

基于多种智能算法的腐蚀天然气管道可靠性评价方法

何蕾, 温凯, 吴长春, 宫敬*

中国石油大学(北京)机械与储运工程学院, 北京 102249

* 通信作者, ydgj@cup.edu.cn

收稿日期: 2018-10-18

国家自然科学基金青年基金资助项目“基于状态空间模型的天然气管网瞬态优化控制研究”(51504271)资助

摘要 天然气管道地理环境复杂、运行工况多变,以蒙特卡罗模拟为代表的确定性仿真是目前腐蚀管道可靠性评价的主要方法。然而天然气管道高设计可靠度特性所带来的高次模拟问题,使蒙特卡罗模拟十分耗时。为解决这一问题,本文采用神经网络算法取代蒙特卡罗模拟的可靠性评价方法,建立管道基本参数与可靠度的非线性模型。针对目前神经网络算法应用过程中存在的先验信息与神经网络模型的融合问题,本文创新性地提出智能优化算法与神经网络算法相结合的方法。该方法能够将腐蚀管道可靠度变化规律融入到建模过程中。建立了从特征变量的选择、样本数据的生成与处理、神经网络模型构建及模型预测效果评价一体化计算流程。在多种工况下采用神经网络模型对管道结构可靠度进行预测,结果表明该模型能够在极短的时间内获得与蒙特卡罗模拟高度近似的评价结果。相比于传统的神经网络模型,该方法建立的模型在可靠度预测准确性及可靠度变化规律的反映能力方面均有大幅度提高。

关键词 腐蚀天然气管道; 可靠性; 人工神经网络建模方法改进; 模拟退火算法; 拉丁超立方抽样; 遗传算法

A corroded natural gas pipeline reliability evaluation method based on multiple intelligent algorithms

HE Lei, WEN Kai, WU Changchun, GONG Jing

College of Mechanical and Transportation Engineering, China University of Petroleum-Beijing, Beijing 102249, China

Abstract Natural gas pipelines have complex geographical environments and varied operating conditions. Uncertainty simulation represented by Monte Carlo methods has become the main method for pipeline corrosion reliability assessment. However, the high-order simulation problems caused by the high design reliability of natural gas pipelines make Monte Carlo simulations very time-consuming. In order to solve this problem, this paper uses a neural network algorithm rather than Monte Carlo simulation to establish a nonlinear model of basic pipeline parameters and reliability. Because of the difficulty of combining prior information in the modeling process, this paper proposes an innovative method that combines an intelligent optimization algorithm and a neural network algorithm. This method can incorporate the pipe corrosion reliability variation into the modeling process. An integrated computational flow from the selection of feature variables, the generation and processing of sample data, the construction of neural network models and the evaluation of model prediction effects are proposed. Under various working conditions, the neural network model constructed by the method proposed in this paper predicts the reliability of pipeline structures. The results show that the model can obtain the calculation results highly similar to Monte Carlo simulation in a very

引用格式: 何蕾, 温凯, 吴长春, 宫敬. 基于多种智能算法的腐蚀天然气管道可靠性评价方法. 石油科学通报, 2019, 03: 310-322

HE Lei, WEN Kai, WU Changchun, GONG Jing. A corroded natural gas pipeline reliability evaluation method based on multiple intelligent algorithms. Petroleum Science Bulletin, 2019, 03: 310-322. doi: 10.3969/j.issn.2096-1693.2019.03.028

short time. Compared with the traditional neural network model, the model established by this method has greatly improved the reliability of prediction and the ability to reflect changes in reliability.

Keywords corroded gas pipelines; reliability; artificial neural network modeling method improvement; simulated annealing algorithm; Latin hypercube sampling; genetic algorithm

doi: 10.3969/j.issn.2096-1693.2019.03.028

0 前言

随着全球天然气的消费量逐年攀升^[1],未来天然气管道的总公里数将大幅增加,由此所带来的天然气管道运行安全问题也日益凸显。2010年至2016年美国^[2]天然气长输管道事故578起,管道本体事故277起,占总经济损失的86%。1970年—2013年欧洲^[3]14.3万公里管道中事故1309起,其中由于管道体积缺陷引发的事故占40%。俄罗斯^[4]天然气管道系统中腐蚀引起的管道事故占到了50%。上述统计数据表明管道腐蚀所带来的管道安全事故所占的比重较大,因此对含腐蚀缺陷的天然气管道可靠性进行评价具有重要的工程意义。

天然气管道作为连接天然气资源与消费市场的重要纽带,空间跨度大、沿线地理环境复杂,管道相关参数存在不确定性。为定量描述不确定性的影响,文献[5-8]结合管道内检测数据采用蒙特卡罗法对管道的结构可靠性随运行时间的变化规律进行计算。然而管道失效在时间和空间维度上属于小概率事件。根据PHMSA^[2]的统计美国天然气管道的平均无故障运行时间53年,全国49万公里的输气管道中平均受影响长度仅为18公里,采用传统的蒙特卡罗计算方法模拟管道失效十分耗时。为提高腐蚀管道可靠性评价效率,S. Zhang^[9]采用一次二阶矩法对管道腐蚀速率、内部压力及缺陷横向扩展速率与缺陷可靠度之间的非线性关系进行线性化处理。C. Gong^[10]在此基础上考虑透壁及塑性失稳两种失效形式,将管道系统中多个缺陷的相互影响关系考虑在内。然而该方法的精确度主要取决于线性化后的管道极限状态方程与原函数之间的偏差及相关参数等效正态化的近似程度。因此构建腐蚀缺陷可靠度与相关输出参数之间的非线性函数关系是提高可靠性评价效率及预测精度的关键。

近年来人工神经网络(Artificial Neural Network, ANN)算法被广泛应用于影响管道可靠性的相关参数非线性关系的构建中。El-Abbasy M S^[11]考虑影响管道安全的13个因素,应用神经网络算法对不同工况下

管道的运行安全展开定性评价。在定量计算方面,W. Z. Xu^[12]利用有限元分析软件产生训练样本,构建缺陷几何尺寸与管道爆裂压力之间的神经网络模型。文献[13-14]结合实验数据,采用神经网络算法分别对管道裂纹扩展速率、极限抗拉强度与相关影响变量之间的非线性关系进行建模。上述研究仅针对影响管道结构的部分参数进行神经网络建模,因而无法通过模型直接获得管道结构可靠度。天然气管道具有较高的设计可靠度,训练样本数据量不足使得管道结构参数与可靠度之间的神经网络模型难以构建。为解决这一问题E. Zio^[15-16]采用蒙特卡罗模拟(Monte Carlo Simulation, MCS)方法构造人工神经网络训练样本,并将该方法应用于核电水热力系统的功能失效分析中。应用该方法文献[17]根据样本点到失效面的距离对MCS产生的样本进行筛选,对加筋板极限强度可靠性进行评价。为提高神经网络模型预测精度,Giovanis D G^[18]采用拉丁超立方抽样方法扩展训练样本的覆盖范围。LIU^[19]采用遗传算法对神经网络的权值进行优化。文献[20-22]分别采用频谱分析法、小波分析、深度学习等方法对训练样本输入层数据进行处理。应用上述方法在一定程度上能够提高模型的预测精度。然而,模型训练过程中无法将先验知识融入到模型建模过程中,使得数据处理过程的可解释性不强。

