

doi:10.11835/j.issn.1000-582X.2019.02.012

## 露天矿卡车外排土场内部运距预测模型

白润才<sup>1a</sup>, 柴森霖<sup>1b</sup>, 刘光伟<sup>1b</sup>, 付恩三<sup>2</sup>, 赵景昌<sup>1a</sup>, 曹博<sup>1b</sup>

(1. 辽宁工程技术大学 a. 辽宁省高等学校矿产资源开发利用技术及装备研究院; b. 矿业学院, 辽宁 阜新 123000;  
2. 中华人民共和国应急管理部信息研究院, 北京 100029)

**摘要:**为有效提高外排土场物料移运规划中运输功能耗模型的精度,以建立更为详细的排弃物料堆置次序优化、规划模型,针对年末排土计划中尚缺乏逐条带运距推估方法的问题展开研究,提出一种采用极限学习机算法(ELM)训练多元非线性运距曲线的预测模型,并将年末排土工程计划位置上已设计运输线路的排土条带作为训练样本,训练预测模型学习运距与影响因子间的时变特征,最终通过非线性运距表达推估待排物料块体的时变运距。为进一步增强 ELM 算法的预测精度,利用改进粒子群算法建立基于结构风险最小化的参数优化算法,改善了传统经验风险最小化算法的泛化能力,提高了算法预测精度。研究表明:采用模拟试算图解法最终确定 ELM 模型隐含层节点数为 27;仿真测试中得出文中算法预测精度评价指标分别为均方误差 0.006 8、拟合优度 0.995 3、相对误差期望 0.027%、绝对误差期望 0.62、错估系数 0.03、执行效率 1.49 s;对比多组智能算法预测模型,其绝对误差分别 0.116 2、0.094 7、0.139 1,其错估系数分别为 0.230、0.200、0.266,算法明显具有更好的预测效果。

**关键词:**卡车外排土场;运距预测;极限学习机算法;改进粒子群算法

**中图分类号:**TD713

**文献标志码:**A

**文章编号:**1000-582X(2019)02-112-11

## A prediction model of the truck dumping haul distance in open-pit mine

BAI Runcai<sup>1a</sup>, CHAI Senlin<sup>1b</sup>, LIU Guangwei<sup>1b</sup>, FU Ensan<sup>2</sup>, ZHAO Jingchang<sup>1a</sup>, CAO Bo<sup>1b</sup>

(1a. Liaoning Academy of Mineral Resources Development and Utilization Technology and Equipment Research Institute; 1b. School of Mining, Liaoning Technical University, Fuxin 123000, Liaoning, P. R. China; 2. Information Research Institute of the Ministry of Emergency Management of the People's Republic of China, Beijing 100029, P. R. China)

**Abstract:** In order to effectively improve the accuracy of transportation function consumption models, open-pit designer can establish a more detailed material transportation planning model for the problems that cannot be solved for lack of estimation method of strip-by-strip transport distance in the annual plan. In this

**收稿日期:**2018-07-03

**基金项目:**国家自然科学基金资助项目(51304104);辽宁省教育厅基金资助项目(LJYL038, LJ2017FAL015);辽宁省煤炭资源安全开采与洁净利用工程研究中心开放基金资助项目(TU15KF07)。

Supported by the National Natural Science Foundation of China (51304104), Project Fund of Education Department of Liaoning Province (LJYL038, LJ2017FAL015) and the Open Projects of Research Center of Coal Resources Safe Mining and Clean Utilization, Liaoning (TU15KF07).

**作者简介:**白润才(1961—),男,辽宁工程技术大学教授,博士生导师,主要研究方向为露天矿优化开采设计、数字化矿山及矿业系统工程。

柴森霖(联系人),男,辽宁工程技术大学博士研究生,主要研究方向为露天矿优化开采设计、数字化矿山及矿业系统工程,(E-mail)3560103696@qq.com。

paper a prediction model of multivariate nonlinear haul distance curve trained by extreme learning machine was proposed. The dump strip on transport line designed for year-end dump project location was taken as the training sample to train prediction model to learn the time varying trait of haul distance and influence factor. Finally, the nonlinear estimation of haul distance expression was used to predict block variable distance. In order to enhance the prediction accuracy of the ELM algorithm, the modified particle swarm optimization algorithm was adopted to build the model of parameters optimization aimed at structural risk minimization and realized the structural risk correction to improve the accuracy of prediction algorithm. The results show that the method of ELM model ultimately determine the number of hidden layer nodes to be 27 through the test of simulation by trial and graphic test. The evaluation indexes of algorithm prediction accuracy (mean square error, goodness of fit, relative error expectation, absolute error expectation, misestimation coefficient, execution efficiency) are 0.006 8, 0.995 3, 0.027%, 0.62, 0.03 and 1.49 respectively. Compared with other prediction model of intelligent algorithm, their absolute error are 0.116 2, 0.094 7, 0.139 1 and the coefficient of miscalculation are 0.230, 0.200, 0.266. In conclusion, the algorithm has better prediction effect obviously.

