

基于混合 PSO-Adam 神经网络的外协供应商评价决策模型

李益兵, 宋东林, 王 磊[†]

(1. 武汉理工大学 机电工程学院, 武汉 430070; 2. 数字制造湖北省重点实验室, 武汉 430070)

摘 要: 当前复杂外协环境中外协加工资源的分散性、多样性、动态性、组合性对制造企业的外协供应商评价提出了更高的要求,这使得传统的方法难以满足当前环境下外协供应商评价的需求. 对此,提出一种基于混合 PSO-Adam 神经网络的外协供应商评价决策模型,以弥补多目标决策方法主观性太强、数学规划方法难以求解复杂问题以及经典神经网络方法的性能不稳定等缺陷. 为验证模型的有效性,以某建材装备制造企业外协供应商评价问题实例进行实验分析,并与其他现有算法进行对比. 结果表明,该决策模型能够针对当前复杂的外协环境客观高效地进行外协供应商评价决策,进一步减少对个人经验的依赖,降低供应商评价难度,减少供应链管理成本.

关键词: 供应商评价; 混合 PSO-Adam 算法; 神经网络优化; 外协管理

中图分类号: TP18; F274

文献标志码: A

Based on hybrid PSO-Adam neural networks decision making model for outsourcing supplier evaluation

LI Yi-bing, SONG Dong-lin, WANG Lei[†]

(1. School of Mechanical and Electronic Engineering, Wuhan University of Technology, Wuhan 430070, China;

2. Hubei Digital Manufacturing Key Laboratory, Wuhan 430070, China)

Abstract: The decentralization, diversity, dynamic and combination of the outsourcing resources in the current complex outsourcing environment put forward higher requirements for the management of the manufacturing enterprises, which makes the traditional methods difficult to meet the needs of outsourcing supplier evaluation in the current situation. In this paper, a decision making model for outsourcing supplier evaluation based on hybrid PSO-Adam neural networks is proposed to solve the defect of multiattribute decision making methods, mathematical programming methods and classical neural networks methods. In order to validate the validity of this model, an example of the building materials manufacturing enterprises outsourcing supplier evaluation is carried out and compared with other existing algorithms. The results show that this model can solve the problem of evaluation of suppliers objectively and efficiently in the current complex outsourcing environment, and reduce the reliance on personal experience, the difficulty of supplier evaluation and the cost of supply chain management.

Keywords: supplier evaluation; hybrid PSO-Adam algorithm; neural network optimization; outsourcing management

0 引 言

随着人工智能、大数据、物联网和云计算等新兴技术在制造业的不断深入,引发了以全球化、信息化、智能化、智慧化和绿色化为发展方向的新一轮产业革命,企业的制造环境也发生了根本性的变革. 越来越多的企业选择与其他企业进行网络化的协同制造,并将一些非核心的加工需求交给更为专业的外协供应商,以专注于自身核心竞争力的提高. 当前,复杂的外协环境给制造企业提供了更多样化的外协加工资

源,然而外协加工资源的分散性、多样性、动态性、组合性也对制造企业的外协供应商的评价提出了更高的要求,使得传统的方法难以满足当前环境下对外协供应商评价的需求. 因此,有必要开发一种新的外协供应商决策模型,进一步减少传统方法对个人经验的依赖,降低供应商评价的难度,减少供应链管理成本,以适应当前复杂的外协环境^[1].

针对供应商评价问题,国内外学者进行了大量研究. Chan 等^[2] 针对服装与纺织行业的灵活、快速变

收稿日期: 2017-07-16; 修回日期: 2017-10-16.

基金项目: 国家自然科学基金项目(71171154); 中央高校基本科研业务费专项资金项目(2017II27GX).

责任编委: 孙秋野.

作者简介: 李益兵(1978—), 男, 副教授, 博士, 从事智能制造与企业信息化等研究; 宋东林(1994—), 男, 硕士生, 从事智能算法与信息系统的研究.

[†]通讯作者. E-mail: wanglei9455@126.com

化的特点,使用 Expert Choice 设计了一种基于层次分析法(AHP)的供应链选择模型. Numery^[3]开发了一种 AHP 的变体以解决多目标决策中的排序问题,且针对大规模决策问题进行了优化. Roshandel 等^[4]为解决洗涤剂行业的供应商选择和评估问题,提出了使用基于分层模糊决策的理想解法(TOPSIS)进行求解. Deng 等^[5]提出了一种基于 TOPSIS、模糊集理论(FST)和证据理论(DST)的多目标决策方法,以解决供应商选择问题. 王先甲等^[6]运用马氏距离改进传统的 TOPSIS 的距离计算,并给出了该方法在供应商选择中的应用. Deng^[7]以信息系统供应商评估指标体系为基础,使用模糊综合评价法(MCE)建立了信息系统供应商评价模型. Golmohammadi 等^[8]开发了一种基于灰色关联分析的供应商选择决策模型,并将其应用于汽车行业产品供应商排序. 针对供应商评估在可持续供应链管理环境中的特点, Azadi 等^[9]开发了一种改进模糊数据包络模型(DEA). Falagarío 等^[10]则使用 DEA 交叉分析法解决了公共招标中的供应商选择问题. 为了根据产品质量进行供应商评估, Hsu 等^[11]基于模糊集理论和非线性规划方法(NLP)提出了一种基于质量的供应商评价方法. Chen 等^[12]研究模糊集背景下的多目标决策问题,开发了一种基于线性规划(LP)与模糊理论的供应商选择问题解法. Lee 等^[13]基于人工神经网络(NN)开发了一个供应商选择与谈判的智能决策系统,为供应商的选择提供决策支持. Güneri 等^[14]提出了一种基于 NN 和模糊推理系统的方法以解决供应商选择问题. 目前,主要的供应商评价方法及其对比如表 1 所示.

供应商评价方法可以分为三类:多目标决策方法、数学规划方法、人工智能方法. AHP、TOPSIS 等多目标决策方法简单有效,得到了广泛的运用,但此类方法主观性较强,需要依据人的知识、直觉和洞察力作判断. DEA、LP、NLP 等数学规划方法在解决简单问题时,能够得到准确、客观的结果,但是社会、生产和经济系统的复杂性和非确定性导致所面临的许多问题无法抽象出清晰的数学模型,并且在问题较大且复杂的情况下很难得到精确的解析解,针对当前复杂的外协环境,该方法难以取得较好的效果. 人工智能方法针对复杂的问题能够获得较好的效果,神经网络能够挖掘和学习数据间复杂且微妙的深层关系,且神经网络由数据驱动,不依赖个人经验,将定性分析与定量分析有效结合,很大程度上保证了供应商评价与选择结果的客观性,因此,神经网络非常适于解决供应商评价问题^[17].