为解决这一问题,本文提出模拟退火算法与基于蒙特卡罗模拟的神经网络算法相结合的处理方法。将多种工况下腐蚀缺陷可靠性的变化规律融入到神经网络模型的构建过程中。同时结合拉丁超立方抽样方法、遗传算法分别对传统神经网络建模过程中样本空间的覆盖性及网络结构参数进行优化。建立了适用于腐蚀缺陷可靠性评价的神经网络建模流程,并对流程中涉及的关键环节进行了详细介绍。结合管道基础运行数据、管材性能数据,应用本文提出的方法建立多输入变量与腐蚀缺陷可靠度之间的神经网络模型。在多种工况下对该模型可靠度预测结果与传统神经网络模型进行对比,进而对模型的有效性进行验证。

1 可靠性神经网络模型构建原理及整体流程

1.1 建模原理

腐蚀缺陷可靠性神经网络模型建模原理与一次二阶矩、响应面法等可靠性快速评价方法相同,主要是通过近似的方法获得腐蚀缺陷可靠性相关物理变量联合概率密度函数在极限状态空间下的近似解。可靠度与概率密度函数之间的关系式如下:

$$R = \int_{g(\bar{X}) > 0} f_{\bar{X}}(\bar{X}) D\bar{X} \quad (1)$$

式中: \bar{X} 为影响腐蚀缺陷可靠性的主要参数 $X = [X_1, X_2, \dots, X_m]^T$; $g(\bar{X})$ 为管道极限状态方程; $f_{\bar{X}}(\bar{X})$ 为 \bar{X} 的联合概率密度函数。

管道极限状态方程表征管道实际破裂压力与管道所受内压的差值,是管道结构可靠性的重要判据。文献[23]应用ASME B31G、RSTRENG、ASME B31G Modified、LPC、PCORRC和C-fer共6种不同规范标准中管道极限状态方程对腐蚀管道运行状态进行判别,指出C-fer模型计算精度最高。本文采用C-fer中推荐的体积型腐蚀缺陷失效应力极限状态方程作为腐蚀缺陷状态的判别关系式,具体表达式如下:

$$g = r_a - P \quad (2)$$

$$r_a = \begin{cases} e_1 r_c + (1 - e_1) r_0 - e_2 \sigma_y & SMYS > 241 \text{ MPa} \\ e_3 r_c + (1 - e_3) r_0 - e_4 \sigma_u & SMYS \leq 241 \text{ MPa} \end{cases} \quad (3)$$

$$r_0 = \frac{1.8 \sigma_y w}{D} \quad (4)$$

$$r_c = r_0 \left[\frac{1 - \frac{d_a}{w}}{1 - \frac{d_a}{mw}} \right] \quad (5)$$

$$m = \begin{cases} \sqrt{1 + 0.6275 \frac{l^2}{D \times w} - 0.003375 \frac{l^4}{D^2 \times w^2}} & \frac{l^2}{D \times w} \leq 50 \\ 0.032 \frac{l^2}{D \times w} + 3.3 & \frac{l^2}{D \times w} > 50 \end{cases} \quad (6)$$

其中: r_a 为管道失效时的环向应力, MPa; P 为管道的内压, MPa; g 为管道的极限状态, 当 $g < 0$ 时管道发生失效; m 为鼓胀系数; l 为缺陷长度, mm; D 为管道直径, mm; w 为管道的壁厚, mm; σ_y 为拉伸强度,

MPa; σ_u 为屈服强度, MPa; e_1 、 e_2 、 e_3 、 e_4 为模型误差; d_a 为平均腐蚀深度, mm。

由管道极限状态方程表达式可知,影响管道腐蚀缺陷可靠度的不确定性参数多达10个,不同参数的分布规律也有所不同。物理参数与腐蚀缺陷可靠度之间非线性程度较高,无法采用解析法求解方程(1)。神经网络模型旨在构建腐蚀缺陷可靠度与物理参数之间的代理模型。神经网络模型由输入层、隐含层及输出层三部分构成,每层中包含多个神经元。通过样本训练获得神经元的特性及它们的连接方式,实现物理参数与腐蚀缺陷可靠度之间的非线性映射关系(式7)。

$$R = f \left(\sum_{i=1}^n W_i X_i - \theta \right) = f(\bar{W}\bar{X} - \theta) \quad (7)$$

其中: \bar{X} 为影响管道可靠性的主要参数; \bar{W} 为神经元之间的连接权向量; θ 为阈值; $f(*)$ 为激活函数。

1.2 神经网络模型整体建模流程

输入层、输出层及训练样本是神经网络模型的关键组成部分。其中输入层为影响管道可靠度的主要物理变量,输出层为管道可靠度。针对直接构建蒙特卡罗模拟的神经网络模型存的问题: (1)以随机生成的方法产生的训练样本空间覆盖性不足; (2)神经网络拓扑结构对模型预测效果有较大影响; (3)腐蚀缺陷可靠性衰减规律无法应用到神经网络模型中。本文在样本数据的选择与构建、样本数据的处理及神经网络参数优化3个方面对神经网络模型进行了改进,具体实现流程如图1所示。

2 神经网络模型各部分构建方法

2.1 样本集构建

神经网络模型中输入层的参数数目直接影响模型的复杂程度进而影响可靠度的预测精度。为了避免模型出现过拟合和欠拟合问题,本文通过敏感性分析选取神经网络输出层物理变量。采用敏感性分析的方法中Sobol全局敏感性指数^[24]表征物理变量的不确定性对腐蚀缺陷可靠度的影响,进而确定神经网络模型的输入层变量。

$$S_i = \frac{E_{X_{-i}} (Var_{X_i} (R | X_{-i}))}{V[R]}, \quad i = 1, 2, \dots, n \quad (8)$$

其中: $V[R]$ 为管道状态方程中所有输入参数 x_j 在相应的变化范围内抽样所获得的可靠度方差;