**Keywords:** truck dumping; haul distance prediction; ELM; MPSO

露天矿排土场内部运距是排土场内部物料运输功计算的重要指标之一,其推估质量直接关系到排土物料移运规划模型中的运输系统的能耗水平<sup>[1-2]</sup>。

目前,国内外关于运距确定方法的研究多集中于两种。一种是以年末计划位置图上道路运输网络为基础,分水平、分区段分割整年物料块段,最终采用重心法对块段运距进行几何量测;如魏强等<sup>[3]</sup>利用线性规划思想,建立以年度为规划阶段的物流规划系统;卢雯雯等<sup>[4]</sup>基于重心法提出解决多阶段、多变量、多目标排岩规划问题的新方法;另一种则采用数学方法进行运距推估;如刘佶林等<sup>[5-6]</sup>通过引入堆置体概念,提出一种针对解决块体物料运距赋值的堆置体搜索算法;Li等<sup>[7-10]</sup>利用实际排土工程推演的逻辑,结合规划算法提出堆置物料块体运距推估的优化算法;于汝绶等<sup>[1]</sup>、刘光等<sup>[11-12]</sup>提出一种采用基于物料量递推动态运距曲线的方法。

在上述研究成果基础上,笔者总结了传统算法应用于精细化物流建模的局限性,并针对排土计划阶段内运输线路未知的排土计划条带内逐块体运距推估问题,提出预测排土场内部动态时变运距的新算法。算法从关键的运距影响因素入手,建立一组多元非线性预测模型,将排土阶段末计划位置上已知运输线路块体的运距信息、影响因素属性作为预测模型的训练数据,通过引进改进的极限学习机算法确定非线性模型参数,确定运距的非线性表达。最终应用运距的非线性表达预测排土阶段内时变运距。经仿真实验对比验证,文中算法预测精度较高,且具有较好的学习能力。

## 1 MPSO-ELM 预测模型理论基础

### 1.1 极限学习机基础

极限学习机(extreme learning machine, ELM)算法模型是由南洋理工大学黄广斌教授提出的一种单隐层前馈神经网络学习算法<sup>[13-16]</sup>,其训练模型结构如图1,其区别于传统的神经网络模型,算法求解无需反复迭代的梯度学习,仅通过随机确定输入权值和隐含层节点阈值便可直接产生最优解,避免了传统梯度学习算法复杂的优化调参过程。具有极强的复杂映射学习能力,对于非结构性、一般规律性的非线性模型训练具有极强的自适应性,且具有良好的容错能力<sup>[17]</sup>。

假设给定运距预测模型的训练数据集  $T = \{(X_1, y_1), \dots, (X_n, y_n)\}$ , 其中  $x_k \in R^p$  为  $p$  维的输入向量,  $y_k \in R$  为输出向量, 则  $x_j$  节点含有  $\tilde{n}$  个隐层节点激励函数  $G$  的极限学习机模型如式(1)所示, 对于具有  $n$  个输入层节点的完整回归估计模型如式(2)所示。

$$f_{n^*}(x_j) = \sum_{i=1}^{\tilde{n}} \beta_i G(a_i \cdot x_j + b_i), \quad (1)$$

$$\begin{cases} \sum_{i=1}^{n^*} \beta_i g(a_i \cdot x_1 + b_i) = y_1 \\ \sum_{i=1}^{n^*} \beta_i g(a_i \cdot x_2 + b_i) = y_2, \\ \dots\dots \\ \sum_{i=1}^{n^*} \beta_i g(a_i \cdot x_n + b_i) = y_n \end{cases} \quad (2)$$

式中： $\beta_i = [\beta_{i1}, \dots, \beta_{in^*}]^T$ 为隐含层节点  $i$  的输出权值； $a_i = [a_{i1}, \dots, a_{in^*}]^T$ 为隐含层节点  $i$  的输入权值； $b_i$  隐含层节点  $i$  的阈值； $g(a_i, b_i, x)$ 为激励函数。

将式(3)、(4)形式引入回归模型式(2)中,可推得式(2)线性方程的矩阵形式(式(5))。

$$\beta = \begin{bmatrix} \beta_1^T \\ \dots \\ \beta_{n^*}^T \end{bmatrix}_{n^* \times m}, \quad Y = \begin{bmatrix} y_1 \\ \dots \\ y_{n^*} \end{bmatrix}_{n^* \times m}, \quad (3)$$

$$H(\omega_1, \dots, \omega_{n^*}, b_1, \dots, b_{n^*}, x_1, \dots, x_{n^*}) = \begin{bmatrix} g(a_1 x_1 + b_1) & \dots & g(a_{n^*} x_1 + b_{n^*}) \\ \dots & \dots & \dots \\ g(a_1 x_n + b_1) & \dots & g(a_{n^*} x_n + b_{n^*}) \end{bmatrix}_{n \times n^*}, \quad (4)$$

式中： $H$  神经网络隐含层输出矩阵,其他参数同上。

$$H\beta = Y. \quad (5)$$

对于式(5)中输出权值  $\beta$  的求解可基于最小经验风险建立损失函数如式(6),将求解问题转化为一个线性系统求解最小二乘解的问题,进而唯一确定输出权值  $\beta$ 。

$$\min \sum_{j=1}^n \|H\beta - Y\| = \sum_{j=1}^n \left( \sum_{i=1}^{n^*} \beta_i G(a_i \cdot x_j + b_i) - y_j \right)^2. \quad (6)$$

其唯一解解形式如式(7)所示。

$$\hat{\beta} = H^+ Y, \quad (7)$$

式中： $H^+$ 为隐含层输出矩阵  $H$  的 Moore-Penrose 广义逆<sup>[13-16]</sup>。

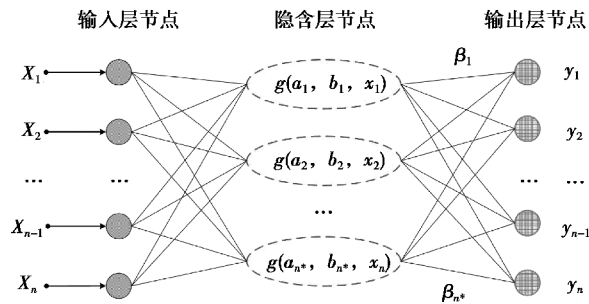


图 1 极限学习机的网络训练模型  
Fig. 1 Network training model of ELM

### 1.2 MPSO 优化 ELM 预测模型

近年来,随着极限学习机技术的发展,不断有文献报道关于优化隐含层节点数、输入权值以及隐含层阈值的新方法,其中比较有代表性的即为采用粒子群算法(PSO)、遗传算法(GA)以及其他类型的改进算法<sup>[18-20]</sup>优化调参,但对于预测求解问题仍具有局限性,主要表现在:缺乏隐含节点数、输入权值以及隐含层阈值的动态的联合调参算法;传统基于经验风险最小化准则建立的 ELM 模型,极易造成训练模型过拟合,导致泛化能力低下,无法应用于实际预测场景等问题。为进一步提高算法预测精度,文中从构建结构风险最小化