表 1 主要的供应商评价方法对比^[15-16]

方法类型	方法名称	优点	缺点
多目标决策方法	AHP ^[2-3]	操作简单、易于计算	依赖专家知识,主观因素较大,易出现判断矩阵的不一致性
	TOPSIS ^[4-6]	削弱了指标量纲对数据带来的不良影响,结果较为可靠	主观性较强,矩阵的计算量过大
	MCE ^[7]	定性指标比较容易量化,可操作性强	依赖领域专家知识,参数选择较难
	CST ^[8]	对样本没有严格的要求,不要求服从特定的分布	指标权重不易确定,有一定的主观性
数学规划方法	DEA ^[9-10]	准确、客观	算法较为复杂,可操作性差
	LP/NLP ^[11-12]	方法描述简单,应用较广	实际问题难以抽象出清晰的数学模型,面对复杂情况很难得到精确解析解
人工智能方法	NN ^[13-14]	定性分析与定量分析有效结合,很大程度上保证了供应商评价与选择结果的客观性	收敛速度慢,容易局部次优收敛,性能受参数选取的影响较大

然而,使用随机梯度下降法(SGD)训练的经典神经网络收敛速度较慢,性能较不稳定,因为缺乏对全局最优的关注,容易局部次优收敛,当遭遇高维空间中广泛分布的鞍点时也难以逃脱,训练会陷入停滞^[18]. 另外,经典的神经网络收敛性能很大程度上取决于网络的初始权值和算法中学习率等参数的选择,而合适的参数很难选取^[19].

有研究者开始研发多种算法相结合的神经网络混合优化算法,以弥补单一算法的缺陷. Ismail 等^[20]成功地将 PSO-BP 混合算法应用于轴向桩的荷载-形变分析. 许少华等^[21]针对时变输入/输出过程神经网络的训练问题,提出一种基于混沌遗传与带有动态惯性因子的粒子群优化相结合的学习方法. 但是,目前仍缺少针对复杂外协环境下基于混合优化神经网络的外协供应商评价方法的研究.

对此,本文提出一种基于混合 PSO-Adam 神经网络的外协供应商评价决策模型,继承神经网络准确客观、能够解决复杂问题的优点,并弥补基于经典神经网络存在的收敛速度慢、容易局部次优收敛、难以逃脱鞍点、参数难选取的缺陷. PSO 是一种基于进化与群体智能的元启发式算法,较遗传算法更容易实

现,能一定程度上解决训练局部次优收敛和收敛速度慢等问题^[22-24]. Adam是一种基于自适应矩估计的随机目标函数优化算法,能为每一个参数自适应地计算学习率,能解决学习率等参数难以确定的问题^[25]. 所以,本文的决策模型在全局优化阶段,引入 PSO 进行并行寻优,跳过局部次优点和鞍点,将初始点优化到全局极值点附近,降低局部次优收敛与鞍点驻留的几率,进一步降低模型的误差,提高供应商评价的准确度. 在局部优化阶段,引入 Adam 为每个参数自适应地计算学习率,更简单高效地搜索全局极值点,学习率不依赖人工设定,从而降低实施难度,提高稳定性,令供应商评价的结果更加客观可信.

使用该决策模型进行外协供应商评价,首先需要基于供应商评价指标体系确定神经网络的结构与 PSO 的粒子编码方式. 在神经网络的训练阶段,混合 PSO-Adam 算法先对粒子种群进行随机初始化,然后根据粒子迭代规则进行 PSO 全局优化. 若 PSO 在限定的迭代次数内获得满意解,则结束训练;若在限定的迭代次数内未能获得满意解,则对所有粒子按照适应度进行排序,将适应度最佳的多个粒子优化后的初始权值阈值分别导入多个神经网络,并使用 Adam 进行局部优化. 若 Adam 在限定的迭代次数内获得满意解,则结束训练;若在限定的迭代次数内未能获得满意解,则重启 PSO 重新开始全局优化. 神经网络训练完毕后,将待评价外协供应商的指标输入神经网络模型,神经网络模型的输出即是该外协供应商的评价值.

为了验证算法的有效性,本文建立了制造业外协供应商评价指标体系,并以某建材装备制造企业的外协供应商评价问题为实例,开展混合 PSO-Adam 算法与多种现有神经网络训练算法的对比实验. 分别使用本文所提出的混合 PSO-Adam、SGD、带 Nesterov 动量的 SGD、Adagrad^[26]、Adam^[25]、PSO-BP^[20] 训练神经网络进行外协供应商评价. 混合 PSO-Adam 算法在应用过程中不需要设置学习率等参数,优化结果不受学习率等初始参数的影响,具有更好的性能稳定性. 通过对比各训练算法的收敛曲线可知,混合 PSO-Adam 算法在保持较高精度的同时,拥有比其他算法更快的收敛速度. 通过对比混合 PSO-Adam 与 PSO-BP 这两种混合算法训练的网络的均方误差 (MSE) 和拟合优度 (R^2),证明在使用神经网络求解外协供应商评价问题时,混合 PSO-Adam 神经网络能够避免训练陷入局部次优点和鞍点,使训练能够全局最优收敛,比 PSO-BP 混合算法优化的神经网络的收敛精度

更高,对数据集的拟合度更优. 综上所述,基于混合 PSO-Adam 神经网络的外协供应商评价决策模型有助于弥补基于经典神经网络的供应商评价方法存在的收敛速度慢、容易局部次优收敛、难以逃脱鞍点、参数难选取的缺陷. 应用实例表明,此评价方法能够客观且高效地解决复杂的外协环境下的外协供应商评价问题.

1 制造业外协供应商评价指标体系的建立

制造企业的外协供应商的评价按如下步骤进行:

Step 1: 企业根据自身外协需求和特点,拟定评价工作的目标期望和评价目标,最终形成科学合理的评价指标体系.

Step 2: 采集待考察外协供应商的必要数据信息.

Step 3: 对于定量指标,根据相关数据依照评价指标体系计算得到评分.

Step 4: 对于定性指标,建立专家评价小组进行评分.

专家小组对定性指标评价的评分分为 5 档,如表 2 所示.

表 2 定性指标打分表

等级	很好	好	一般	差	很差
得分	0.9	0.7	0.5	0.3	0.1

Step 5: 借助相应软件或算法计算分析,得出评价结果.

本文结合制造业的外协特点和实际需求,在外协供应商评价原则的基础上,建立基于目标层、准则层、指标层的三级评价指标体系. 目标层即为外协供应商的综合能力;准则层分为 8 类,分别为质量水平、交付能力、制造加工能力、信息传递能力、变更处理能力、成本水平、企业内外环境、服务水平;指标层是以这 8 类准则而展开的 22 个指标层,制造业外协供应商评价指标体系如表 3 所示.