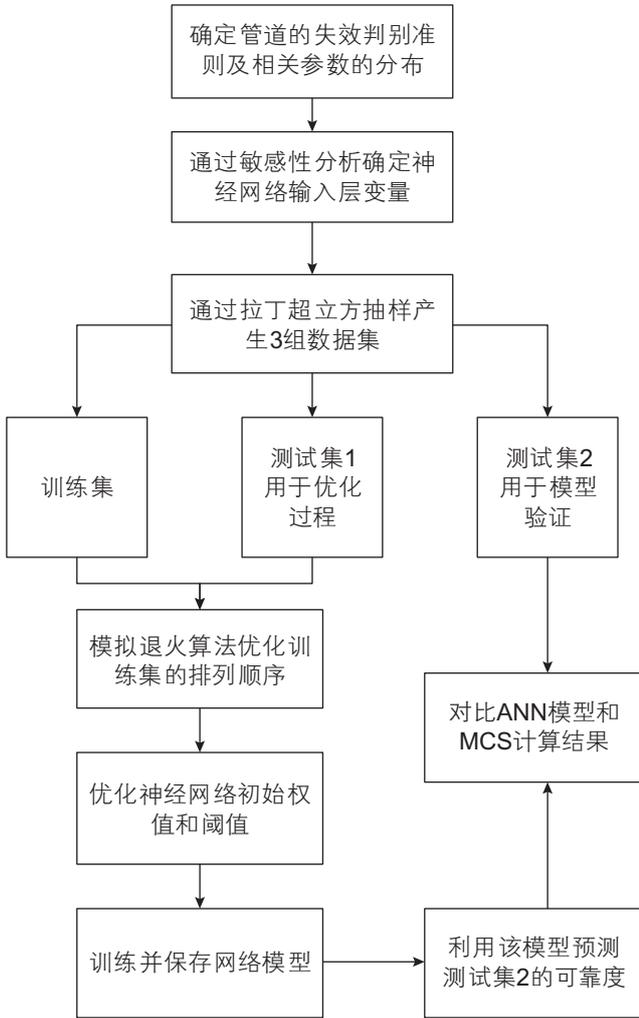


图1 腐蚀管道可靠性神经网络整体建模流程
Fig. 1 The flow chart of corrosion pipeline reliability methodology based on ANN

$E_{X_{-i}}(Var_{X_i}(R|X_{-i}))$ 由输入参数 x_j 不变, 其余输入变量在其变化范围内被抽样时获得的可靠度方差的期望; n 为敏感性分析的变量数目。

管道失效属于小概率事件采用直接蒙特卡罗模拟构建样本输出层, 抽样次数较高。为提高训练样本输出层的构建效率, 本文采用拉丁超立方抽样方法^[25]进行样本输出可靠度计算。以文献[8]中的数据为例, 模拟次数取 10^5 次, 分别采用直接蒙特卡罗和拉丁超立方抽样方法对管道运行可靠度进行 50 组计算。两种方法可靠度计算的标准差如图 2 所示。从图中可以看出在相同的抽样次数下, 拉丁超立方抽样计算结果收敛程度优于直接蒙特卡罗模拟。

2.2 样本数据处理

在神经网络训练过程中存在多种不确定性因素影

响模型预测结果, 其中训练样本的排列顺序是影响因素之一。在传统的神经网络训练过程中往往按照一定比例随机划分训练集及测试集并对训练样本进行随机排序带入模型进行训练。通过测试集决定系数(式 9)对模型有效性进行验证^[14]。图 3 对比了不同输入顺序下训练样本获得的神经网络模型对测试集样本的预测结果。第一种测试数据集输入顺序下获得的神经网络模型对测试集样本的决定系数为 0.988 31, 第二种仅为 0.174 01。

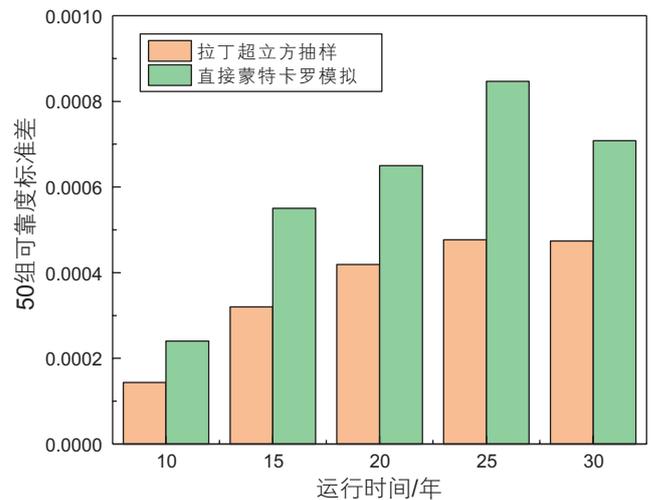


图 2 两种抽样方法可靠度标准差对比
Fig. 2 The comparison of reliability standard deviation obtained by two different sampling methods

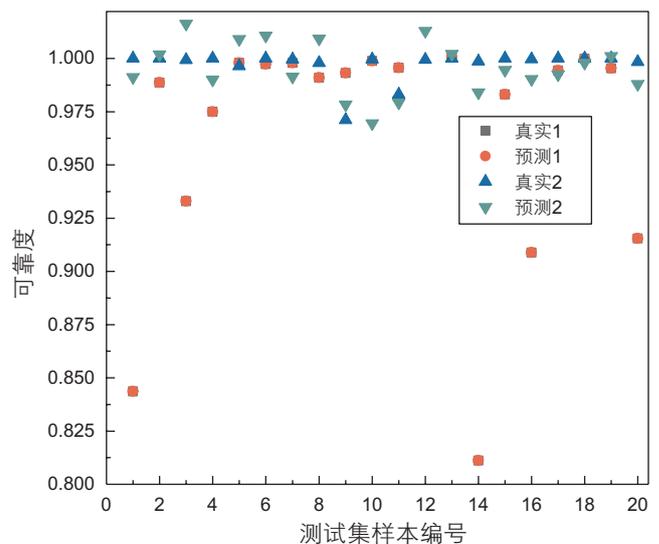


图 3 不同的训练样本排列下获得的 ANN 模型对测试集的预测结果
Fig. 3 Test sets reliability results by ANN models obtained under different training sample arrangements

$$r^2 = \frac{\left(N \sum_{i=1}^N R_i \hat{R}_i - \sum_{i=1}^N R_i \sum_{i=1}^N \hat{R}_i \right)^2}{\left(N \sum_{i=1}^N \hat{R}_i^2 - \left(\sum_{i=1}^N R_i \right)^2 \right) \left(N \sum_{i=1}^N R_i^2 - \left(\sum_{i=1}^N R_i \right)^2 \right)} \quad (9)$$

其中： r 为决定系数， N 为测试集样本数； R_i 为可靠度理想输出值； \hat{R}_i 为神经网络可靠度预测值。

然而，通过决定系数对模型的预测精度进行评价的方法仅具有统计意义，无法表征模型对可靠性变化规律的反映能力。图4对比了测试集决定系数为0.986 27、0.973 45的两种BP神经网络模型对不考虑维修影响的管道可靠度预测结果。可以看出测试集决定系数较高的模型1无法反映管道可靠度随时间的衰减规律。为解决这一问题，本文在进行神经网络建模前加入样本数据处理环节。根据多种工况下腐蚀缺陷可靠性的衰减规律构建验证集。定义不满足可靠性随时间变化规律的预测点为异常点。以验证集中神经网络模型预测的可靠度与理想输出值之间的偏差及异常点个数最小化为优化目标，对训练样本数据的排列顺序进行优化。

