , 其它初始参数不变, 寻优过程的收敛情况见图 7。

图 7 中的“**A**”处呈现折线下降趋势, 表明粒子群算法在快速寻优起了明显作用, 而“**B**”处呈现平滑下降趋势, 表明梯度下降法在寻优区域进一步提高精度起了优化作用。

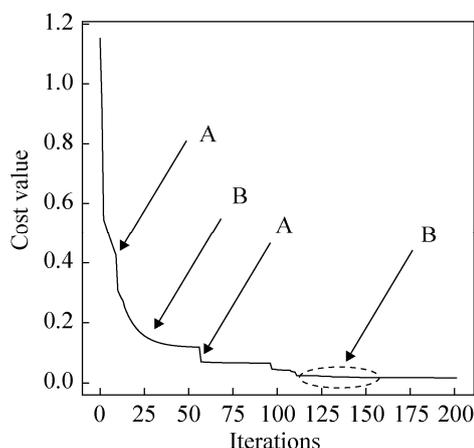
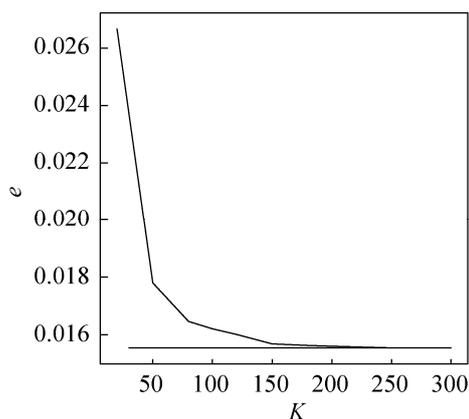


图 7 损失值变化曲线  
Fig. 7 Loss curve

#### (4) 迭代次数 $K$ 和 $K_{\max}$ 对寻优影响测试

第一种情况: 将  $K$  值作为迭代退出条件, 考察不同  $K$  对寻优影响: 设置粒子个数  $N=20$ , 步长  $\alpha=0.5$ , 迭代次数分别为  $K=\{30, 60, 90, 120, 150, 180, 210, 240, 270, 300\}$ , 其它初始参数不变, 并且相同参数运行 100 次试验, 取其最小  $e$  的均值作为当前  $K$  值对应的损失值精度, 运行结果如图 8 所示。



(a) 设置不同迭代次数  $K$  对损失值精度的影响

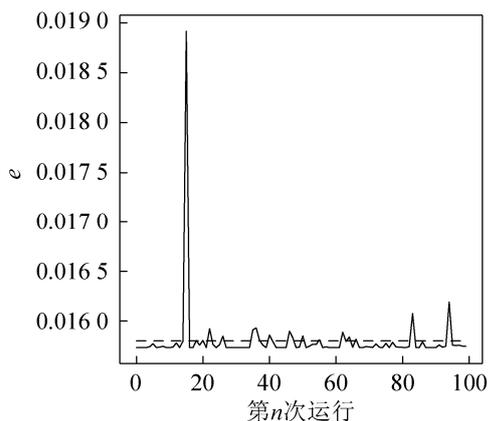
(b)  $K=150$  运行 100 次试验

图 8 设置不同  $K$  值对寻优影响  
Fig. 8 Influence of setting different  $K$  values on optimizing

在图 8(a)中, 可以借用统计学方法确定稳定区间<sup>[11]</sup>, 其计算表达不等式为:

