

基于 MLCRBMs-ELM 的软测量建模

倪健华, 王 静

(南京工业大学 计算机科学与技术学院, 江苏 南京 211816)

摘 要: 针对辅助变量之间相关性差挖掘困难等问题, 提出一种基于特征提取集和极限学习机 (MLCRBM_s-ELML) 的软测量建模方法. 该方法首先通过聚类算法对输入数据集进行属性簇划分. 按结果将数据集分类后输入至 MLCRBM_s 特征提取集中进行同步的特征提取, 提取到的特征子集经 Blending 层进行非线性融合得到新特征集, 并输入至极限学习机 (ELM) 进行拟合得到最后的估计结果. 实验结果表明该方法优于传统的方法, 具有更高的预测精度和泛化性能.

关键词: 计量学; 极限学习机; 受限玻尔兹曼机; 软测量

中图分类号: TB97

文献标识码: A

文章编号: 1000-7180(2018)10-0007-06

Soft Sensor Modeling Based on MLCRBMs-ELM

NI Jian-hua, WANG jing

(Nanjing Tech University, School of Computer Science and Technology, Nanjing 211816, China)

Abstract: Aiming at the difficult problem of poor correlation between auxiliary variables, this paper proposes a soft sensor modeling method based on feature extraction sets and extreme learning machine (MLCRBM_s-ELML). First of all, it divides the attribute of input into several classes by clustering algorithm. The classed data set enter to the MLCRBM_s feature extraction to perform synchronous feature extraction. Then, the extracted feature subsets are nonlinearly merged by the Blending layer and obtain the new feature set. Finally, the new feature set enter the ELM model to get the fitting results. The experimental results show that the soft sensor model is superior to the traditional method, and has higher prediction accuracy and generalization performance.

Key words: metrology; extreme learning machine; restricted boltzmann machine; soft sensor

1 引言

在实际的工业生产中, 许多重要的变量难以实时测量, 为了解决这一问题, 许多专家采用了软测量技术. 软测量技术的核心是软测量建模^[1-2], 常规软测量建模方法主要有机理建模与数据驱动建模, 机理建模方法具有工程背景清晰、可解释性强等优点, 但这种建模方法存在移植性差和结构复杂等问题, 导致难以建立比较完善的机理模型. 因此, 通常采用数据驱动建模方法, 通过构建可测变量和不可测变量之间的数学模型实现对不可测变量的实时监控.

传统过程工业数据建模方法大多采用主元分析法^[3-4], 但对于非线性较强的对象来说, 传统主元分析法建模估计精度较差, 影响工业产品质量. 与经典统计建模相比, 神经网络对于非线性较强的对象有很好的拟合能力且不需要对象的先验知识^[5]. 然而很多情况下, 将具有多样性、多特征的数据输入网络的最直接方法是将多个输入堆叠成更高维的数据, 此方法使得许多软测量模型很难构建出辅助变量与主导变量之间准确的数学模型, 导致主导变量估计精度较低, 模型泛化能力较差且稳定性也不高. 因此, 本文提出一种新的软测量模型方法.

2 相关介绍

2.1 CRBM 模型

受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM) 和生成式随机神经网络 (generative stochastic neural network), 是一个无向图 (undirected graph) 模型^[6-7]. 结构如图 1 所示.




图 1 RBM 的结构图

为了提高模型特征提取的稳定性, Desjardins 提出了 CRBM 模型^[8], 该模型是基于 RBM 模型的一种改进, 在 RBM 网络中用可见层和隐藏层的变量 v 和 h 分别减去一个偏移量, 该偏移量分别为原始数据的平均值和隐层特征的平均值, 其模型的能量模型为:

$$E(v, h | \theta) = - \sum_{i=1}^n a_i (v_i - \mu_i) - \sum_{j=1}^k b_j (h_j - \lambda_j) - \sum_{i=1}^n \sum_{j=1}^k (v_i - \mu_i) w_{ij} (h_j - \lambda_j) \quad (1)$$

式中, n 和 k 分别表示可视层和隐层的单元个数向量; v 和 h 分别为可视层和隐藏层的状态; w_{ij} 表示可视单元 i 和隐层单元 j 之间的连接权值, a_i 表示可视层单元的偏置, b_j 表示隐藏层单元的偏置, $\theta = \{w_{ij}, a_i, b_j\}$ 表示的是 RBM 的各个参数.