对于训练样本的输入顺序寻优问题本文采用模拟退火算法。模拟退火基于金属退火过程找到最优解，被广泛应用于最佳排列问题的求解过程^[26-27]。其中参数初始化、代价函数的构建以及解集更新是该优化过程的三大关键要素。本文将训练样本集合 T_1 的初始排列顺序进行编号作为初始解 S_1 。对该序列下的训练集应用神经网络算法进行训练，应用训练后的神经网络模型对测试集 T_2 的可靠度进行预测。将神经网络模

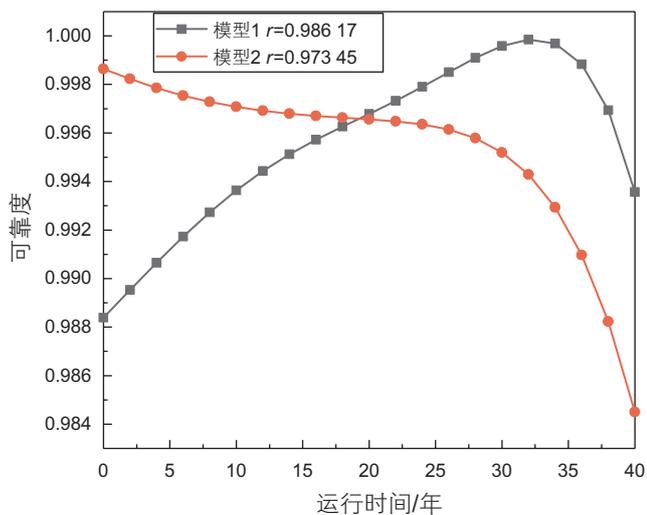


图4 不同的BP神经网络模型对管道可靠度预测结果
Fig. 4 Pipeline reliability assessment results based on different BP neural network models

型预测结果与蒙特卡罗模拟结果的误差平方和作为代价函数。通过调整 T_1 中任意两变量的位置获得新的解 S_2 ，利用 S_2 序列训练获得新的神经网络模型及代价函数计算结果。将新的样本排序集合与原样本排序集合计算的两组代价函数数值进行插值得到 df 。为避免算法陷入局部最优解，本文应用Metropolis准则以 $\exp\left(-\frac{df}{T}\right)$ 的概率确定新解 S_2 是否取代 S_1 ，并更新迭代次数及当前温度数值，当达到终止温度或多次迭代无新解产生算法终止，输出训练样本最优排列顺序 S_1 。优化过程的流程图如图5所示。

为加速优化过程，应用极限学习机作为优化过程

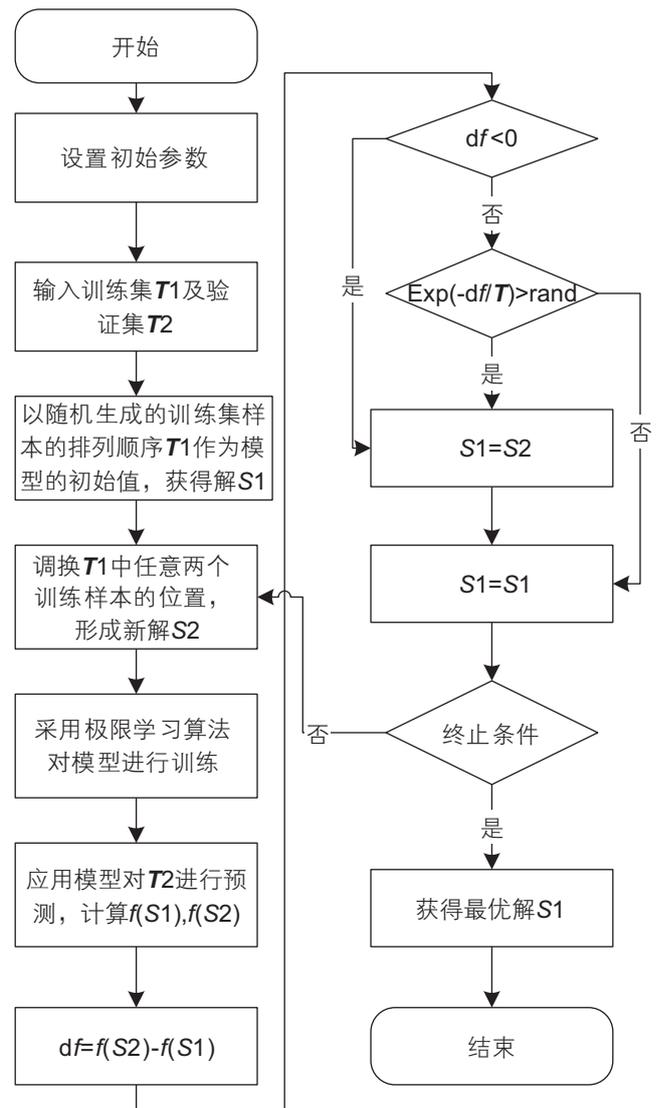


图5 基于模拟退火算法与极限学习机算法的训练集样本顺序优化
Fig. 5 Training samples sequence optimization based on Simulated Annealing algorithm and Extreme Learning Machine algorithm training samples

神经网络训练算法。该算法不同于BP这种前馈型神经网络，极限学习机输入节点与隐含层之间的连接权值随机产生，且在训练过程中不再进行调整，隐含层与输入层之间的连接权值由式(10)~(13)计算获得。文献[28]表明极限学习机算法能够在较短时间内快速训练并产生与BP相近似的训练效果。因此本文在训练过程中采用该方法作为优化过程的神经网络算法。

$$\beta = H^+ T' \tag{10}$$

$$T = [t_1, \dots, t_Q]_{m \times Q} \tag{11}$$

$$t_j = \begin{bmatrix} t_{1j} \\ \dots \\ t_{mj} \end{bmatrix}_{m \times 1} = \begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(w_i x_j + b_i) \\ \dots \\ \sum_{i=1}^l \beta_{im} g(w_i x_j + b_i) \end{bmatrix}_{m \times 1} \quad (j=1, \dots, Q) \tag{12}$$

$$H(w_1 \dots w_l, b_1 \dots b_l, x_1 \dots x_l) = \begin{bmatrix} g(w_1 x_1 + b_1) \dots g(w_l x_1 + b_l) \\ \dots \\ g(w_1 x_Q + b_1) \dots g(w_l x_Q + b_l) \end{bmatrix} \tag{13}$$