$$n \times \sum e_i^2 - (\sum e_i)^2 \leq (n \times \sigma)^2$$

取样本数量  $n \in \{2, 3, \dots, 10\}$  (因为共 10 个  $K$  值), 每连续  $n$  个  $e_i$  为一组, 若标准差  $\sigma=0.0005$  作为稳定条件, 计算和比较各组是否满足计算表达不等式, 把满足条件的所有组中最小  $i$  对应  $K$  值作为  $K$  的下限, 取  $i+n-1$  对应  $K$  值上限; 通过简单算法不难计算  $K$  的最大稳定区间在  $[150, 300]$ , 也就是说当  $K \geq 150$  时  $e$  趋向一个最小稳定值, 认为找到了全局最优。另外, 图 8(b)是设置  $K=150$  时运行 100 次, 考察每次试验  $e$  的最小值变化曲线, 得到  $e$  均值为 0.0158 (见图 8(b)中虚线), 标准差为 0.00032, 计算变异系数(标准差/均值)为 0.02, 说明只有少数试验没有完全收敛, 大多数情况是以很小方差稳定在均值附近, 认为设置  $K=150$  时多数情况能够寻找到全局最优; 同时, 在图 8(a)中也直观表明了大约  $K \geq 150$  时损失值精度变化非常缓慢, 基本趋向于一个固定的值。

第二种情况: 将条件精度  $E$  作为迭代退出条件, 考察  $K_{\max}$  范围多少能够满足条件精度  $E$  要求。若设置条件精度为  $E=0.016$ , 最大迭代次数为  $K_{\max}=300$ , 运行 100 次试验, 其结果如图 9 所示。

统计这 100 次试验数据, 计算平均实际迭代

次数约为 185 次, 最大实际迭代次数 224, 最小实际迭代次数 97 次, 标准差 20.11; 假设“实际迭代次数  $K$ ”服从正态分布(可由假设检验验证), 若置信水平为 0.05, 根据文献[6]知识, 查  $t$  分布表得  $t_{0.025}(100-1)=1.984$ , 计算均值的置信区间在  $[185 \pm 3.99]$ , 同理, 通过查卡方表计算标准差的置信区间在  $[17.58, 23.23]$ , 为了满足概率  $P(K < K_{\max}) = 1 - 0.05$  的  $K_{\max}$  最大可能值, 分别取均值和标准差的上限作为正态分布参数, 即  $K \sim N(189, 23.23^2)$ , 若置信水平 0.05, 查标准正态表的单边置信区域上限是 1.645 倍标准差, 计算得  $K_{\max}=227.21$ ; 因此, 当设置  $K_{\max} > 227.21$  时, 多数情况下能满足条件精度  $E=0.016$  要求, 概率在 0.95 以上。

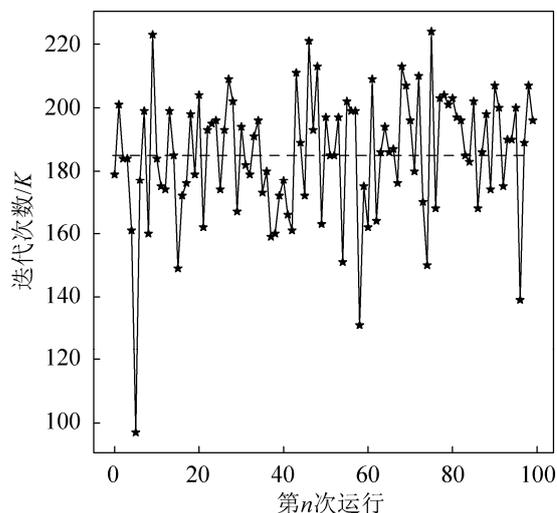


图 9  $E=0.016$  对应的实际迭代次数  
Fig. 9  $E=0.016$  corresponds to the actual number of iterations

综合上述 2 种情况测试, 若选择迭代次数作为寻优退出条件,  $K$  需要大于 150, 基本能使误差  $e$  趋向一个固定值; 若选择条件精度  $E$  作为寻优退出条件, 最大迭代次数  $K_{\max}$  需要大于单边置信区间上限(根据实际  $E$  需要而定)。

## 5.2 效果测试

由于样本空间不同, 导致寻优结果  $\theta$  在某个区间变化, 不是确切的值, 为了提高基于 Sigmoid 预测模型的泛化能力, 采用交叉验证方法, 将交