2 算法设计

基于混合 PSO-Adam 神经网络的外协供应商评价决策模型主要可以分为 3 个阶段: 数据处理阶段、混合 PSO-Adam 训练神经网络阶段、外协供应商评价阶段. 其中混合 PSO-Adam 训练神经网络阶段主要包括神经网络与 PSO 结构设计、PSO 全局优化、Adam 局部优化等关键步骤. 在全局优化阶段,使用 PSO 将训练初始点优化到全局极值点附近,使训练跳过局部次优点和鞍点,在一定程度上缓解训练局部次优收敛与鞍点驻留的问题. 在局部优化阶段,引入 Adam 代替 SGD,使训练能够自适应地为每个参数计算学习

表3 制造业外协供应商评价指标体系

准则层	指标层	类型	计算公式	备注
质量水平 Z_1	质检合格率 QR	定量	$QR = \frac{N_Q}{N_T} \times 100\%$	N_T : 质检件总数 N_Q : 质检合格件总数
	质量稳定性 QS	定量	$QS = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$ $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$	n : 交付批次 x_i : 每次的质检合格率 \bar{x} : 平均质检合格率
	故障发生率 FR	定量	$FR = \frac{N_B}{N_Q} \times 100\%$	N_Q : 质检合格件总数 N_B : 使用时故障件总数
	质量保障体系 QAS	定性	无	无
交付能力 Z_2	平均交货提前期差额 DL	定量	$DL = \frac{\sum_{i=1}^n (T_i - \bar{T}_i)}{N}$	T_i : 某供应商的交货提前期/天 \bar{T} : 各供应商的平均交货提前期/天
	按期交货率 PD	定量	$PD = \frac{N_A}{N} \times 100\%$	N : 考察期内(季度/年)的总交货次数 N_A : 考察期内(季度/年)准时交货次数
	交付准确率 AD	定量	$AD = \frac{N_B}{N} \times 100\%$	N : 考察期内(季度/年)的总交货次数 N_B : 数量准确的正确件交付次数
制造加工能力 Z_3	生产和加工规模 PPS	定性	无	无
	制造加工人员素质 MP	定量	$MP = N_A + N_E + N_H$	N_A : 熟练技工人数 N_E : 工程师人数 N_H : 本科及以上学历人数
	先进设备比例 AB	定量	$AB = \frac{V_A}{V} \times 100\%$	V_A : 先进生产设备总价值/万元 V : 生产设备总价值/万元
	技术标准 TS	定性	无	无
信息传递能力 Z_4	信息化水平 IL	定性	无	无
	信息传递及时性 ITT	定性	无	无
	信息传递准确性 ITA	定性	无	无
变更处理能力 Z_5	加工要求变更完成率 PAS	定量	$PAS = \frac{N_C}{N} \times 100\%$	N : 考察期内(季度/年)加工要求变更的总次数 N_C : 考察期内(季度/年)完成加工要求变更的次数
	工期变更完成率 LTA	定量	$LTA = \frac{N_D}{N} \times 100\%$	N : 考察期内(季度/年)工期变更的总次数 N_D : 考察期内(季度/年)完成工期变更的总次数
成本水平 Z_6	加工报价差额 AP	定量	$AP = \frac{\sum_{i=1}^n (P_i - \bar{P}_i)}{N}$	N : 考察期内(季度/年)报价总次数 P_i : 供应商报价/(元/件) \bar{P}_i : 每次的供应商平均报价/(元/件)
	运输成本差额 ATC	定量	$ATC = \frac{\sum_{i=1}^n (C_i - \bar{C}_i)}{N}$	N : 考察期内(季度/年)运输报价次数 C_i : 某供应商的运输成本/(元/吨) \bar{C}_i : 每次的供应商平均运输报价/(元/吨)
长期合作能力 Z_7	信誉度 CRE	定量	$CRE = \frac{N_J}{N} \times 100\%$	N : 考察期内(季度/年)的合作总次数 N_J : 完整履行合同的次数
	财务状况 FS	定性	无	无
服务水平 Z_8	售前/售后服务水平 SA	定性	无	无
	敏捷反应 AR	定性	无	无

率,降低学习率等参数的选取对算法性能的影响,使算法实施更加简单,性能更加稳定. 混合 PSO-Adam

算法如图1所示. 下面详细探讨基于混合 PSO-Adam 神经网络的外协供应商评价决策模型的流程与步骤.

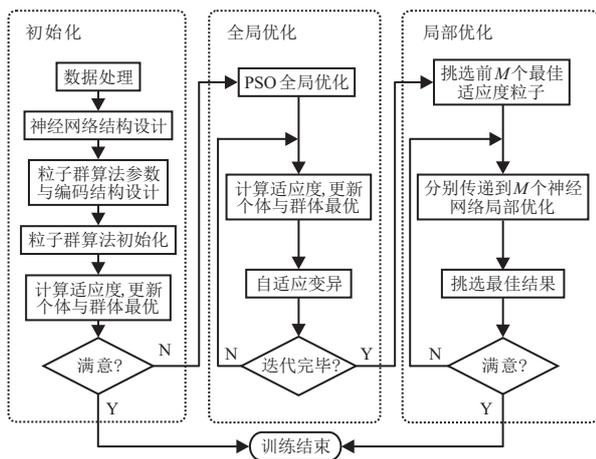


图1 混合 PSO-Adam 算法框图

Step 1: 数据处理.

本文使用留出法 (Hold-out) 直接将数据集 D 划分为两个互斥的集合, 其中一个集合作为训练集 S , 另一个作为测试集 T , 即 $D = S \cup T, S \cap T = \emptyset$. 在 S 上训练出模型后, 用 T 来评估其测试误差, 并作为泛化误差的估计.

为了防止因奇异样本数据的存在而可能引起的网络训练时间增加和网络无法收敛等问题, 在训练之前对样本数据集进行归一化处理. 本文用 min-max 标准化实现样本数据的归一化, 即

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}}. \quad (1)$$

其中: X 为未归一化的一个样本数据, X^* 为归一化后的一个样本数据, X_{\min} 为样本数据的最小值, X_{\max} 为样本数据的最大值.

Step 2: 神经网络结构设计.

神经网络的模型结构包括输入层、隐含层、输出层. 输入层和输出层的神经元数目由实际模型的样本决定. 本文的输入层即为表3中给出的制造业外协供应商评价指标体系中的22个指标, 故网络的输入层节点(神经元)个数为22; 而网络的输出值即为供应商的得分, 故网络的输出层节点(神经元)个数为1.

因为隐层数为1的神经网络已被证明在不限制神经网络节点数的同时, 可以实现任意非线性映射, 而且训练时间相对短, 精度能够达到要求^[27], 所以本文选用单隐含层的网络.

通常选择隐含层节点数 k 的经验公式有以下4种^[28]:

1) $\sum_{i=0}^n C_k^i > N$. 其中: n 为输入层节点数, k 为隐含层节点数, N 为样本数, 当 $i > k$ 时规定组合数 $C_k^i = 0$.

2) $k = \sqrt{n + m} + t$. 其中: n 为输入层节点数, k

为隐含层节点数, m 为输出层节点数, t 为 $[1, 10]$ 之间的常数.

3) $k = \log_2 n$. 其中: n 为输入层节点数, k 为隐含层节点数.

4) $k = \frac{n + m}{2}$. 其中: n 为输入层节点数, k 为隐含层节点数, m 为输出层节点数.