由 CRBM 模型各层单元之间是互相独立可知, 当给定可见层数据时, 输出层节点取值满足如下条件概率:

$$P(v_j = 1 | h, \theta) = \sigma(a_j + \sum_i w_{ij} (h_i - \lambda_i)) \quad (2)$$

$$P(h_j = 1 | v, \theta) = \sigma(b_j + \sum_i (v_i - \mu_i) w_{ij}) \quad (3)$$

式中, $\mu = (\mu_1, \mu_2, \dots, \mu_n)$; $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_n)$; 当 $\mu = 0$ 和 $\lambda = 0$ 时, CRBM 模型是标准的 RBM 模型. 本文中 μ 和 λ 的初始值分别为: $\mu = \langle \text{data} \rangle$, $\lambda = \langle h \rangle$.

训练 CRBM 意味着调整参数 θ 以拟合给定的训练样本, 使得该参数下由相应 CRBM 表示的概率分布尽可能地与训练数据的经验分布相符合. 采用最大似然估计对网络参数进行调整, 即训练目标为最

大化模型的似然函数来调整参数 θ . 其更新公式如下:

$$\Delta w_{ij} = \eta (\langle (v_i - \mu_i)(h_j - \lambda_j) \rangle_{\text{data}} - \langle (v_i - \mu_i)(h_j - \lambda_j) \rangle_{\text{reconstruction}}) \quad (4)$$

$$\Delta b_j = \eta (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{reconstruction}} - \Delta W \mu) \quad (5)$$

$$\mu = (1 - v_\mu) \mu + v_\mu \mu_{\text{batch}} \quad (6)$$

$$\lambda = (1 - v_\lambda) \lambda + v_\lambda \lambda_{\text{batch}} \quad (7)$$

式中, $v_\mu, v_\lambda \in \{0.001, \dots, 0.1\}$; $\mu_{\text{batch}} \leftarrow \langle x_d \rangle$, $\lambda_{\text{batch}} \leftarrow \langle h_d \rangle$. 最后训练学习到 CRBM 模型的超参数.

2.2 极限学习机 ELM

极限学习机 ELM 算法, 它是一种新的针对单隐层神经网络的学习算法^[9-11]. 该算法训练过程快速简单, 无需繁琐的迭代和调整参数, 且具有优良的泛化性能, 广泛应用于软测量建模^[12]. 设一个单隐层神经网络输入为 N 个样本 (X_i, t_i) , 其中 $X_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, t_{i2}, t_{i3}, \dots, t_{im}]^T$. 假设一个单隐层神经网络有 L 个隐层节点, 随机生成隐藏层的权重 α_i 和偏置 b_i , 且 $(i = 1, 2, 3, \dots, L)$. 然后利用广义逆矩阵的思想求出输出权重. 则此网络可表示为:

$$\sum_{i=1}^L \beta_i g(\alpha_i X_j + b_i) = o_j, j = 1, 2, 3, \dots, N \quad (8)$$

式中, $g(x)$ 为激活函数; β_i 为输出权重; b_i 为第 i 个隐藏单元的偏重.

训练整个单隐层神经网络的目的是使输出的误差最小化即:

$$\sum_{j=1}^N \| o_j - t_j \| = 0 \quad (9)$$

即存在 β_i, b_i 和 α_i , 使得:

$$\sum_{i=1}^N \beta_i g(\alpha_i X_j + b_i) = t_j, j = 1, 2, 3, \dots, N \quad (10)$$

此时变成 $H\beta = T$. 其中, H 为隐藏层输出矩阵, β 为 ELM 输出权重, T 为期望输出.

$$H = \begin{bmatrix} g(\alpha_1, b_1, x_1) & \cdots & g(\alpha_L, b_L, x_1) \\ g(\alpha_1, b_1, x_2) & \cdots & g(\alpha_L, b_L, x_2) \\ \vdots & \ddots & \vdots \\ g(\alpha_1, b_1, x_N) & \cdots & g(\alpha_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (11)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_N^T \end{bmatrix} \quad (12)$$

训练单隐藏层神经网络的目的,就是得到特殊的 $\hat{W}_i, \hat{b}_i, \hat{\beta}_i$ 使得:

$$\|H(\hat{\alpha}_i, \hat{b}_i)\hat{\beta} - T\| = \min_{\alpha, b, \beta} \|H(\alpha_i, b_i)\beta - T\| \quad (13)$$

当采用 ELM 算法时,输入权重 α_i ,隐层的偏置 b_i 被随机确定后,隐层的输出矩阵 H 也被确定. 此时单隐层神经网络的训练问题变成一个线性系统 $HP = T$, 输出权重即为:

$$\hat{\beta} = H^+ T \quad (14)$$

式中, H^+ 为 H 的广义矩逆,同时,求得解 $\hat{\beta}$ 是最小且唯一.