又验证集解的均值作为最终模型参数。这里把训练集 60 个样本平均分成 6 等份(每 10 个样本 1 份), 其中一份 10 个样本作为交叉验证集, 其它样本作为交叉训练集, 那么就有 6 组结果, 如表 4 所示。

表 4 交叉验证结果  
Tab. 4 Cross validation results

组号	计算结果 $\theta$	交叉训练集 $R^2$	交叉验证集 $R^2$
1	-2.02, -1.83, 2.37, 2.01	0.967	0.943
2	-2.61, -1.40, 2.89, 2.24	0.969	0.972
3	-2.31, -1.51, 2.68, 2.06	0.971	0.904
4	-2.84, -1.37, 2.85, 2.54	0.968	0.974
5	-2.94, -1.28, 3.04, 2.48	0.971	0.962
6	-2.66, -1.35, 3.16, 2.12	0.977	0.912

对 6 组计算结果取平均值  $\theta=[-2.56, -1.46, 2.83, 2.24]$  作为预测模型参数, 预测成绩结果如图 10~11 所示。

图 10~11 中的“•”是原始样本评分数据散点, “x”是预测模型计算数据散点; 根据拟合优度表达式(9), 计算训练集拟合优度  $R^2=0.971$ , 测试集拟合优度  $R^2=0.964$ , 计算结果与样本数据差距较小, 而且没有发生过拟合或欠拟合问题, 基本能满足模拟训练成绩评估需要。

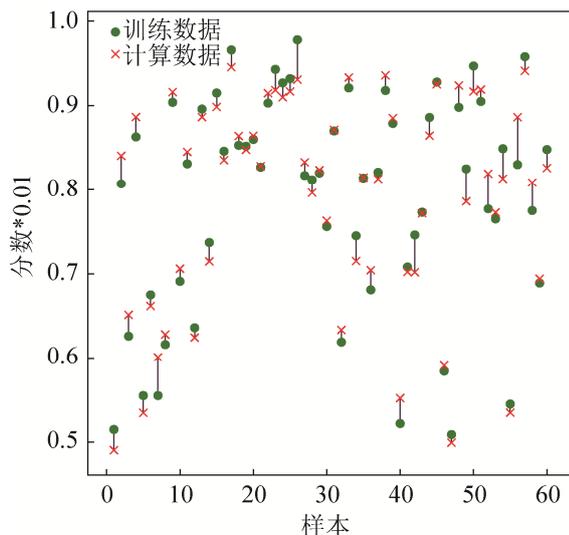


图 10 训练集的预测成绩分布

Fig. 10 Prediction score distribution of training set

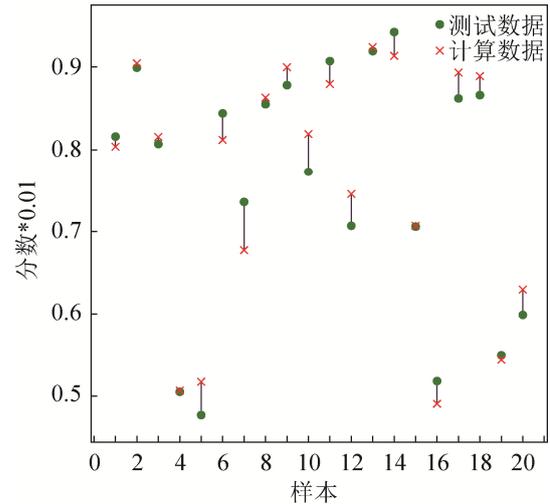


图 11 测试集的预测成绩分布

Fig. 11 Prediction score distribution of test set

### 5.3 模型比较

机器学习中还有许多优秀智能方法<sup>[7]</sup>, 课题选择几个常用的预测模型或算法进行比较, 采用相同的训练集和测试集, 计算它们的拟合优度值如表 5 所示。

表 5 模型比较

Tab. 5 Method comparison

方法	主要参数	Train $R^2$	Predict $R^2$
决策树回归	max_depth=8	0.999	0.832
BP	hidden_layer_size=(5,)	0.983	0.875
GBRT	D=3, $\alpha=0.05$ , M=80	0.998	0.951
Sigmoid 回归	$\theta=[-2.56, -1.46, 2.83, 2.24]$	0.971	0.964