入手,提出一种改进粒子群算法对 ELM 模型进行多参数动态调参,详细的算法流程见图 3。

对于基于 ELM 模型的运距预测模型,其基于经验风险的平方损失函数可以表示如式(8)。

$$L(Y, f(X)) = (Y - f(X))^2 = \sum_{j=1}^n \sum_{i=1}^{\tilde{n}^*} (\beta_i g(\mathbf{a}_i \cdot \mathbf{x}_j + b_i) - y_j)^2. \quad (8)$$

为使模型具有更好的泛化能力,获得经验风险和期望风险间的理想权衡,文中基于结构风险最小化原则,对模型进行修正,其修正式如式(9)所示。

$$\min \frac{1}{n} \left[ \sum_{j=1}^n \frac{1}{\tilde{n}^*} \sum_{i=1}^{\tilde{n}^*} (\beta_i g(\mathbf{a}_i \cdot \mathbf{x}_j + b_i) - y_j)^2 \right] + c \gamma^2, \quad (9)$$

式中: $\gamma^2$ 为惩罚项, $\gamma$ 函数形式如式(10)所示,其中  $c$  取较大值时证明优化模型更注重由随机测试带来的误差损失。

$$\gamma = \sqrt{\frac{d_i}{m-1}} = \sqrt{\frac{(\tilde{y}^* - y')^2}{m-1}}, \quad (10)$$

式中: $\tilde{y}^*$ 为结构修正测试集预测结果; $y'$ 为结构修正测试集真值; $m$ 为测试集规模。

故整个参数优化问题被转化为以向量  $\mathbf{a}, \mathbf{b}$  为优化变量,以式(9)中结构风险最小化模型为目标函数,应用粒子群算法求解最优化问题,其中粒子群算法适应值函数如式(11)所示。

$$F(\mathbf{a}, \mathbf{b}) = \frac{1}{L(Y, f(X))} = \frac{1}{\sum_{i=1}^{\tilde{n}^*} (\beta_i g(\mathbf{a}_i \cdot \mathbf{x}_j + b_i) - y_j)^2}. \quad (11)$$

利用非线性模型预测运距其本质是一种建立在多元回归估计基础上,面向已知道路设计的非线性推估手段,其模型受多种因素综合影响且已知数据伴有一定规模局限性,上述影响对于实际参数优化建模极为敏感,会直接制约粒子群算法种群搜索范围,随着迭代进行会促进种群丧失多样性,导致早熟现象发生。因此,为进一步提高 ELM 模型优化效果,文中从扩充种群搜索空间、增进种群多样性以及动态分配惯性因子等几方面入手,对粒子群算法进行改进,提出更为接近稳健性建模的方法策略。其中惯性因子( $\omega$ )、学习因子( $c_1, c_2$ )修正式如式(12)。其作用在于能有效的保证算法在迭代前期以较大的范围搜索最优解,较大程度的保持种群多样性。而在迭代后期有利于实现更精细的局部搜索,以提高整体优化建模精度。

$$\begin{cases} \omega = \left[ \left( 1 - \left( \frac{k}{D} \right)^{\frac{1}{3}} \right) \omega_s + \left( \frac{k}{D} \right)^{\frac{1}{3}} \omega_e \right] / 2, \\ c_1 = c_{1s} - (c_{1s} - c_{1e}) \left( \frac{k}{D} \right)^{\frac{1}{3}}, \\ c_2 = c_{2s} + (c_{2e} - c_{2s}) \left( \frac{k}{D} \right), \end{cases} \quad (12)$$

式中: $\omega_s, \omega_e$ 分别表示惯性权重  $\omega$  的初始值和上一期迭代结果值; $c_{1s}, c_{1e}$ 分别表示学习因子  $c_1$  的初值和上一期迭代结果值; $k$ 表示迭代次数; $D$ 表示总的迭代次数。

为进一步扩大搜索空间,减少个体寻优过程中极易陷入局部最优状态的可能,在每次迭代产生的搜索空间内,算法会采用轮盘赌法随机调整部分粒子位置,以加大搜索空间内寻优策略的随机性,引入轮盘赌后其位置更新模型如下:

$$x_i = x_i + \left[ (x_{\max} - x_i) \frac{x_i}{(x_{\max} - x_{\min})} + (x_i - x_{\min}) \frac{(x_{\max} - x_{\min}) - x_i}{(x_{\max} - x_{\min})} \right] \frac{k\gamma}{D}, \quad (13)$$

式中: $\gamma$ 为 $[-1, 1]$ 区间上的随机数,其他参数同上。

搜索空间内粒子状态初始化规模由轮盘赌概率事件决定,由于轮盘赌模型建立在适应值函数基础之上,文中启发式的等分了适应值区间,采用式(14)统计区间频率,最后以随机数  $\gamma \in [0, 1]$ 在统计区间内的 1 000 次频率作为优选概率。该方法的优势在于随着迭代逼近最优解会不断加大优选规模,可动态扩大粒子群模