其中： β 为隐含层与输出层之间的连接权值； m 和 l 分别为输出节点和隐含层节点数目； Q 是训练样本数目； $g(\cdot)$ 为激活函数； w_i 为第 i 个隐含层与第 i 个输入层样本 x_i 之间的连接权值； b_i 为第 i 个隐含层的偏差。

2.3 模型训练及优化

为建立多输入变量与腐蚀缺陷可靠度之间的非线性模型，应选用有监督学习功能的网络进行训练。文献[29]对比了不同类型神经网络模型的预测准确度，指出BP神经网络的预测效果最佳，因此本文采用BP神经网络作为模型的主要训练方法。训练样本按照模拟退火算法优化顺序带入神经网络模型进行训练。在每次训练过程中变量由输入层经隐含层传向输出层，每层神经元的状态都对应着一个作用函数和阈值。设定可靠度的预测结果与蒙特卡罗模拟获得的可靠度理想输出值之间的可接受误差，当在输出层得到的计算结果高于设定误差，则转入反向传播将误差信号沿原来通路返回。通过修改各层神经元的权值，使输出层的误差达到设定要求。

在神经网络训练过程中，初始权值和阈值以随机生成的方式产生，存在一定的不确定性。本文采用遗传算法对神经网络模型的初始权值和阈值进行优选。首先通过对神经网络进行拓扑结构分析构建染色体矩

阵，具体表达式如下。

$$S = (n \times Q + Q \times m + Q + m) \times 6 \tag{13}$$

式中： S 为染色体矩阵列数， n 、 m 分别为神经网络输入层、输出层神经元个数； Q 为隐含层神经元个数。

对染色体矩阵中的每一个元素进行转译处理，将处理后的神经元分组到神经网络模型中。输入样本训练模型，将测试集样本带入训练后的模型进行可靠度预测。以可靠度预测结果与蒙特卡罗模拟结果的误差平方和为适应度函数(式(14)~(15))。根据种群的适应度计算结果，采用竞争选择机制确定下一代获得遗传的双亲。通过交叉、变异操作产生新的个体。反复应用突变、交叉、反演和选择算子，获得神经网络的最佳权重和阈值。

$$e(i) = \frac{\sum_{p=1}^q (d_p - d_r)^2}{q} \tag{14}$$

$$F = \left[\exp(-e) \times \exp(-Q) + \frac{1}{(e \times Q)} \right] \tag{15}$$

其中： d_p 和 d_r 分别为测试集中每个个体 i 的可靠性预测值与理想输出值； $e(i)$ 为测试集样本中每一个个体 i 的误差平方和； Q 为隐含层神经元个数； F 为适应度函数。

在神经网络模型有效性验证方面，采用异于2.2中的验证集数据，从多种工况的模型预测结果，对可靠性变化规律的反映能力及与理想输出值之间的误差两个角度对模型进行评价。

3 算例

3.1 神经网络模型构建

本文以某含腐蚀缺陷的X80管段为例，采用本文提出的方法进行可靠性评价。该管道设计压力12 MPa，管道外径1219 mm，壁厚18.4 mm，相关参数及分布类型如表1所示。在不同的拉丁超立方抽样次数下，对管道运行30年后的可靠度进行100次计算。采用箱型图对不同抽样次数下可靠度计算结果及平均运算时间的进行对比如图6所示。计算结果表明，抽样次数达到 10^6 次后腐蚀缺陷的可靠度计算结果趋于稳定，随着抽样次数的提高模拟时间大幅上升。综合考虑计算结果的稳定性和计算效率，本算例中蒙特卡罗模拟次数取 10^6 次。

参考文献[33]中管道敏感性分析结果及管段运行特点，选取管段初始缺陷深度(1.54~3.95 mm)、腐

蚀深度增长速率(0.05~0.2 mm/a)、腐蚀长度增长速率(3~6 mm/a)、初始缺陷长度(35~50 mm)、运行压力(8~12 MPa)、屈服强度(558~690 MPa)、抗拉强度

(703~728 MPa)8个物理变量,采用Sobol全局敏感指数进行敏感性分析,计算结果如表2所示。根据Sobol全局敏感指数计算结果可知初始缺陷深度、腐蚀深度

表1 管道相关参数分布规律

Table 1 The distribution model of pipeline parameters

物理参数	均值	变异系数	分布类型	参考文献
管道内压 P/MPa	0.993 $P_{\text{设计}}$	0.034	β 分布	[30]
管道屈服强度 σ_u/MPa	600	0.0417	正态分布	[6]
管道抗拉强度 σ_y/MPa	703	0.0412	正态分布	[6]
初始缺陷深度 d_0/mm	3.68	0.092	正态分布	[31]
初始缺陷长度 l_0/mm	50	0.5	正态分布	[13]
缺陷深度增长速率 $v_d/(\text{mm/a})$	0.1	0.5	威布尔分布	[32]
缺陷长度增长速率 $v_l/(\text{mm/a})$	3	0.15	对数正态	[13]
最大腐蚀深度与平均腐蚀深度比	2.08	0.5	对数正态	[31]
e_1	1.04	-	定值	[31]
e_2	-0.000 56	0.001 469	正态分布	[31]
e_3	1.17	-	定值	[31]
e_4	-0.007 655	0.006 506	正态分布	[31]