表 5 中的参数是经过在训练集反复调节并取拟合优度最好所对应的主要参数, 分别表示: max\_depth=8 表示回归树的最大树深度为 8; hidden\_layer\_size=(5,) 表示神经网络隐藏层为 5, 神经元个数默认; “D=5,  $\alpha=0.5$ , M=80” 分别表示集成学习模型(梯度渐进回归树 GBRT)的回归树深度为 5、步长为 0.5 和回归树数量为 80。其中集成学习预测模型的拟合优度值表现较为优秀, 而本文提出的基于 Sigmoid 回归预测模型虽然在训练集表现不如常用模型效果, 但在测试集表现更为突出。

由于样本空间不同, 各个模型预测效果也不同, 采用 5.2 节相同的交叉验证集比较 GBRT 和 Sigmoid 回归模型预测稳定性, 如图 12 所示。

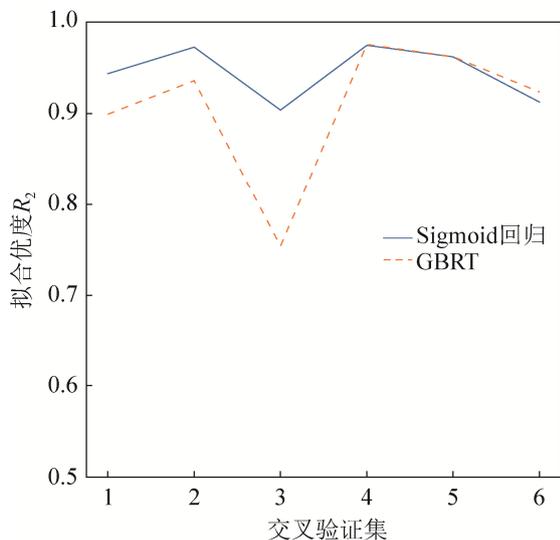


图 12 2 种模型预测效果比较

Fig. 12 Comparison of two prediction models

图 12 中实线是 Sigmoid 回归预测模型效果  $R^2$  评估曲线, 虚线是 GBRT 模型效果  $R^2$  评估曲线; 基于 Sigmoid 回归预测模型基本稳定在 0.9 评估值以上, 而 GBRT 模型存在低于 0.9 评估值情况, 并且效果整体水平比 GBRT 模型略有优势。

但值得注意的是: 基于 Sigmoid 回归模型比上述通用机器学习模型占优势的主要原因是根据数据分布形态“人为介入”选择回归模型, 从而能较好地拟合数据趋势走向, 而其它机器学习通用模型并不知道数据形态状况, 需要以“大数据”样本训练作为基础, 才有可能预测准确结果; 但本研究的航空弹药技术保障模拟训练的分队评估功能由于实践应用过程非常繁琐, 目前处于“搁置”状态, 只有前期实践时积累的一些少量样本数据。因而, 为了重启分队模拟训练评估功能, 发挥计算机优势, 给出了上述研究。

## 6 结论

为了实现航空弹药技术保障模拟训练自动成绩评估, 引入智能评估技术。从中提出基于

Sigmoid 预测模型, 对样本数据降维处理后保留客观成绩评估指标, 为了克服梯度下降法解算参数时容易陷入局部解, 结合了粒子群算法来寻找全局最优值, 经过实际样本测试, 模型具有较满意成绩预测效果和稳定性, 而且模型简单。在实际应用时, 只需根据“完成任务时间、步骤正确率和人员配置”3 个指标进行模拟训练成绩评估, 无需再依赖考官和专家主观参与打分, 能够发挥基于计算机技术的模拟训练自动化评估优势, 该智能评估方法可为航空弹药技术保障模拟训练的定量评估提供新途径, 也可为其军事勤务保障模拟训练定量评估提供技术参考。