本文的外协供应商评价神经网络的输入层节点数为22, 输出层节点数为1, 即 $n = 22, m = 1$. 根据上述公式计算可知, 隐含层节点 k 的范围为 $[5, 15]$. 经过试验对比分析, 当 $k = 12$ 时, 神经网络的学习能力最强, 故确定神经网络的隐含层节点数为12.

外协供应商的评价问题本质上是一种广义多元回归问题, 因此, 将神经网络的目标函数设置为 MSE, 有

$$MSE = \frac{1}{mN} \sum_{p=1}^N \sum_{k=1}^m (d_k^p - y_k^p)^2 = \frac{1}{N} \sum_{p=1}^N (d^p - y^p)^2. \quad (2)$$

其中: m 为输出节点的个数, N 为训练样本数目, d_k^p 为网络期望输出值, y_k^p 为网络实际输出值.

为了让网络获得强大的非线性拟合能力, 本文在网络的激活层和输出层加入激活函数对神经元的输出进行映射. 按照 Bengio 的定义, 映射函数为 $h: R \rightarrow R$ 形式, 且几乎处处可导的函数^[29]. 常用的激活函数有 linear、sigmoid、tanh 等. 针对外协供应商评价问题, 本文通过实验比较, 选择 tanh 函数为隐含层和输出层的激活函数. 该函数不仅具有软饱和性, 能避免 sigmoid 产生的梯度消失问题^[30], 而且 tanh 收敛速度比 sigmoid 更快^[31]. tanh 公式如下所示:

$$\tanh(\chi) = \frac{1 - e^{-2\chi}}{1 + e^{-2\chi}}. \quad (3)$$

按照已确定的结构和参数, 最终的网络结构如图2所示. 制造业外协供应商评价指标体系的22个评价指标作为网络的输入, 隐含层节点数为12, 网络训练结果输出与评价期望的 MSE 作为误差反向传播, 指导输入层到隐含层的权值 w_1 、阈值 b_1 和隐含层到输出层之间的权值 w_2 、阈值 b_2 优化, 从而完成网络的训练.

Step 3: 确定 PSO 算法参数与编码结构.

本文中的 PSO 用于在全球搜索空间中寻找最优的神经网络初始权值阈值, 即: 网络输入层到隐含层的连接权值 w_{ji} , 隐含层的阈值 b_{1j} , 隐含层到输出层的连接权值 w_{kj} , 输出层阈值 b_{2k} . 采取合适的方法对这些参数进行编码, 从而形成单个粒子, 众多的粒子在一起便构成粒子种群.

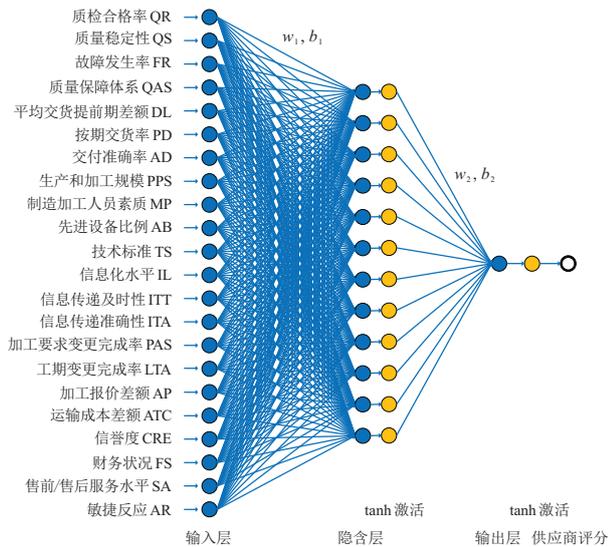


图2 外协供应商评价网络结构

在标准三层神经网络结构中,网络输入层节点数为 m ,隐含层节点数为 n ,输出层节点数为 q ,则输入层到隐含层的连接权值 w_{ji} 的个数为 $n \times m$.隐含层的阈值 b_{1j} 的个数为 n ,隐含层到输出层的连接权值 w_{kj} 的个数为 $q \times n$.输出层阈值 b_{2k} 的个数为 q .待优化的参数共有 $m \times n + n \times q + n + q$ 个. PSO的粒子长度即待优化的参数总和为

$$N = m \times n + n \times q + n + q. \quad (4)$$

PSO粒子编码方法如图3所示.

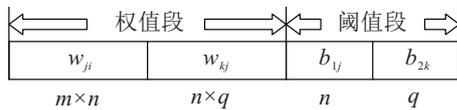


图3 粒子编码方法

PSO算法中的参数主要包括种群规模、惯性权重、学习因子、最大迭代次数等,不同类型的优化问题,PSO算法的参数设置也不尽相同,需要根据实际问题的规模和特点进行分析.

Step 4: PSO算法初始化.

在PSO启动之前,需要随机初始化粒子种群中每个粒子的位置和速度.每个粒子都被视作无质量无体积的 D 维空间中的点,其中 D 即是参数的个数.假设一个具有 N 个粒子的种群,其种群的最初位置为

$$w_0 = [w_{1,0}, w_{2,0}, \dots, w_{n,0}], \quad (5)$$

$$v_0 = [v_{1,0}, v_{2,0}, \dots, v_{n,0}], \quad (6)$$

其中 W_0 和 V_0 分别为粒子的初始位置集和初始速度集. W 是粒子坐标的 D 维矢量,而 V 是粒子速度的 D 维矢量.下面进行粒子适应度评价.本文中的PSO的适应度函数即如式(2)所示的神经网络目标函数.

Step 5: PSO算法迭代.

在PSO的迭代寻优过程中,粒子的坐标即为一个参数集,代表最优化问题的可能解.粒子的目的是在搜索空间中从当前位置移动到一个更优位置.粒子移动速度由粒子当前速度、个体最优位置、种群最优位置决定,粒子更新后的位置由当前位置和移动速度决定.传统PSO中粒子的速度和位置分别按下式更新:

$$v_{i,t+1} = v_{i,t} + c_1 r_1 (P_i - w_{i,t}) + c_2 r_2 (P_G - w_{i,t}), \quad (7)$$

$$w_{i,t+1} = w_{i,t} + v_{i,t+1}. \quad (8)$$

其中: $v_{i,t+1}$ 为粒子 i 的变化速度矢量, $v_{i,t}$ 为粒子 i 的当前速度矢量; $w_{i,t+1}$ 为粒子 i 的更新后的坐标, $w_{i,t}$ 为粒子 i 的当前坐标; c_1 、 c_2 为加速度常量; r_1 、 r_2 为两组均匀分布随机数; P_i 、 P_G 分别为粒子 i 的个体最优位置和粒子种群的群体最优位置.