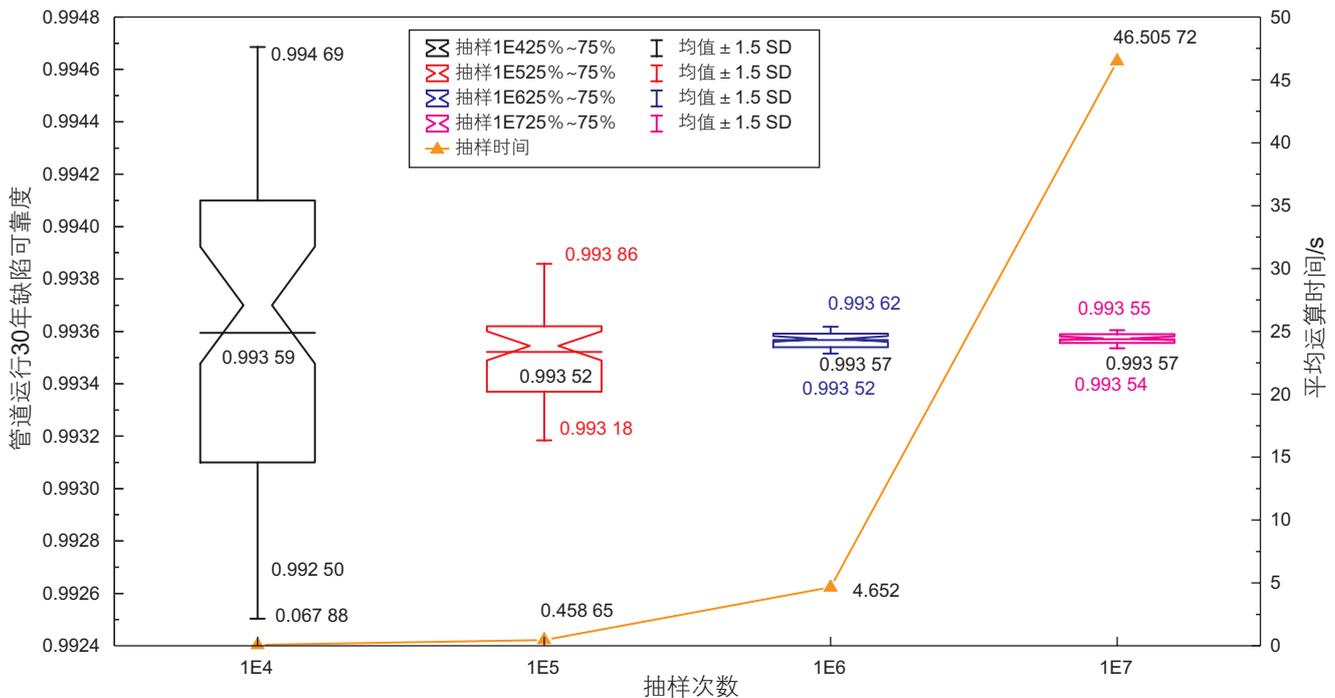


图6 拉丁超立方抽样结果稳定性及计算效率分析

Fig. 6 The stability and efficiency analysis of Latin Hypercube sampling method

表2 管道相关参数Sobol全局敏感性指数

Table 2 The Sobol global sensitivity index of pipeline related parameters

物理变量	初始缺陷深度	腐蚀速率	裂纹长度扩展速率	初始缺陷长度	运行压力	屈服强度	抗拉强度	运行时间
Sobol指数	0.163	0.579	0.008	8.64E-05	0.194	9.14E-06	0.001	0.639

增长速率、运行压力及运行时间 4 个变量的 Sobol 指数总和占有所有变量的 99.4%，因此针对该管道选取上述 4 个变量作为神经网络模型的输入层。

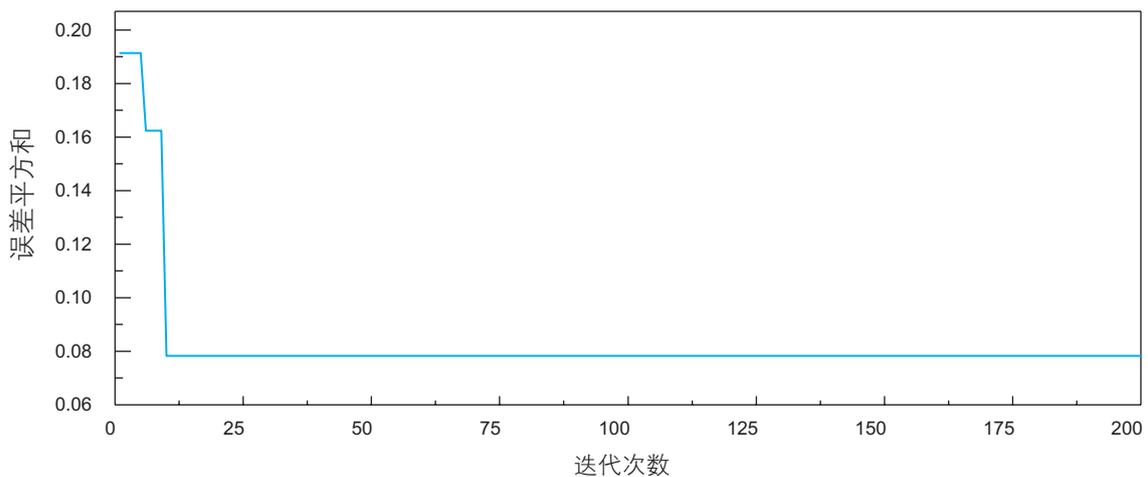
根据表 1 中相关参数的分布特点，采用拉丁超立方抽样构建神经网络训练集和两组验证集。采用模拟退火算法对训练数据集进行重新排列。根据训练数据的排列顺序，取后 10 组作为测试集，采用遗传算法对 BP 神经网络的初始参数进行优化，优化过程如图 7 所示。

分别采用本文提出的方法构建的神经网络模型及传统方法构建的 BP 神经网络模型对第 2 组测试集中的数据进行可靠度计算。分别将两种模型预测结果与蒙特卡罗模拟结果进行对比(图 8、表 3)。相比于传统方法构建的神经网络模型，采用本文提出的处理流程获得的神经网络模型对 $5 \times 5 \times 5 \times 21$ 种工况下可靠度

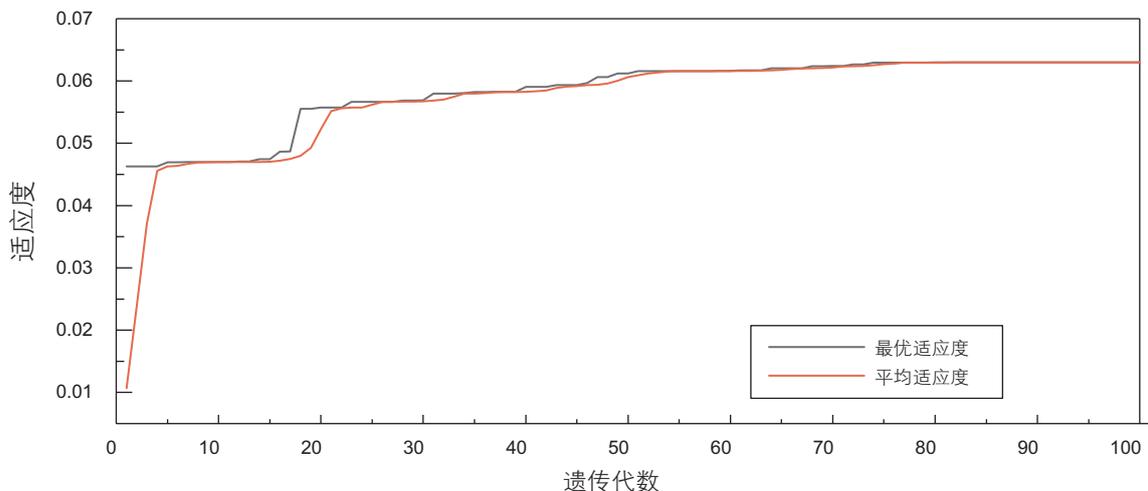
预测结果与蒙特卡罗模拟结果的误差平方和从之前的 0.0023 降低到 0.000 17。采用本文提出的方法构建的模型对测试集可靠度预测结果无异常点产生，而传统的方法构建的 BP 神经网络模型异常点多达 55 个。在计算速度方面，神经网络模型对 2625 种工况下可靠度的预测时间仅为 39.19s，而对相同工况点采用拉丁超立方抽样方法进行 10^6 次蒙特卡罗模拟所需时间长达 29 076.026s。