虽然基于 Sigmoid 预测模型简单, 但求解算法“梯度下降+粒子群”的参数较多, 调节参数过程非常耗时和繁琐, 还需要进一步优化。另外, 特征评估指标“完成任务时间”与“指挥时机、人员调配、作业协同性、装备操作熟练性”指标要有较强的线性相关性, 否则不能替换, 因此具有一定应用要求和条件。

## 参考文献:

- [1] 肖剑波, 胡大斌, 胡锦涛, 等. 考核评估系统研究综述[J]. 舰船电子工程, 2016, 36(1): 15-19.  
Xiao Jianbo, Hu Dabin, Hu Jinhui, et al. Review of Intelligent Evaluation System[J]. Ship Electronic Engineering, 2016, 36(1): 15-19.
- [2] 段尊雷, 任光, 张均东, 等. 船舶机舱协作式模拟训练智能评估[J]. 交通运输工程学报, 2016, 16(6): 82-90.  
Duan Zunlei, Ren Guang, Zhang Jundong, et al. Intelligent Assessment for Collaborative Simulation Training in Ship Engine Room[J]. Journal of Traffic and Transportation Engineering, 2016, 16(6): 82-90.
- [3] 范敏毅, 杨新明, 马强, 等. 飞行模拟器训练的计算机智能评估[J]. 系统仿真学报, 2013, 25(8): 1811-1815.  
Fan Minyi, Yang Xinming, Ma Qiang, et al. Application of Computer Brainpower Evaluating in Flight Simulator Training[J]. Journal of System Simulation, 2013, 25(8): 1811-1815.
- [4] 曹辉, 马玉鑫, 贾宝柱. 基于模糊综合评判的轮机模拟器智能评估系统[J]. 大连海事大学学报, 2015, 41(1): 104-108.  
Cao Hui, Ma Yuxin, Jia Baozhu. An intelligent evaluation

- system of marine engine room simulator based on fuzzy comprehensive evaluation[J]. Journal of Dalian Maritime University, 2015, 41(1): 104-108.
- [5] 曹琦, 王文政. 军事后勤保障模拟训练基本理论框架研究[J]. 军事运筹与系统工程, 2017, 31(2): 76-80.  
Cao Qi, Wang Wenzheng. Research on the Basic Theoretical Framework of Military Logistics Support Simulation Training[J]. Military Operations Research and Systems Engineering, 2017, 31(2): 76-80.
- [6] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.  
Zhou Zhihua. Machine Learning[M]. Beijing: Tsinghua University Press, 2016.
- [7] 东华大学概率统计教研组. 概率论与数理统计[M]. 北京: 高等教育出版社, 2017: 2.  
Probability and statistics teaching and research group of Donghua University. Probability Theory and Mathematical Statistics[M]. Beijing: Higher Education Press, 2017: 2.
- [8] Stephen Boyd. 凸优化[M]. 北京: 清华大学出版社, 2013.  
Stephen Boyd. Convex Optimization[M]. Beijing: Tsinghua University Press, 2013.
- [9] 陈宝林. 最优化理论与算法[M]. 北京: 清华大学出版社, 2005.  
Chen Baolin. Optimization Theory and Algorithm[M]. Beijing: Tsinghua University Press, 2005.
- [10] 杨虎, 许峰. 基于聚集密度的粒子群多目标优化算法[J]. 计算机工程与应用, 2013, 49(17): 190-194.  
Yang Hu, Xu Feng. Multi-objective Particle Swarm Optimization Algorithm Based on Crowding-density[J]. Computer Engineering and Applications, 2013, 49(17): 190-194.
- [11] 李娜, 黄孝彬, 田志强, 等. 生产过程数据稳定性判断的一种方法[J]. 华电技术, 2010, 32(1): 32-34, 38.  
Li Na, Huang Xiaobin, Tian Zhiqiang, et al. A Decision Method of Production Process Data Stability[J]. Huadian Technology, 2010, 32(1): 32-34, 38.