3 MLCRBMs-ELM 软测量模型

由于在软测量模型中选取的辅助变量间相关性较差,使得传统的算法模型对原始工业数据进行特征提取并拟合预测,最终的预测不精确. 为更好挖掘出相关性较差的数据特征,本文先通过 FCM 聚类方法将数据集划分成多个属性簇;然后对不同的属性簇通过 CRBM 进行单独的训练学习,提取相应到的特征子集,再融合这些特征子集进行进一步的学习拟合,最终组成了 MLCRBMs-ELM 软测量模型.

3.1 数据集划分

针对软测量模型中选取的辅助变量间相关性较差等问题,本文采取一种常见的聚类算法 FCM 算法,用 FCM 算法按数据的特征属性对数据集进行划分. 在数据属性簇的划分中,FCM 算法对每个数据的属性特征进行聚类,得到不同的属性向量. 设数据 $X = \{x_1, x_2, \dots, x_n\}$ 是 n 个待聚类样本. 算法如下:

① 固定聚类数 c 和模糊加权指数 $m (1 < m < \infty)$, 随机设置 $V^{(0)}$, 置 $k = 1$, 取 $\epsilon > 0$. 其中, 本文使用 $\{x_i\}$ 初始化类中心 $V^{(0)}$, 会使得 FCM 算法迭代次数减少, 且聚类速度提高.

② 计算隶属度矩阵 $U^{(k)}$ 如下所示:

$$u_{ij}^{(k)} = \left(\sum_{l=1}^c \left[\left(\frac{d_{ij}^{(k)}}{d_{lj}^{(k)}} \right)^{\frac{2}{m-1}} \right] \right)^{-1}, \forall i, j \quad (15)$$

式中, $d_{ij}^{(k)} = \|x_i - v_j\|$ 表示的是第 i 个数据点与第 j 个聚类中心的欧式距离.

③ 计算新的聚类中心 $V^{(k+1)}$ 如下所示:

$$V_j^{(k+1)} = \frac{\sum_{i=1}^n (u_{ij}^{(k)})^m x_i}{\sum_{i=1}^n (u_{ij}^{(k)})^m}, \forall j \quad (16)$$

④ 若 $\|V^{(k+1)} - V^{(k)}\| < \epsilon$, 停止, 否则 $k = k + 1$, 转第二步来更新聚类中心.

随机选择足够的航煤干点辅助变量数据, 将按数据的特征属性对选出的数据划分成不同的属性向量. 运用上面的方法最终得到 c 簇属性类别, 并将多个属性簇作为 MLCRBMs-ELM 的输入.

3.2 MLCRBMs 模型

① 通过 FCM 算法对辅助变量数据集进行划分, 得到多个属性簇. 为了对多个属性簇进行同步单独的特征提取, 本文提出了 MLCRBMs 模型, 该模型由多个 CRBM 组成的特征提取集. 具体的算法步骤如下:

② 设选取的辅助变量数据集为 X , 通过 FCM 聚类算法进行属性簇划分, 即得到最终的训练样本 $X = \{X_1, X_2, \dots, X_m\}$.

③ 选取 m 个 CRBM 组成一个特征提取集, 初始化 MLCRBMs 模型中 CRBM 的超参数 $\theta^l = \{W^l, a^l, b^l\}$, 其中, l 表示第 l 个 CRBM 模型的超参数.

④ 用 m 个属性簇对 m 个 CRBM 进行单独的训练, 通过最大化似然函数对 CRBM 模型用公式 (4)、(5)、(6) 和 (7) 进行参数更新, 并训练得到最后的特征提取集 MLCRBMs.