3.2 神经网络模型应用

应用本文构建的神经网络模型结合水热力计算对一段 260 km，设计压力为 12 MPa，管径 $\Phi 1219 \times 18.4$ mm 的管段沿线腐蚀缺陷点的可靠度随管道运行时间的变化情况进行预测。该管道沿线各腐蚀缺陷参数如图 9 所示。



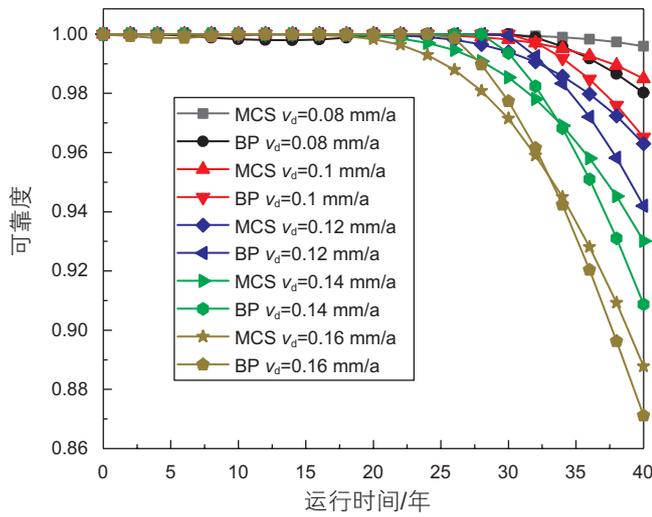
(a) 模拟退火算法样本排序优化过程



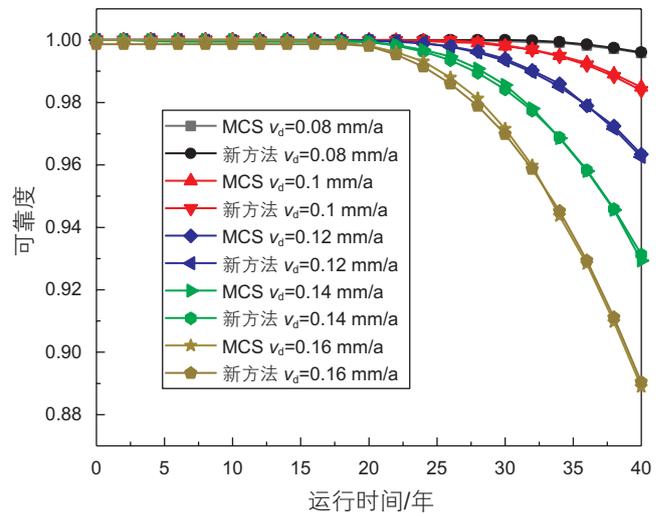
(b) 遗传算法权值和阈值优化过程

图 7 优化迭代过程

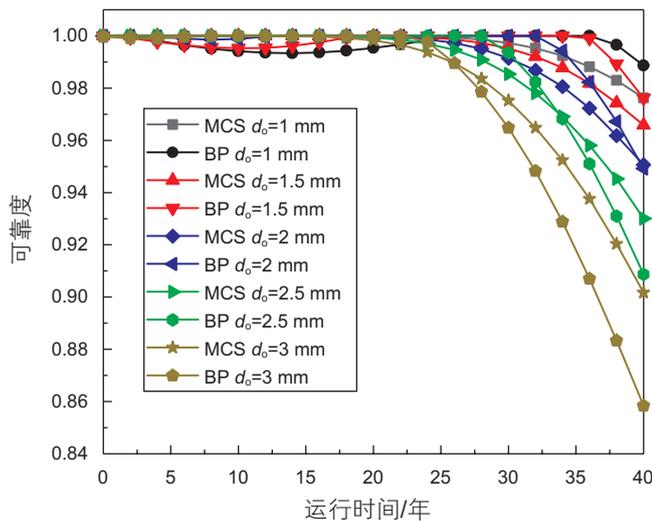
Fig. 7 The process of optimized iterative



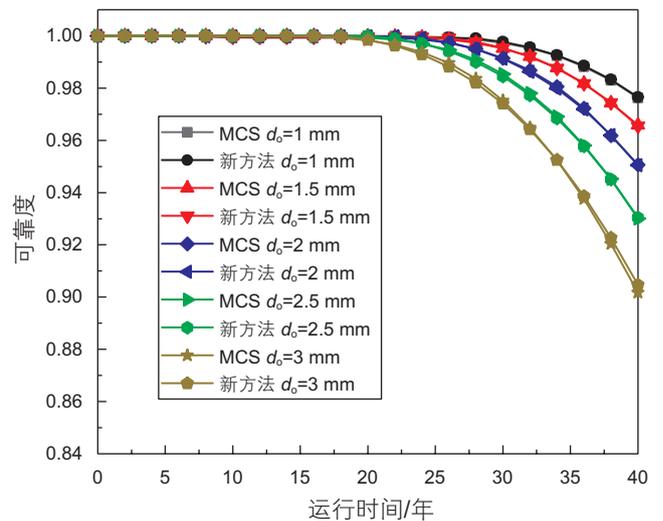
(a) 不同腐蚀速率管道可靠性预测对比



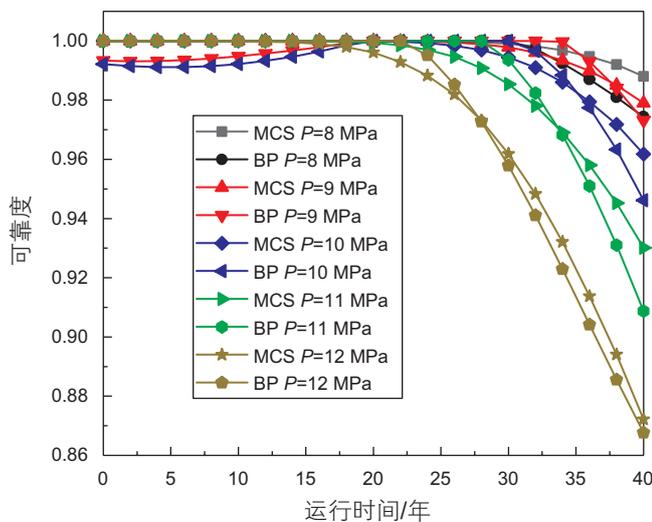
(b) 不同腐蚀速率管道可靠性预测对比(新方法)