为了稳定粒子的移动速度,Clerc等^[32]在原算法中加入了压缩因子.由此,粒子速度的更新公式由下式取代:

$$v_{i,t+1} = x[v_{i,t} + c_1 r_1 (P_i - w_{i,t}) + c_2 r_2 (P_G - w_{i,t})]. \quad (9)$$

其中压缩因子 x 的定义如下:

$$x = \frac{2}{|2 - \Phi - \sqrt{\Phi^2 - 4\Phi}|}, \quad (10)$$

$\Phi = c_1 + c_2 > 4$.粒子最优位置 P_i 和群体最优位置 P_G 按照下式更新:

$$\text{if } \xi(P_i) > \xi(w_i) \text{ then } P_i = w_{i,t}, 1 \leq i \leq N; \quad (11)$$

$$\text{if } \xi(P_G) > \xi(w_i) \text{ then } P_G = w_{i,t}, 1 \leq i \leq N. \quad (12)$$

其中 ξ 是适应度函数.在PSO算法的迭代寻优过程中,所有粒子将按照上述规则持续地在搜索空间中迭代,直到获得满意解或触发如表7所示的其他终止条件.

Step 6: 粒子自适应变异.

为了防止种群内部的粒子过早趋于一致,导致算法的搜索空间缩小,本文在原有的PSO基础上,加入了自适应变异与粒子重置机制,防止网络过拟合,保证网络的泛化能力.在PSO迭代中期,以随机概率重置随机粒子坐标向量中某一个值;在PSO迭代的末期,将聚集在同一点的多余粒子进行随机化重置.

Step 7: 神经网络迭代.

现有的PSO-BP算法通常使用SGD按照如下公式进行更新:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}). \quad (13)$$

其中: $x^{(i)}$ 为训练数据, $y^{(i)}$ 为期望输出. 在这种算法中, 神经网络突触权重的逐步更新值与误差函数的梯度相对应. 本文使用 Adam 进行神经网络的误差反向传递, 这种自适应学习率的方法比 SGD 收敛速度更快, 更容易收敛到全局极值. Adam 需要计算梯度的带权平均 m_t 和带权有偏方差 v_t , 其计算公式如下:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t, \quad (14)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2. \quad (15)$$

由于 m_t 和 v_t 初始化是零向量, 容易偏向零向量, 需要对 m_t 和 v_t 进行偏差校正. 校正后的梯度带权平均为 \hat{m}_t , 校正后的梯度带权有偏方差为 \hat{v}_t , 校正公式如下所示:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad (16)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}. \quad (17)$$

因此, Adam 最终的更新公式为

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t. \quad (18)$$

其中: β_1 取默认值 0.9, β_2 的默认值为 0.999, ϵ 的值为 10^{-8} .

Step 8: 外协供应商评价.

混合 PSO-Adam 算法完成对神经网络的训练后,

即可进行外协供应商的评价. 将外协供应商数据集输入神经网络的输入层, 神经网络输出层的输出即为外协供应商的评价得分.

3 应用案例

3.1 数据预处理

某建材装备制造公司在生产过程中有大量的工序外协和成品外协需求, 迫切需要一个评价决策模型对其外协供应商作出合理评价以发展长期稳定的合作伙伴关系. 为解决该企业在复杂外协环境下的外协供应商评价问题, 采用本文提出的基于混合 PSO-Adam 神经网络的外协供应商评价决策模型. 为验证该模型的有效性, 抽取该公司 24 组外协供应商数据作为样本数据进行实验分析, 其数据由表 3 所示的制造业供应商评价指标体系计算得到. 具体数据如表 4、表 5 所示. 其中: $S_1 \sim S_{20}$ 为有标记数据集, $S_{21} \sim S_{24}$ 为待评价数据集.

3.2 全局优化

混合 PSO-Adam 算法中 PSO 部分参数的设置需要分析实际的优化问题. 本文的神经网络输入层节点数为 22, 输出层节点数为 1, 隐含层层数为 1, 节点数为 12, 粒子长度按式 (4) 计算得 289. 粒子惯性权重从 0.9 线性递减到 0.4, 令算法在运行的初期具有较强的全局搜索能力, 并且在运行的后期能够快速收

表 4 外协供应商评价样本数据(1)

指标	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}	S_{11}	S_{12}
QR	97.88	97.56	99	98.2	97.1	96.26	94.79	98.82	95.9	95.28	99.3	95.1
QS	0.38	0.13	0.23	0.25	0.56	0.49	0.44	0.12	0.58	0.29	0.27	0.45
FR	1.74	1.3	0.56	0.76	1.13	1.4	1.38	0.44	1.3	1.3	0.37	1.4
QAS	0.5	0.5	0.7	0.7	0.9	0.5	0.7	0.7	0.3	0.3	0.7	0.5
DL	5.4	-2	-3.6	-2.1	3.3	3.4	4.3	-2.1	4.3	3	-5.6	1.2
PD	100	99	100	100	100	98.5	99.1	100	98.7	99.3	100	100
AD	97.6	98.1	100	100	96	96.5	97.3	97	96.4	94.5	100	95.6
PPS	0.7	0.7	0.9	0.7	0.7	0.5	0.3	0.7	0.3	0.5	0.9	0.5
MP	5 500	5 000	9 000	9 000	5 300	6 000	5 000	6 500	5 200	5 000	8 000	8 000
AB	48.3	50	67.4	58.1	54	47.5	46.7	54.3	45.7	46	56.2	48.1
TS	0.5	0.7	0.7	0.7	0.7	0.5	0.5	0.7	0.5	0.5	0.7	0.7
IL	0.7	0.7	0.9	0.9	0.7	0.7	0.5	0.9	0.5	0.5	0.9	0.5
ITT	0.5	0.5	0.7	0.5	0.5	0.3	0.3	0.5	0.3	0.3	0.7	0.3
ITA	0.5	0.7	0.7	0.5	0.5	0.5	0.3	0.5	0.5	0.5	0.7	0.3
PAS	73	70	80	76	71	68	66	72	67	68	78	67
LTA	86	84	90	85	84	80	78	83	79	80	88	81
AP	120	-134	870	600	-230	-168	-620	340	-356	-380	547	-260
ATC	63	-24	235	-158	53	-160	-212	185	-168	-137	190	-133
CRE	100	100	100	100	100	98	99	100	98	98	100	98
FS	0.7	0.7	0.9	0.9	0.7	0.7	0.7	0.7	0.5	0.5	0.9	0.7
SA	0.5	0.7	0.9	0.9	0.5	0.5	0.3	0.7	0.3	0.3	0.9	0.3
AR	0.7	0.7	0.9	0.7	0.7	0.5	0.5	0.7	0.5	0.5	0.9	0.5
评分	6.8	7.4	9.6	9.1	8.2	6.3	5.4	8.7	6.2	6.5	9.4	5.1

表5 外协供应商评价样本数据(2)