型的搜索空间。其适应值被带入下一个状态的概率估计如式(14)所示。

$$P(X_s) = \frac{\sum_i^p F_i(a, b)}{\sum_k^n F_k(a, b)}, s \in S, \quad (14)$$

式中:  $F$  所对应的是式(11)中所计算出得对应值;  $S$  表示粒子种群总体;  $s$  表示种群个体。

为保证 MPSO-ELM 算法模型在优化调参过程中, 具有联动的隐含节点数优化能力, 文中在粒子群迭代过程中引入节点数的单位梯度下降算法建立试算模型, 实现优化调参后的逐节点试算, 最终以均衡执行效率和精度为原则优选节点数, 其优选节点判别式如式(15)所示。

$$\min \mathcal{O} = \min \left[ \frac{\nabla \delta}{(\nabla \delta_{\max} - \nabla \delta_{\min})} - \frac{\nabla t}{(t_{\max} - t_{\min})} \right], \quad (15)$$

其中

$$\nabla \delta = \left[ \frac{1}{n} \sum_{j=1}^n \frac{1}{n^*} \sum_{i=1}^{n^*} |\beta_i g(a_i \cdot x_j + b_i) - y_j| \right]. \quad (16)$$

## 2 基于 MPSO-ELM 的运距预测模型

### 2.1 影响因子选取

露天矿外排土场运输网络其本质是一个受多元因素综合影响的动态非线性系统, 其运距明显受道路运输系统的关键组成要素影响。因此, 笔者选取如下 7 个参数作为运距预测模型的影响因子: 块体质心至排土场入口的欧氏距离( $D_{i,j,k}$ )、物料提升高度( $H_{i,j,k}$ )、阶段累加工程量( $M_{i,j,k}$ )、坡道长度( $L_{i,j,k}$ )、缓冲段长度( $L'_{i,j,k}$ )、台阶高度( $H_{i,j,k}^T$ )以及道路坡度( $\beta_{i,j,k}$ )。

$$D_{i,j,k} = ((y_{ijk} - y_{o1})^2 + (x_{ijk} - x_{o1})^2)^{\frac{1}{2}}. \quad (17)$$

### 2.2 数据预处理

当排土场存在多出入口、多运输干线时, 土岩物料的基础道路结构将发生变化, 若采用不同道路结构的数据训练非线性模型, 易导致预测模型难以收敛于一致表达, 造成精度损失。为进一步说明上述问题, 文中以图 2 为例, 介绍当排土场存在多出入口、多运输干线条件下的分组方式。图 2 是为描述分组而假定的排土场推进方向上纵剖面图示意图, 其中  $B_1 \sim B_8$ 、 $D_1 \sim D_8$  条带为已知道路运输条件的计划工程位置, 文中拟求解的运距推估问题即为预测排土条带  $B$  与排土条带  $D$  期间的物料块体运距。图中所指线路  $B_1 \sim B_8$  (以及线路  $C_1 \sim C_8$ 、线路  $E_1 \sim E_8$ ) 并非剖面上实际的线路组成, 该图示路径仅指明排土场端帮环线的布置位置。假设图 2 中 2018 年末排土计划位置上物料( $B_1 \sim B_8$ ) 入口为  $a$ , 2019 年末排土计划位置上物料( $D_1 \sim D_8$ ) 入口  $b_1$ , 对于采用回归模型进行回归估计, 其控制模型精度的关键即应保证模型不应才在结构性的任意外推, 但对于文中结构, 当采用  $B_1 \sim B_8$ 、 $D_1 \sim D_8$  条带上的块体属性训练同一组模型时, 会直接导致回归模型的结构性变化, 造成回归估计出现明显的二义性。为消除上述二义性影响, 文中在训练前对训练数据进行结构上的预先分组处理。




图 2 排土场纵剖面上数据分组原则

Fig. 2 The data grouping principle in the longitudinal section of dumping



如图 2 所示理想的分组方式为找出排土条带新入口与老入口之间的等距位置,并保证随着推进,新入口距离占优。但上述条件建立的基础是在距前方新入口较远处便开始建立运输道路,即如图 2 中相对于新入口  $b_1$  的  $X_3 \sim X_4$  位置。但对于实际排土定线与上述假设则明显冲突,实际的排土定线需建立在已完成排土位置之上,且需提前满足端帮道路建设的空间条件。因此,新入口启用条件需满足在纵剖面上排土条带推进超前于平面上排土场新入口位置,即如图 2 中排土推进需超前于新入口  $b_1$  距离大于  $L$  (其中  $L$  为排土端帮道路设计在纵剖面上投影最小平面展线距离) 才能具备新入口启用的道路空间条件。文中以该特性为基本分组原则,在新入口位置按排土运输系统端帮道路在纵剖面上投影的最小平面展线距离  $L(X_7, X_8)$  补充端帮排土道路设计(如图 2 中  $C_1$  至  $C_8$ ),利用端帮道路空间条件、几何约束推估条带内的运距参数,以建立不同的运距预测模型,并分组训练,模型示意如图 2。其中  $L(X_7, X_8)$  应按照实际所采用的排土运输线路设计方法确定。

### 2.3 评价因子选取

运距预测模型的误差水平是反映整个预测模型精度的重要评价因子<sup>[21]</sup>,为进一步综合评价文中算法模型的参数优化和运距预测效果,文中引入如下的误差水平评价指标,各参数具体计算方法如下。