⑤ 再将多个属性簇输入至训练好的 MLCRBMs 模型中得到特征子集 $h = \{h_1, h_2, \dots, h_m\}$.

⑥ 对 Blending 层的融合权重 W^B 进行初始化 (如图 2 所示), 并在 Blending 层通过非线性方式进行特征子集 $h = \{h_1, h_2, \dots, h_m\}$ 融合, 且起到了降维的作用. 其模型为:

$$U = \sigma(W^B h + b^B) \quad (17)$$

⑦ 并通过自编码的无监督训练方法去更新 Blending 层的融合权重, 最后学习得到 Blending 层的各参数, 其更新公式如下^[13]. 其中 $J_s(W, b)$ 为模型的代价函数.

$$W_{ij} = W_{ij} - \eta \frac{\partial}{\partial W_{ij}} J(W^B, b^B) \quad (18)$$

⑧ 训练完成后, 就建立起 MLCRBMs 模型.

3.3 MLCRBMs-ELM 模型

将 CSSE-OSELM 算法用于软测量建模如图 2 所示, 具体流程如下:

(1) 采集不同时间段的辅助变量数据, 按比例分成训练集和测试集.

(2) 确定特征提取集 MLCRBMs 中 CRBMs 的数目. 按 3.1 进行设置 FCM 的参数, 从训练集中随

机选取足够的辅助变量数据,进行特征聚类.调整 FCM 的参数重复聚类,直至达到较好的分类,分类数目即 CRBMs 数目.

(3)建立起 MLCRBMs-ELM 软测量模型.将 FCM 算法聚类得到的特征集输入至 MLCRBMs 模型中,对 MLCRBMs 进行单独学习训练,得到特征子集后输入至 Blending 层对其进行无监督训练.在 MLCRBMs 和 Blending 层预训练完成后,采用反向传播算法对其进行微调,并且 Blending 层传向并行的 CRBM 时要并行传播残差而保留局部化信息.

(4)将通过 MLCRBMs 和 Blending 层训练得到的特征集输入至 ELM 进行学习拟合,把训练样本集中目标输出作为模型期望输出.最终建立 MLCRBMs-ELM 软测量模型.

(5)用测试集数据按照与训练集相同的方式输入至 MLCRBMs-ELM 模型,计算出软测量模型的输出结果如下所示,将网络输出与真实值对比,计算相对均方误差来评估网络性能.

$$y_{out} = \sum_{j=1}^N H_j \cdot \beta_{j,k}^+$$

(19)




图 2 MLCRBMs-ELM 模型结构图

4 仿真研究

为了验证该模型对于相关性较差的数据的预测能力,本文分别利用 UCI 数据集集中的 Condition Based Maintenance of Naval Propulsion Plants (CBMONPP)数据集和 wine 数据集数据集做验证.

4.1 UCI 数据集测试

CBMONPP 和 wine 数据集信息如表 1 所示.

表 1 UCI 测试数据集

数据集	样本数(训练/测试)	特征数	类别	任务
CBMONPP	2 000(1 500/500)	16	2	回归
wine	178(128/50)	13	3	分类

表 1 为 CBMONPP 数据集预测的相对均方误差(RMSE),计算公式如(21),图 3 为 wine 数据集

预测的命中率与 ELM 隐层节点数 s 的关系图.




图 3 分类命中率与 ELM 隐层节点数目 s 关系图

从表 2 和图 3 上看,针对数据特征间相关性较差的问题,MLCRBMs-ELM 模型的预测能力明显优于 DBM-ELM 模型,这表明本文提出的 ML-CRBMs-ELM 模型能从相关性较差的变量间充分提取到有用的特征表达,使得模型的预测精度得到提高.再从图 3 中可看出当 ELM 模型的隐层节点数取 29 的时候,模型能达到较高的命中率.

表 2 CBMONPP 数据集相对均方误差

RMSE	MLCRBMs-ELM	DBM-ELM
training	0.062 3	0.164 5
test	0.095 6	0.203 2

4.2 加氢裂化

常压塔是一个复合塔,原油通过常压蒸馏要切割成汽油、煤油、轻柴油、重柴油和重油等五种产品.本文考虑采用 MLCRBMs-ELM 软测量模型来预测航煤干点.以某石化公司的加氢裂化装置为研究背景,加氢裂化第一分馏塔示意图如图 4 所示.