指标	S_{13}	S_{14}	S_{15}	S_{16}	S_{17}	S_{18}	S_{19}	S_{20}	S_{21}	S_{22}	S_{23}	S_{24}
QR	97.68	98.63	97.6	96.56	97.86	97.25	98.3	97.4	98.7	96.47	98.62	97.48
QS	0.37	0.31	0.42	0.33	0.31	0.29	0.3	0.37	0.56	0.13	0.12	0.38
FR	0.82	0.73	0.7	0.84	0.72	0.91	0.81	0.7	1.13	1.3	0.44	1.74
QAS	0.7	0.9	0.7	0.5	0.7	0.9	0.7	0.7	0.9	0.5	0.7	0.5
DL	1.4	-4.1	-3.3	-2.4	0.7	-1.3	-1.7	1.2	3.3	-2	-2.1	5.4
PD	100	100	100	99.3	100	100	100	100	100	99	100	100
AD	98	97.3	97.1	98.2	97.4	98	100	97.9	96	98.1	97	97.6
PPS	0.7	0.9	0.7	0.5	0.7	0.7	0.9	0.7	0.7	0.7	0.7	0.7
MP	7000	7400	7500	6900	7200	7800	8000	7000	5300	5000	6500	5500
AB	52	54.7	52.3	48.7	53.1	53	57.6	51.6	54	50	54.3	48.3
TS	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
IL	0.7	0.9	0.7	0.5	0.7	0.7	0.9	0.7	0.7	0.7	0.9	0.7
ITT	0.5	0.5	0.5	0.3	0.5	0.5	0.7	0.5	0.5	0.5	0.5	0.5
ITA	0.5	0.7	0.5	0.5	0.5	0.7	0.5	0.5	0.5	0.7	0.5	0.5
PAS	71	73	70	70	69	72	76	71	71	70	72	73
LTA	83	84	82	82	83	85	85	80	84	84	83	86
AP	-87	130	112	-46	135	63	234	63	-230	-134	340	120
ATC	-32	114	56	-63	72	-44	137	26	53	-24	185	63
CRE	100	100	100	100	98	100	100	100	100	100	100	100
FS	0.7	0.7	0.7	0.5	0.7	0.7	0.9	0.7	0.7	0.7	0.7	0.7
SA	0.7	0.9	0.9	0.7	0.7	0.5	0.9	0.7	0.5	0.7	0.7	0.5
AR	0.7	0.7	0.7	0.5	0.7	0.7	0.9	0.7	0.7	0.7	0.7	0.7
评分	7.2	8.5	9.2	6.8	7.1	7.8	8.8	7.5	待评	待评	待评	待评

敛^[33]. 设置最小变化步长与最小变化适应度为 $1e-6$, 小于阈值时算法得到的结果趋于稳定, 令算法终止, 以减少计算量. PSO 算法的种群规模和迭代次数一般通过实验或者经验选择. 因此, 针对本文的应用案例, 在上述算法参数的基础上, 分别选取不同种群规模, 在不同最大迭代次数下进行正交实验, 以测试算法参数的敏感性. 对实验结果用均方误差 (MSE) 和决定系数 (R^2) 进行性能衡量, MSE 代表模型预测结果与数据集的误差, R^2 代表模型对数据集的拟合优度. 正交实验部分结果如表6所示, 从整体结果上看, 当种群规模设置为5, 最大迭代次数设置为15时, 测试集MSE最低, 精度最高, 测试集 R^2 最高, 数据拟合情况最好.

表6 PSO参数正交实验结果

种群规模	最大迭代次数	MSE (训练集)	MSE (测试集)	R^2 (训练集)	R^2 (测试集)
3	10	0.01425	0.004731	0.8443	0.9018
3	15	0.0006685	0.0009127	0.8973	0.9442
3	20	0.0001226	0.0005142	0.9430	0.9583
5	10	0.0004778	0.002381	0.9627	0.9620
5	15	0.0001496	0.0003851	0.9783	0.9708
5	20	0.00008796	0.000738	0.9828	0.9592
7	10	0.0002367	0.001173	0.9758	0.9679
7	15	0.0001098	0.0008476	0.9803	0.9632
7	20	0.00007462	0.01633	0.9917	0.8336

由表6可知: 种群规模和最大迭代次数偏小时, 训练集和测试集的MSE偏高, 而训练集和测试集的 R^2 偏小, 说明优化不够充分; 种群规模和最大迭代次数偏大时, 训练集的MSE偏低, 测试集的MSE偏高, 训练集的 R^2 偏高, 测试集的 R^2 偏低, 说明出现过拟合, 泛化能力变差. 从参数变化对结果的影响来看, 混合 PSO-Adam 算法对 PSO 种群规模敏感性不大, 而对 PSO 最大迭代次数敏感性相对较大. PSO 的主要参数设置如表7所示.

表7 PSO主要参数表

参数	参数值
种群规模	5
粒子速度范围	(-1, 1)
粒子位置范围	(-1, 1)
惯性权重	0.9线性递减到0.4
学习因子 C_1 、 C_2	1.49445, 1.49445
最大迭代次数	15
最小变化步长	$1e-6$
最小变化适应度	$1e-6$

3.3 局部优化

基于前文建立的制造业外协供应商评价指标体系, 使用 python 语言在基于 Theano 的 Keras 高层神经网络 API 下分别使用以下6个算法优化神经网络并进行外协供应商评价: SGD、带Nesterov动量的SGD、Adagrad^[26]、Adam^[25]、PSO-BP^[20]和混合 PSO-Adam.

PSO-Adam与PSO-BP两种混合优化算法具有全局优化与局部优化两个阶段,全局优化阶段的PSO算法具有一定的随机性,在相同的参数下优化结果也不尽相同.为了更科学地比较PSO-Adam与PSO-BP两种混合优化算法的性能,需要控制PSO算法的全局优化结果的随机性.因此,针对PSO-Adam与PSO-BP两种算法,本实验选取一组相同的全局优化结果集作为其局部优化的初始值.局部优化阶段各算法收敛曲线如图4所示,各算法性能对比如表8所示. PSO-BP算法所训练神经网络的训练集、测试集拟合度分别如图5、图6所示,混合PSO-Adam算法所训练神经网络的训练集、测试集拟合度分别如图7、图8所示.

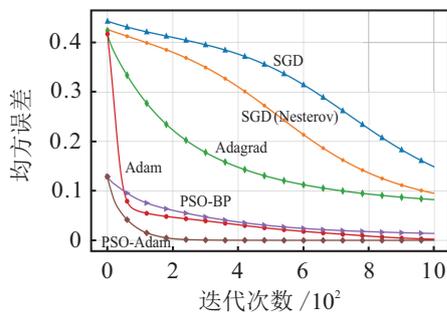


图4 各算法收敛曲线对比

表8 神经网络训练算法性能对比

训练算法	MSE (训练集)	MSE (测试集)	R^2 (训练集)	R^2 (测试集)
SGD	0.1489	0.03314	0.8389	0.9456
SGD(Nesterov)	0.09520	0.03328	0.8607	0.9459
Adagrad ^[26]	0.08232	0.03182	0.8386	0.9123
Adam ^[25]	0.002427	0.009967	0.9734	0.9542
PSO-BP ^[20]	0.01302	0.03197	0.9052	0.9133
PSO-Adam	0.0001496	0.0003851	0.9783	0.9708