#### 2.3.1 均方误差( $\epsilon_{\text{MSE}}$ )

均方误差水平表征的是运距估计值与运距真值平方偏差的期望值,该因子是文中评价体系中衡量参数估计过程中拟合程度的重要指标之一,即认为均方误差越小,回归估计的精度越高,与实际非线性曲线越接近,预测效果则越好。其参数计算方法如式(18)。

$$\epsilon_{\text{MSE}} = \frac{\sum_{i=1}^n (y' - y)^2}{n}, \quad (18)$$

式中: $n$  为样本总数; $y'$  为运距预测值; $y$  运距真值。

#### 2.3.2 拟合优度( $R^2$ )

为进一步描述运距预测值与训练真值的非线性相关程度,文中引入拟合优度用以度量变量间的相关性,进而评价参数优化效果。即认为该值越接近 1,拟合程度越高,参数优化效果越好,预测质量越好。其参数计算方法如式(19)。

$$R^2 = 1 - \frac{S_{\text{RSS}}}{S_{\text{TSS}}} = 1 - \frac{\sum_{i=1}^n (y' - y)^2}{\sum_{i=1}^n (y' - \bar{y})^2}, \quad (19)$$

式中: $S_{\text{RSS}}$  为残差平方和; $S_{\text{TSS}}$  为总离差平方和;其他参数同式(18)。

#### 2.3.3 错估计系数( $R_M$ )

错估计系数是文中为综合衡量总体估计而设计的无量纲参数指标。在预测模型中所谓错估计是指绝对误差大于块体模型边长的现象,判据如式(20),一般认为这种错误估计会直接影响物料流规划模型精度,其参数计算方法见式(21)。

$$\epsilon_{\text{ME}} = |y' - y| > l, \quad (20)$$

$$R_M = \frac{n_M}{n}, \quad (21)$$

式中: $\epsilon_{\text{ME}}$  为绝对误差; $l$  为块体模型边长; $n_M$  满足错估计判据的块体模型数量;其他参数同式(18)。

#### 2.3.4 算法执行效率( $t$ )

该系数指算法执行时间,执行时间越短算法执行效率则越高,算法收敛性越好。

## 2.4 基于 MPSO-ELM 的运距预测算法

MPSO-ELM 运距预测模型的基本预测算法流程如图 3,算法核心作用在于建立 ELM 预测建模与 MPSO 优化调参的动态联系,最终获得非线性预测模型的理想输出,其预测算法的具体实现步骤如下。

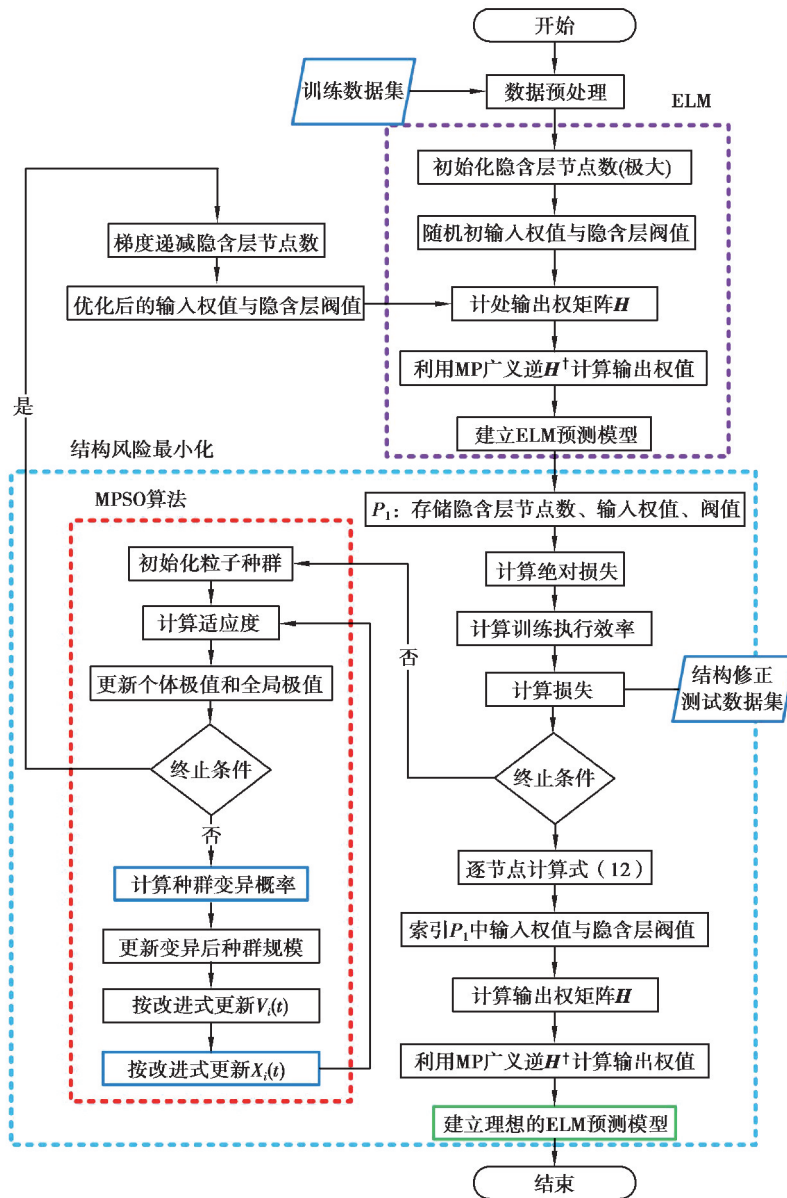


图 3 预测算法流程图

Fig. 3 Flow chart of prediction algorithm

- 1) 当排土阶段内存在多出入口时,对训练数据进行聚类预处理,消除训练数据的二义性,否则忽略此步;
- 2) 初始化 $\hat{n}_0^*$ 为较大值(模型中规定 $\hat{n}_0^* = 150$ );
- 3) 建立伪随机数发生器,对个体输入权值 $a_i$ 和隐含层阈值 $b_i$ 赋随机初值;
- 4) 计算输出权矩阵 $H$ ,并利用 Moore-Penrose 广义逆 $H^+$ 计算出输出 $\hat{\beta}$ ;
- 5) 利用上述结果,建立经典 ELM 预测模型;
- 6) 引入修正结构风险的测试数据集 $T_M$ ,利用 ELM 预测模型 $T_M$ ,并统计均方误差 $\gamma^2$ ;
- 7) 将步骤 6 中 $\gamma^2$ 作为惩罚项(其中惩罚因子 $c = 100$ ),并结合式(8)中预测模型的平方损失函数构成模型的结构风险;
- 8) 基于步骤中结构风险,建立式(9)的结构风险最小化模型,并采用改进粒子群算法进行优化求解;
- 9) 利用步骤 3 结果,进行粒子种群初始化;