图 4 加氢裂化分馏塔示意图

本文设航煤干点与辅助变量之间的数学模型公式如下所示:

$$Y = f(T_h, F_h, T_j, F_j, T_r, F_r, T_{top}, P_{top}, T_{in}, F_{in}, T_b, F_b, F_L) \tag{20}$$

式中, $f()$ 为辅助变量与主导变量之间的映射关系; T_h 为重石脑油抽出点温度; F_h 为重石脑油抽出量; T_j 为航煤抽出点温度; F_j 为航煤抽出量; T_r 为塔顶回流温度; F_r 为回流量; T_{top} 为塔顶温度; P_{top} 为塔顶压力; T_{in} 为进料温度; F_{in} 为进料量; T_b 为塔底温度; F_b 为塔底流量; F_L 为轻石脑油抽出量, 这 13 个变量构成航煤干点软测量建模的辅助变量。

为了判定软测量模型的估计性能, 本文分别采用了相对均方误差 (RMSE) 和平均相对变动值 (ARV) 二个指标. 其中, RMSE 指标来衡量软测量模型的估计精确程度; ARV 指标来衡量软测量模型的泛化能力, ARV 值越大表明软测量模型的泛化能力越差. 二个指标的计算公式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (f - \hat{f})^2}{N}} \tag{21}$$

$$ARV = \frac{\sum_{i=1}^N (f - \hat{f})^2}{\sum_{i=1}^N \bar{(f - \hat{f})}^2} \tag{22}$$

式中, f 为实际值; $\hat{f}$ 为软测量模型的估计值; $\bar{(f - \hat{f})}$ 为软测量模型的估计平均值。

4.3 加氢裂化航煤干点软测量

通过对现场数据进行采集, 并利用 3 σ 准则剔除病态数据, 共采集 800 组数据, 随机选取 750 组作为训练数据, 剩余 50 组为测试数据集. 将训练数据通过 FCM 进行属性划分, 实验表明当划为二类时, 各类数据较为均匀, 故将数据集分为二类 (C_1 和 C_2), 其中 C_1 为航煤干点辅助变量中的温压值等参数, C_2 为有关进出料的流量参数. 因此从输入数据筛选出的 13 个属性被分成 6 维和 7 维度属性簇. 将不同的属性簇输入至 MLCRBMs 中, 进行单独的学习和特征提取, 然后通过 Blending 层进行特征融合, 最后叠加 ELM 极限学习机作为模型输出层, 得出其拟合结果. 使用 DBM-ELM 模型^[14] 和 RBM-ELM 模型进行实验对比.

为了更好的评价模型性能, 分别使用预测均方根误差 (RMSE) 和命中率 HR (误差为 $\pm 1^\circ\text{C}$) 对模型准确性进行分析. 从表 3 和图 5 中可看出, 本文提出的基于 MLCRBMs-ELM 的软测量模型与传统模型相比, 模型的均方误差和平均相对变动值相比于 DBM-ELM 和 RBM-ELM 得到降低, 同时模型的命中率得到提高, 达到了 96.2%, 这表明 MLCRBMs-

ELM 模型对不同的属性簇进行同步单独特征提取的策略, 使得模型在相关性很差的辅助变量中提取出有用的数据特征, 提高了模型的主导变量估计的精度和模型的泛化能力。




图 5 模型预测结果对比图

表 3 各模型性能指标对比统计

性能指标	RBM-ELM	DBM-ELM	MLCRBMs-ELM
RMSE	0.541 2	0.365 4	0.163 2
ARV	0.194 1	0.102 3	0.071 2
HR/%	77.6	91.4	96.2

为了验证 MLCRBMs-ELM 软测量模型相比于传统的软测量模型更具有稳定性, 本文从每个月内随机抽取多组辅助变量数据, 组成一个编号为 0~9 的 10 组数据集, 将 12 组测试集分别输入至已经训练好的 MLCRBMs-ELM 和 DBM-ELM 软测量模型中, 得到最后的命中率 HR (误差为 $\pm 1^\circ\text{C}$). 从图 6 中可看出 MLCRBMs-ELM 模型的最大和最小的 HR 差值为 1.4%, DBM-ELM 模型的差值为 7.5%, 这表明 CRBM 模型的使用和 MLCRBMs-ELM 模型对不同的属性簇进行同步单独特征提取的策略使得 MLCRBMs-ELM 测量稳定性高于




图 6 模型预测结果对比图

DBM-ELM. 因此,本文方法整体的估计精度高于其他的算法.