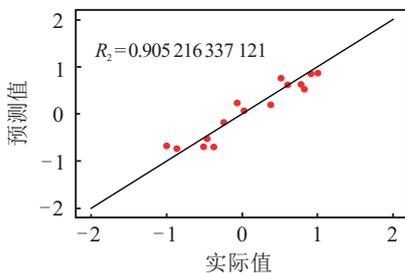


图5 PSO-BP神经网络训练集拟合度

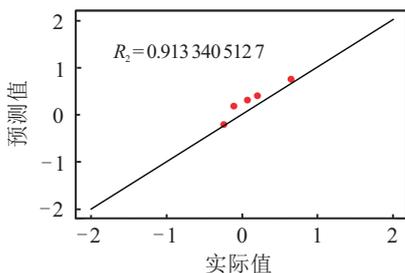


图6 PSO-BP神经网络测试集拟合度

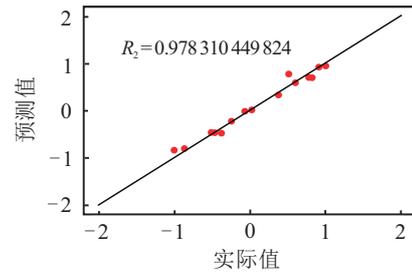


图7 混合PSO-Adam神经网络训练集拟合度

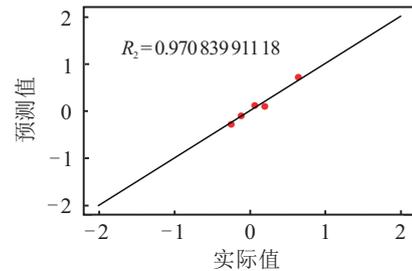


图8 混合PSO-Adam神经网络测试集拟合度

根据以上图表可以得出如下结论:

1) 训练收敛速度:由图5可知,PSO-BP与混合PSO-Adam两种混合算法中的PSO经过全局并行优化,将神经网络 MSE 从 0.7653 降至 0.1289. 采用SGD、带Nesterov动量的SGD、Adagrad训练的神经网络收敛相对较慢;采用Adam训练的神经网络次之;PSO-BP与混合PSO-Adam两种混合优化算法由于采用了PSO进行全局优化,初始MSE更低,整体收敛速度更快.所有进行实验的算法中,混合PSO-Adam算法的收敛速度最快.说明采用PSO进行全局优化,采用Adam进行局部优化能够在一定程度上提高训练的收敛速度.

2) 全局最优收敛:由表8可知,与SGD、带Nesterov动量的SGD、Adagrad、Adam、PSO-BP算法相比,采用混合PSO-Adam算法训练的神经网络能够以更高的精度收敛,并且具备更高的拟合优度.由图5~图8可知,混合PSO-Adam算法训练的神经网络比PSO-BP训练的神经网络对训练集与测试集的拟合程度更好.说明采用混合PSO-Adam算法优化神经网络,能够避免训练陷入局部次优点和鞍点,使训练能够全局最优收敛,有效提高训练的精度与对数据集的拟合优度.

3) 自适应计算学习率:与基于经典神经网络的供应商评价方法相比,基于混合PSO-Adam神经网络的外协供应商评价决策模型在应用过程中不需要设置学习率等参数,优化结果不受学习率等初始参数影响,具有更好的性能稳定性,降低了算法的实施难度,令供应商评价的结果更加客观可信.

4) PSO参数设置:由表6和PSO参数敏感性分析

可知,混合 PSO-Adam 算法对 PSO 种群规模敏感性不大,而对 PSO 最大迭代次数敏感性相对较大. PSO 种群规模的选择应根据优化问题的规模设定,种群规模过大会增加计算成本,种群规模过小会限制混合 PSO-Adam 算法的全局优化性能. 混合 PSO-Adam 算法由 Adam 算法完成收敛,需要 PSO 迭代的次数较少,因此应适当限制 PSO 迭代次数,避免过度训练.

综上所述,基于混合 PSO-Adam 神经网络的外协供应商评价决策模型在基于经典神经网络的供应商评价方法能够准确客观解决复杂问题的基础上,进一步弥补了经典神经网络的收敛速度慢、容易局部次优收敛、难以逃脱鞍点、参数难选取的缺陷.

将 4 组待评价的数据样本使用混合 PSO-Adam 算法优化的神经网络进行评价,所得结果如表 9 所示.

表 9 待测样本评价结果

待评价外协供应商	S_{21}	S_{22}	S_{23}	S_{24}
评价结果	8.5374	6.9473	8.2547	7.7638

由表 9 可知:外协供应商 S_{21} 评价分数最高, S_{22} 分数较低; S_{21} 和 S_{23} 可作为优秀外协供应商纳入资源库; S_{24} 可作为普通合作的外协供应商; S_{22} 合作风险较高,需谨慎合作. 评价结果交由公司专家小组审查,得到了公司人员的普遍认可. 应用实例表明,基于混合 PSO-Adam 神经网络的外协供应商评价决策模型能够针对当前复杂的外协环境,客观高效地解决外协供应商评价问题,进一步减少对个人经验的依赖,降低供应商评价难度,减少供应链管理成本.

4 结 论

为了解决复杂外协环境下的外协供应商评价问题,本文首先分析了当前主流的供应商评价方法的优劣,提出了基于混合 PSO-Adam 神经网络的外协供应商评价决策模型,以弥补多目标决策方法主观性太强、数学规划方法难以求解复杂问题以及经典神经网络存在的收敛速度慢、容易局部次优收敛、难以逃脱鞍点、参数难选取的缺陷;然后,结合制造业的外协特点和实际需求,建立了基于目标层、准则层、指标层的三级评价指标体系;最后,为验证算法的有效性,以某建材装备制造企业外协供应商评价问题实例进行实验分析,并与其他现有算法进行了对比. 结果表明,基于混合 PSO-Adam 神经网络的外协供应商评价决策模型能够针对当前复杂的外协环境,客观且高效地解决外协供应商评价问题,进一步减少了对个人经验的依赖,降低了供应商评价难度,减少了供应链管理成本.

随着以云制造与网络化的协同制造联盟为代表的新型制造模式的不断发展^[34],制造业外协供应商的评价方法将会面临着更大的挑战. 本文下一步将重点研究云制造模式下,面向高度复杂网络和海量数据的供应商评价方法.