10) 根据式(11)计算适应度,更新最优粒子状态;

11) 判断终止条件,如满足则执行步骤 12,否则根据 1.2 小节调整粒子群算法参数,后代执行步骤 10;

12) 梯度递减隐含层节点数(其中 $\widetilde{\nabla n^*} = 1$ ;  $\widetilde{n_{\max}^*} = 150$ ;  $\widetilde{n_{\min}^*} = 50$ ),结合优化后 $a_i, b_i$ 迭代执行步骤 4,直至枚举出全部优化解;

13) 优选式(12)所确定的极大值者,并在 $P_1$ 中反向索引出入权值和隐含层阈值,重新建立 ELM 预测模型。

### 3 实例分析

本次研究以解决黑山露天煤矿物料流规划模型逐条带运距推估问题展开。研究选取该矿 2018—2019 年外部卡车外排土场年末计划位置图为基础数据采集模型,在境界内构建标准立方体块体模型,即部分矿业类软件中的块段模型,并根据年末排土计划工程位置建立三维面模型,利用构建的面模型作为几何约束控制块体模型堆置形态,细化出边界位置的次级块体,最终建立逼近真实工程位置形态的立方体块段模型。收集计划排土工程位置上块段模型中的 300 组块体作为设计数据进行建模分析和预测,块体模型标准尺寸  $85 \times 50 \times 20$ ,块体具有次级结构尺寸;采用随机抽样选取 100 组数据作为预测模型的训练样本集,其中 50 组来自于 2018 年排土计划工程位置,其余 50 组来自于 2019 年排土计划工程位置;并选取剩余中的 50 组、30 组分别作为结构修正测试集和测试样本集。设置 MPSO 模型初值如下:种群规模  $N = 30$ ,最大迭代次数  $G = 300$ , $c_1 = 2.5$ , $c_2 = 0.5$ , $\omega = 1$ 。

#### 3.1 隐含层节点数优化

隐含层最优的节点数确定对单隐层神经网络算法精度控制至关重要,神经元个数少预测模型欠拟合,数量过多模型过拟合现象明显。为有效控制最优化节点,文中按照 1.2 小节的方法策略处理节点数优选。

综合文中情况,分别对绝对误差水平以及执行效率进行线性归一化处理,以保证量纲一致,并利用式(15)模拟图解交点最终得出本次研究中最优激励函数为 RBF 函数,最优节点个数为 27。

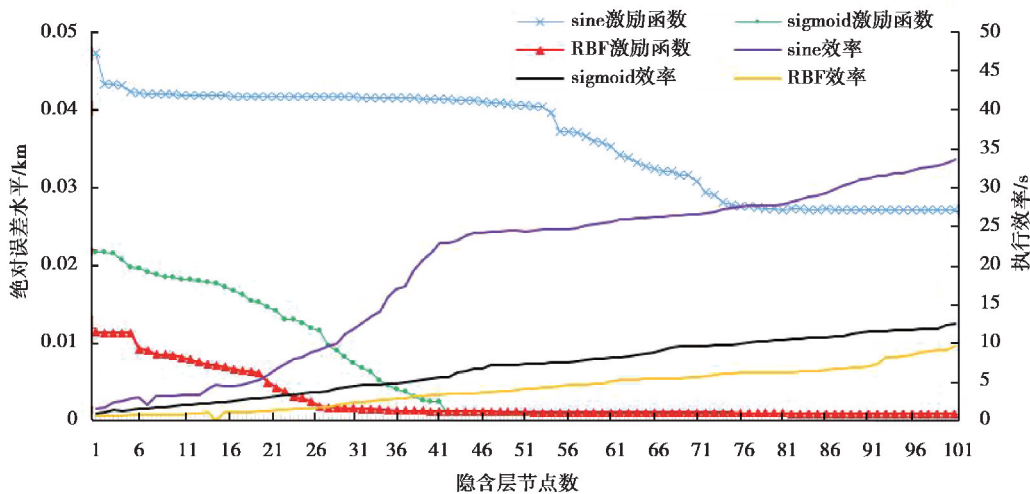


图 4 试算图解法确定最优隐含层节点数

Fig. 4 The number of optimal hidden layer nodes determined by trial graphic method

#### 3.2 测试集预测效果对比分析

利用 3.1 小节确定 RBF 激励函数、隐含层节点数( $\widetilde{n^*} = 27$ )、输入权值以及隐含层阈值重新预测模型,并将 30 组测试集数据带入预测模型,其测试预测结果如图 5 中(a)组模型,其中图 5 中主轴为运距,次轴为预测模型的绝对误差水平。



由图 5(a)可知,文中采用的 MPSO-ELM 模型具有较好的拟合精度,泛化能力好,通过引入惩罚项建立了良好的风险均衡,消除传统 ELM 常存在的过拟合问题。图中红线表示测试集的绝对误差水平,均控制在 1 m 以下,且波动较小。