5 结束语

面对软测量模型中辅助变量之间相关性差使得主导变量估计精度不高等问题,本文提出了 ML-CRBM_s-ELM 软测量模型,首先利用 FCM 算法对数据进行属性簇划分,将划分得到多个属性簇输入至 MLCRBM_s 特征提取集中进行特征提取,将提取到的多个特征子集输入至 Blending 层进行特征融合得到新的特征集,最后输入至极限学习机中进行拟合,得到最后的拟合结果. 实验结果表明 ML-CRBM_s-ELM 模型相比于其他的传统算法,不仅有较高的拟合精度,而且提升了软测量模型的稳定性,具有较好的泛化能力.

参考文献:

- [1] Min H, Luo X L. Calibration of soft sensor by using Just-in-time modeling and AdaBoost learning method [J]. Chinese Journal of Chemical Engineering, 2016, 24(8):1038-1046.
- [2] 曹鹏飞, 罗雄麟. 化工过程软测量建模方法研究进展 [J]. 化工学报, 2013, 64(3):788-800.
- [3] 汤健, 赵立杰, 岳恒, 等. 湿式球磨机筒体振动信号分析及负荷软测量 [J]. 东北大学学报(自然科学版), 2010, 31(11):1521-1524.
- [4] 常鹏, 王普, 高学金, 等. 基于统计量模式分析的 MK-PLS 间歇过程监控与质量预报 [J]. 仪器仪表学报, 2014, 35(6):1409-1416.
- [5] 张振, 徐立中, 韩华, 等. 基于径向基神经网络的明渠流量软测量方法 [J]. 仪器仪表学报, 2011, 32(12):2648-2655.
- [6] Ackley D H, Hinton G E, Sejnowski T J. A learning

algorithm for boltzmann machines [J]. Cognitive Science, 1985, 9(1):147-169.

- [7] Ackley D H, Hinton G E, Sejnowski T J. A learning algorithm for Boltzmann machines [M]. Ablex Publishing Corp. 1985:147-169.
- [8] Melchior J, Fischer A, Wiskott L. How to center deep boltzmann machines [J]. Journal of Machine Learning Research, 2016, 17(99):61.
- [9] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70(1/3):489-501.
- [10] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]// IEEE International Joint Conference on Neural Networks. IEEE, 2005:985-990.
- [11] Guo L, Hao J, Liu M. An incremental extreme learning machine for online sequential learning problems [J]. Neurocomputing, 2014, 128(27):50-58.
- [12] 严东, 汤健, 赵立杰. 基于特征提取和极限学习机的软测量方法 [J]. 控制工程, 2013, 20(1):55-58.
- [13] Saul L K, Roweis S T. Think globally, fit locally: unsupervised learning of low dimensional manifolds [J]. Journal of Machine Learning Research, 2003, 4(2):119-155.
- [14] 王宇红, 狄克松, 张姗, 等. 基于 DBN-ELM 的聚丙烯熔融指数的软测量 [J]. 化工学报, 2016, 67(12):5163-5168.

作者简介:

倪健华 男, (1992-), 硕士研究生. 研究方向为人工制智能与软测量建模. E-mail:1207790299@qq.com.

王 静 女, (1982-), 副研究员. 研究方向为机器学习和软测量建模.

(上接第 6 页)

- [8] Al Azza A A, Al Jodah A A, Harackiewicz F J. Spider monkey optimization: a novel technique for antenna optimization [J]. IEEE Antennas and Wireless Propagation Letters, 2016(15):1016-1019.
- [9] Singh U, Salgotra R. Optimal synthesis of linear antenna arrays using modified spider monkey optimization [J]. Arabian Journal for Science and Engineering, 2016, 41(8):2957-2973.

- [10] 杜振鑫, 王兆青. 一种改进的动态改变惯性权重的粒子群算法 [J]. 微电子学与计算机, 2011, 28(3):85-88.

作者简介:

姜 爽 女, (1992-), 硕士研究生. 研究方向为智能算法. E-mail:13302139306@163.COM.

林 丹 男, (1968-), 博士, 教授. 研究方向为智能算法、车辆调度问题.