参考文献(References)

- [1] 尹胜,尹超,刘飞,等. 云制造环境下外协加工资源集成服务模式及语义描述[J]. 计算机集成制造系统, 2011, 17(3): 525-532.
(Yin S, Yin C, Liu F, et al. Outsourcing resources integration service mode and semantic description in cloud manufacturing environment[J]. Computer Integrated Manufacturing Systems, 2011, 17(3): 525-532.)
- [2] Chan F T, Chan H K. An AHP model for selection of suppliers in the fast changing fashion market[J]. Int J of Advanced Manufacturing Technology, 2010, 51(9): 1195-1207.
- [3] Nemery P. AHPSort: An AHP-based method for sorting problems[J]. Int J of Production Research, 2012, 50(17): 4767-4784.
- [4] Roshandel J, Miri-Nargesi S S, Hatami-Shirkouhi L. Evaluating and selecting the supplier in detergent production industry using hierarchical fuzzy TOPSIS[J]. Applied Mathematical Modelling, 2013, 37(24): 10170-10181.
- [5] Deng Y, Chan F T S. A new fuzzy dempster MCDM method and its application in supplier selection[J]. Expert Systems with Applications, 2011, 38(8): 9854-9861.
- [6] 王先甲,汪磊. 基于马氏距离的改进型 TOPSIS 在供应商选择中的应用[J]. 控制与决策, 2012, 27(10): 1566-1570.
(Wang X J, Wang L. Applications of topsis improved based on Mahalanobis distance in supplier selection[J]. Control and Decision, 2012, 27(10): 1566-1570.)
- [7] Deng G. An application of fuzzy comprehensive evaluation in information systems supplier evaluation[C]. Int Conf on Information Management, Innovation Management and Industrial Engineering. Shenzhen, 2011: 509-513.
- [8] Golmohammadi D, Mellat-Parast M. Developing a grey-based decision-making model for supplier selection[J]. Int J of Production Economics, 2012, 137(2): 191-200.
- [9] Azadi M, Jafarian M, Farzipoor Saen R, et al. A new fuzzy DEA model for evaluation of efficiency and effectiveness of suppliers in sustainable supply chain management context[J]. Computers & Operations Research, 2015, 54(C): 274-285.
- [10] Falagario M, Sciancalepore F, Costantino N, et al. Using a DEA-cross efficiency approach in public procurement tenders[J]. European J of Operational Research, 2012,

- 218(2): 523-529.
- [11] Hsu B M, Chiang C Y, Shu M H. Supplier selection using fuzzy quality data and their applications to touch screen[J]. *Expert Systems with Applications*, 2010, 37(9): 6192-6200.
- [12] Chen T Y, Wang H P, Lu Y Y. A multicriteria group decision-making approach based on interval-valued intuitionistic fuzzy sets: A comparative perspective[J]. *Expert Systems with Applications*, 2011, 38(6): 7647-7658.
- [13] Lee C C, Ou-Yang C. A neural networks approach for forecasting the supplier's bid prices in supplier selection negotiation process[J]. *Expert Systems with Applications*, 2009, 36(2): 2961-2970.
- [14] Güneri A F, Ertay T, Yücel A. An approach based on ANFIS input selection and modeling for supplier selection problem[J]. *Expert Systems with Applications*, 2011, 38(12): 14907-14917.
- [15] Chai J, Liu J N K, Ngai E W T. Application of decision-making techniques in supplier selection: A systematic review of literature[J]. *Expert Systems with Applications*, 2013, 40(10): 3872-3885.
- [16] Govindan K, Rajendran S, Sarkis J, et al. Multi-criteria decision making approaches for green supplier evaluation and selection: A literature review[J]. *J of Cleaner Production*, 2015, 98: 66-83.
- [17] Wang J, Wu W, Zurada J M. Computational properties and convergence analysis of BPNN for cyclic and almost cyclic learning with penalty[J]. *Neural Networks the Official J of the Int Neural Network Society*, 2012, 33(9): 127-135.
- [18] Dauphin Y, Pascanu R, Gulcehre C, et al. Identifying and attacking the saddle point problem in high-dimensional non-convex optimization[J]. *Mathematics*, 2014, 111(6 Pt 1): 2475-2485.
- [19] Pushpalatha M P, Nalini N. Analysis on the convergence of dyadic wavelet based neural network with varying learning rate and resolution for function learning[C]. *Int Conf on Machine Learning and Computing*. Bangalore: IEEE, 2010: 340-344.
- [20] Ismail A, Jeng D S, Zhang L L. An optimised product-unit neural network with a novel PSO - BP hybrid training algorithm: Applications to load - deformation analysis of axially loaded piles[J]. *Engineering Applications of Artificial Intelligence*, 2013, 26(10): 2305-2314.
- [21] 许少华, 何新贵. 一种基于混沌遗传与粒子群混合优化的过程神经网络训练算法[J]. *控制与决策*, 2013, 28(9): 1393-1398.
(Xu S H, He X G. A training algorithm of process neural networks based on CGA combined with PSO[J]. *Control and Decision*, 2013, 28(9): 1393-1398.)
- [22] Kennedy J, Eberhart R. Particle swarm optimization[C]. *IEEE Int Conf on Neural Networks*. Perth, 1995: 1942-1948.
- [23] Gudise V G, Venayagamoorthy G K. Comparison of particle swarm optimization and backpropagation as training algorithms for neural networks[C]. *Swarm Intelligence Symposium*. Indianapolis: IEEE, 2003: 110-117.
- [24] Zhao F, Ren Z, Yu D, et al. Application of an improved particle swarm optimization algorithm for neural network training[C]. *Int Conf on Neural Networks and Brain*. Beijing: IEEE, 2005: 1693-1698.
- [25] Kingma D P, Ba J. Adam: A method for stochastic optimization[C]. *Int Conf on Learning Representations*. San Diego: IEEE, 2015.
- [26] Duchi J, Hazan E, Singer Y. Adaptive subgradient methods for online learning and stochastic optimization[J]. *J of Machine Learning Research*, 2011, 12(7): 2121-2159.
- [27] Wu W, Wang J, Cheng M, et al. Convergence analysis of online gradient method for BP neural networks[J]. *Neural Networks the Official J of the Int Neural Network Society*, 2011, 24(1): 91-98.
- [28] Madhjarasan M, Deepa S N. Comparative analysis on hidden neurons estimation in multi layer perceptron neural networks for wind speed forecasting[J]. *Artificial Intelligence Review*, 2016, 48(4): 1-23.
- [29] Gulcehre C, Moczulski M, Denil M, et al. Noisy activation functions[C]. *Int Conf on Machine Learning*. New York: IEEE, 2016: 3059-3068.
- [30] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks[J]. *J of Machine Learning Research*, 2010, 9: 249-256.
- [31] Cesar A, Gómez S. Exact solution of the bogoyavlenskii equation using the improved tanh-coth method[J]. *Nonlinear Dynamics*, 2015, 70(1): 13-24.
- [32] Clerc M, Kennedy J, Kennedy J. The particle swarm: Explosion, stability and convergence in a multi-dimensional complex space[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(1): 58-73.
- [33] Eberhart R C, Shi Y. Comparing inertia weights and constriction factors in particle swarm optimization[C]. *Proc of the 2000 Congress on Evolutionary Computation*. La Jolla: IEEE, 2002: 84-88.
- [34] 李伯虎, 张霖, 任磊, 等. 再论云制造[J]. *计算机集成制造系统*, 2011, 17(3): 449-457.
(Li B H, Zhang L, Ren L, et al. Further discussion on cloud manufacturing[J]. *Computer Integrated Manufacturing Systems*, 2011, 17(3): 449-457.)

(责任编辑: 李君玲)