为进一步验证算法模型的预测效果,分别以 BP 算法、GA-BP 算法以及 SVR 算法为基础构建预测模型,利用同种仿真测试条件建模,其测试集预测结果如图 5 中(b)、(c)、(d)组对比图。由 4 组预测结果对比可知,MPSO-ELM 模型预测结果明显优于其他 3 组模型,(b)、(c)两组模型其训练集绝对误差分别为 2.17, 1.54 m,拟合效果极好,但测试集预测结果精度差别较大,存在明显过拟合现象。(d)模型因受离群误差波动影响较为严重,导致算法模型因为频繁的误差波动而造成拟合精度下降。

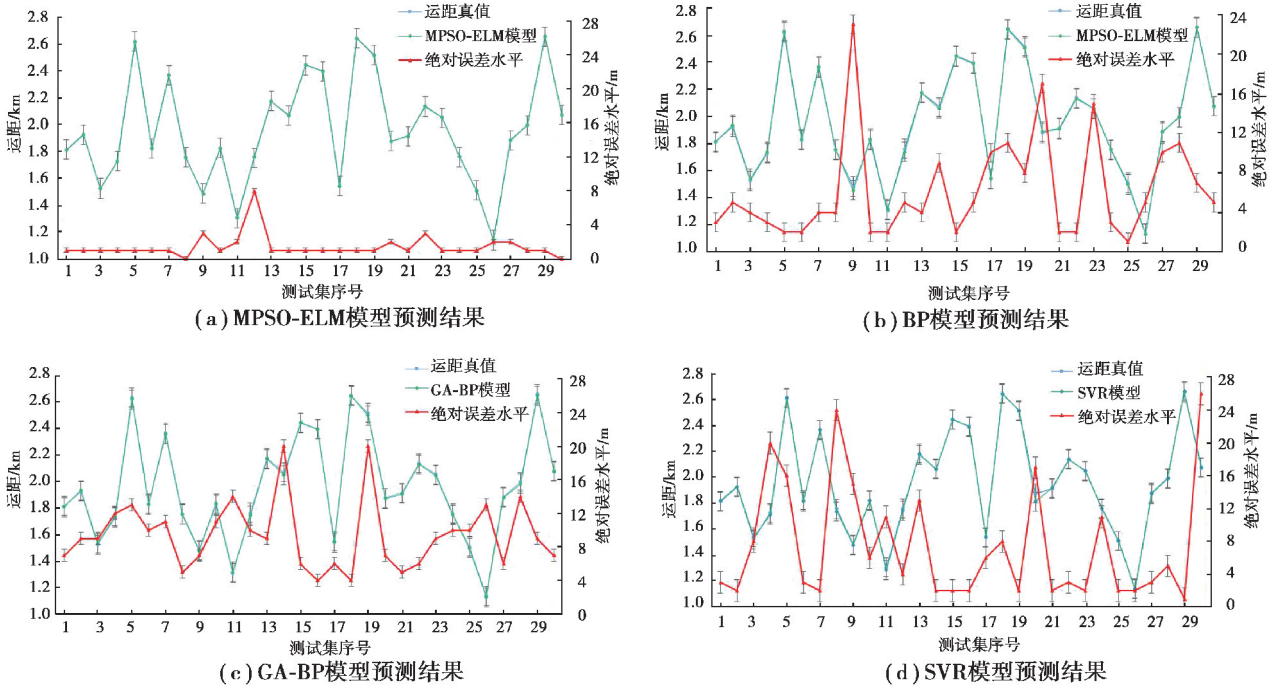


图 5 不同算法模型运距预测结果

Fig. 5 The prediction results of different algorithm models

在图 5 基础上文中对 4 组算法模型的体系评价指标进行统计,统计结果如表 1 所示。表 1 中 MPSO-ELM 模型精度评价指标分别为: $\epsilon_{MSE} = 0.0068$ ;  $R^2 = 0.9953$ ;  $\bar{\epsilon}_{RE} = 0.027\%$ ;  $\bar{\epsilon}_{ME} = 0.62$ ;  $R_M = 0.03$ ;  $t = 1.49$  s。较之均方误差可知,文中算法泛化能力更强,能有效避免过拟合现象的发生;对比错估计系数可知,文中预测结果在现实场景中对于运输功能耗的影响小,对于存在多层次级结构块体的运距推估具有更强的现实意义。

表 1 误差体系指标评价

Table 1 Error system index evaluation

算法对比模型	测试集评价指标体系				测试集预测效果	
	均方误差 $\epsilon_{MSE}/m$	拟合优度 $R^2$	相对误差期望 $\bar{\epsilon}_{RE}/\%$	绝对误差期望 $\bar{\epsilon}_{ME}/m$	错估计系数 $R_M$	效率/s
MPSO-ELM 模型	0.006 8	0.995 3	0.027	0.62	0.030	1.49
BP 神经网络模型	0.116 2	0.956 2	0.316	1.83	0.230	5.57
GA-BP 神经网络模型	0.094 7	0.973 1	0.273	1.57	0.200	0.71
SVR 模型	0.139 1	0.912 4	0.516	3.68	0.266	2.63

## 4 结 论

1)为有效解决排土场内部逐条带的运距推估问题,提出一种采用极限学习机(ELM)训练多元非线性运距曲线的预测模型;

2)针对 ELM 隐含层节点数、输入权值以及隐含层阈值选择不当易造成 ELM 过拟合问题,文中在修正了传统粒子群(PSO)自身缺陷的基础上,采用改进粒子群算法,建立了基于结构风险最小化为目标的动态调参算法;为进一步求解隐含层节点数,引入节点单位梯度下降算法,并模拟试算图解法,得出均衡精度与性能后的最优隐含层节点个数;

3)通过多组仿真实验对比分析,文中算法最终确定精度评价指标分别为 $\epsilon_{\text{MSE}}=0.0068$ , $R^2=0.9953$ , $\bar{\epsilon}_{\text{RE}}=0.027\%$ , $\bar{\epsilon}_{\text{ME}}=0.62$ , $R_{\text{M}}=0.03$ , $t=1.49\text{ s}$ ,相比于其他智能算法,MPSO-ELM 模型具有更高预测精度以及泛化能力,能为运输功建模提供更为精准的数据支撑。

### 参考文献:

- [1] 于汝绶,张瑞新,王宝庭,等.露天采矿优化理论与实践[M].北京:煤炭工业出版社,2005:224-238.  
YU Rushou, ZHANG Ruixin, WANG Baoting, et al. Optimization theory and practice of open pit mining[M]. Beijing: China Coal Industry Publishing House, 2005: 224-238. (in Chinese)
- [2] 张幼蒂,李克民,张瑞新,等.露天开采优化设计理论与应用[M].徐州:中国矿业大学出版社,2000:309-315.  
ZHANG Youdi, LI Kemin, ZHANG Ruixin, et al. Theory and application of optimum design for open pit mining[M]. Xuzhou: China University of Mining and Technology, 2000: 309-315. (in Chinese)
- [3] 魏强,李克民,姚绍武.露天矿物料流规划系统的设计与实现[J].中国矿业大学学报,2003,32(2):180-182.  
WEI Qiang, LI Kemin, YAO Shaowu. Design and realization of surface mining material-stream programming system[J]. Journal of China University of Mining & Technology, 2003, 32(2): 180-182. (in Chinese)
- [4] 卢雯雯,叶义成,刘明,等.露天矿排岩优化的物流调度规划方法探讨[J].资源环境与工程,2007,21(4):466-470.  
LU Wenwen, YE Yicheng, LIU Ming, et al. A research of dumping optimization in strip mine based on logistics programming[J]. Resources Environment & Engineering, 2007, 21(4): 466-470. (in Chinese)
- [5] 刘佶林,戴晓江,王孝东.露天矿排土运输优化的最优排土堆置体搜索算法研究[J].矿业研究与开发,2016,36(12):13-18.  
LIU Jilin, DAI Xiaojiang, WANG Xiaodong. The optimized dumping region searching algorithm of dumping transportation for open-pit mine[J]. Mining Research and Development, 2016, 36(12):13-18. (in Chinese)
- [6] 刘佶林.基于数字矿床模型的露天排运规划优化研究[D].昆明:昆明理工大学,2015.  
LIU Jilin. Optimization research of outdoor row transportation planning based on digital deposit model[D]. Kunming: Kunming University of Science and Technology, 2015.
- [7] Li Y, Topala E, Williams D. Waste rock dumping optimisation using mixed integer programming (MIP)[J]. International Journal of Mining, Reclamation and Environment, 2013, 27(6): 425-436.
- [8] Li Y, Topal E, Williams D J. Optimisation of waste rock placement using mixed integer programming[J]. Mining Technology, 2014, 123(4): 220-229.
- [9] Li Y, Topal E, Ramazan S. Optimising the long-term mine waste management and truck schedule in a large-scale open pit mine[J]. Mining Technology, 2016, 125(1): 35-46.
- [10] Li Y. Optimum waste dump planning using mixed integer programming (MIP)[D]. Perth: Curtin University, 2014.
- [11] 刘光,张瑞新.露天矿排土及土岩流向流量优化模型[J].化工矿山技术,1991(3):6-8.  
LIU Guang, ZHANG Ruixin. Discharge optimization model of discharge and soil rock flow in open pit mine[J]. Chemical Mining Technology, 1991(3): 6-8. (in Chinese)
- [12] 刘光.露天矿排土场排土程序的综合优化及 $S=F(V)$ 曲线的绘制[J].露天采矿,1989(4):35-39.

- LIU Guang. Comprehensive optimization of dump program and drawing of  $S=F(V)$  curve for open pit mine dump[J]. *Open-cast Mining*, 1989(4): 35-39. (in Chinese)
- [13] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and application[J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [14] Huang G B, Zhu Q Y, Siew C K. Real-time learning capability of neural networks[J]. *IEEE Transactions on Neural Networks*, 2006, 17(4): 863-878.
- [15] Lan Y, Soh Y C, Huang G B. Ensemble of online sequential extreme learning machine[J]. *Neurocomputing*, 2009, 72(13/14/15): 3391-3395.
- [16] Huang G B, Ding X J, Zhou H M. Optimization method based extreme learning machine for classification [J]. *Neurocomputing*, 2010, 74(1/2/3): 155-163.
- [17] 毛力,王运涛,刘兴阳,等.基于改进极限学习机的短期电力负荷预测方法[J].*电力系统保护与控制*,2012,40(20): 140-144.  
MAO Li, WANG Yuntao, LIU Xingyang, et al. Short-tern power load forecasting method based on improved extreme learning machine[J]. *Power System Protection and Control*, 2012, 40(20): 140-144. (in Chinese)
- [18] Kennedy J, Eberhart R, Shi Y H. *Swarm intelligence*[M]. San Francisco, Cal, USA: Morgan Kaufmann Publishers, 2001: 287-318.
- [19] Cao Z Y, Xia J C, Zhang M, et al. Optimization of gear blank preforms based on a new R-GPLVM model utilizing GA-ELM[J].*Knowledge-Based Systems*, 2015, 83: 66-80.
- [20] Xu Y, Shu Y. Evolutionary extreme learning machine-based on particle swarm optimization[M]// Xu Y, Shu Y, eds. *Advances in Neural Networks-ISBN 2006*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006: 644-652.
- [21] Vapnik V N. An overview of statistical learning theory[J]. *IEEE Transactions on Neural Networks*, 1999, 10(5): 988-999.

(编辑 郑洁)