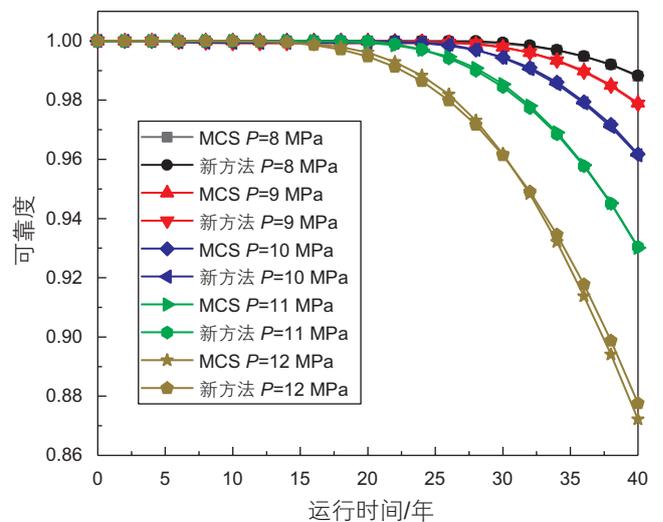
(c) 不同初始缺陷深度可靠性预测对比



(d) 不同初始缺陷深度可靠性预测对比(新方法)



(e) 不同运行压力可靠性预测对比



(f) 不同运行压力可靠性预测对比(新方法)

图 8 两种方法获得的神经网络模型可靠性预测结果对比

Fig. 8 The comparison of reliability assessment results obtained by ANN models established by two different methods

表 3 多种工况下两种模型预测结果对比

Table 3 The comparison of reliability assessment results of two models under various operation conditions

变量名称	数值				
平均腐蚀速率/(mm/a)	0.8	1	1.2	1.4	1.6
传统BP模型预测误差平方和	3.117×10^{-5}	9.525×10^{-6}	2.143×10^{-5}	6.546×10^{-5}	7.075×10^{-5}
传统BP模型预测异常点数目	3	4	2	2	1
本文模型预测误差平方和	3.802×10^{-6}	5.826×10^{-6}	3.928×10^{-6}	3.684×10^{-6}	1.883×10^{-5}
初始缺陷深度/mm	1	1.5	2	2.5	3
传统BP模型预测误差平方和	1.637×10^{-4}	1.803×10^{-4}	1.423×10^{-4}	6.546×10^{-5}	6.773×10^{-5}
传统BP模型预测异常点数目	6	9	5	2	0
本文模型预测误差平方和	3.956×10^{-6}	2.184×10^{-6}	1.967×10^{-6}	3.684×10^{-6}	2.305×10^{-5}
运行压力/MPa	8	9	10	11	12
传统BP模型预测误差平方和	5×10^{-4}	2.118×10^{-5}	8.707×10^{-6}	6.546×10^{-5}	8.618×10^{-4}
传统BP模型预测异常点数目	12	3	1	2	3
本文模型预测误差平方和	4.465×10^{-7}	5.346×10^{-6}	4.641×10^{-6}	3.684×10^{-6}	8.976×10^{-5}

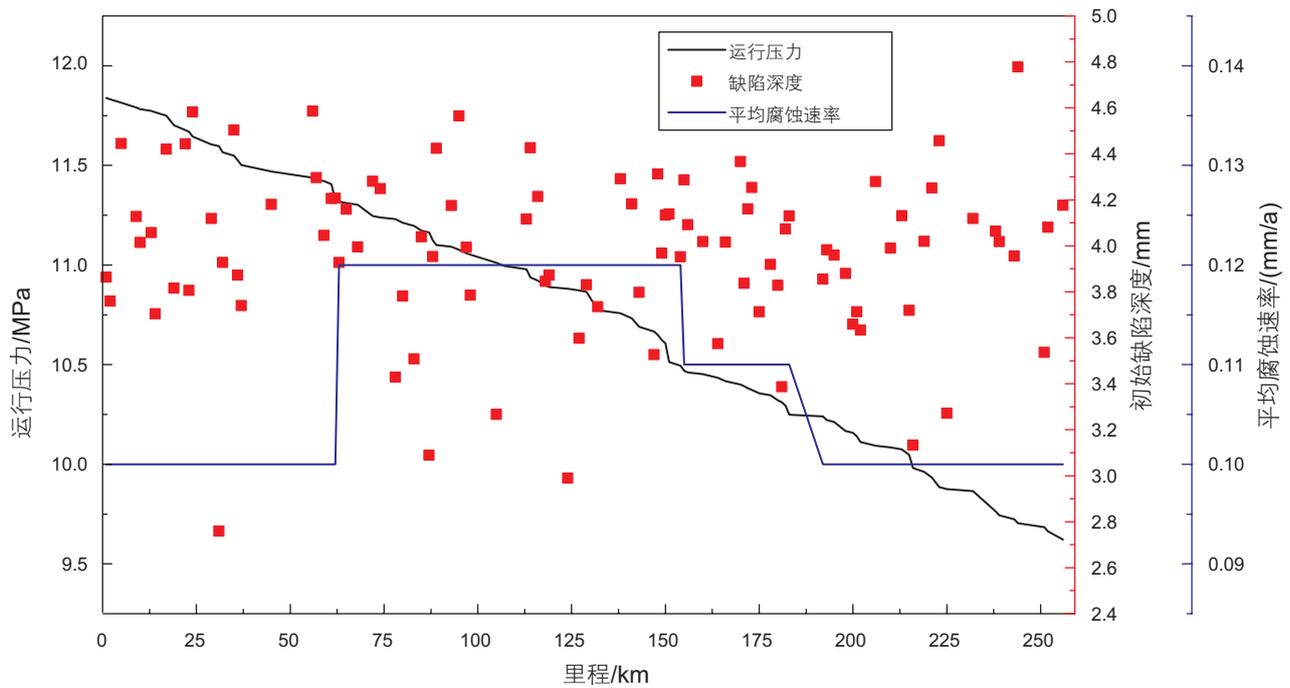


图 9 管道沿线缺陷点及相关参数

Fig. 9 Defect points along the pipeline and related parameters

图 10 为神经网络模型计算的管道各缺陷位置 30 年内可靠度的变化趋势。神经网络模型对于整条管段可靠度的评价时间仅为 33.69 s，大幅地提高了管段结构可靠度的评价效率。图 11 为该管段薄弱点的结构可靠度随管道运行年限的变化趋势。评价结果表明该管道腐蚀缺陷薄弱环节出现在 107km 处的高腐蚀地区。

4 总结

本文通过对国外天然气管道事故数据库的调研分

析，认为腐蚀缺陷是影响管道运行安全的关键因素。考虑到天然气管道具有里程数大、缺陷数目多、失效率低的特点，逐点进行蒙特卡罗模拟确定对应的可靠度存在计算时间长、效率低的问题。本文利用蒙特卡罗模拟与神经网络模型相结合的方法构建管道物理变量与可靠度之间的非线性关系。针对目前神经网络模型仅具有统计意义的问题，本文采用模拟退火算法与神经网络算法相结合的处理方法，将腐蚀管道可靠度变化规律融入到神经网络建模过程中。并建立了从样本输入变量的选择、数据生成、数据处理、神经网络模型构建到模型预测结果评价一体化建模方法。在样

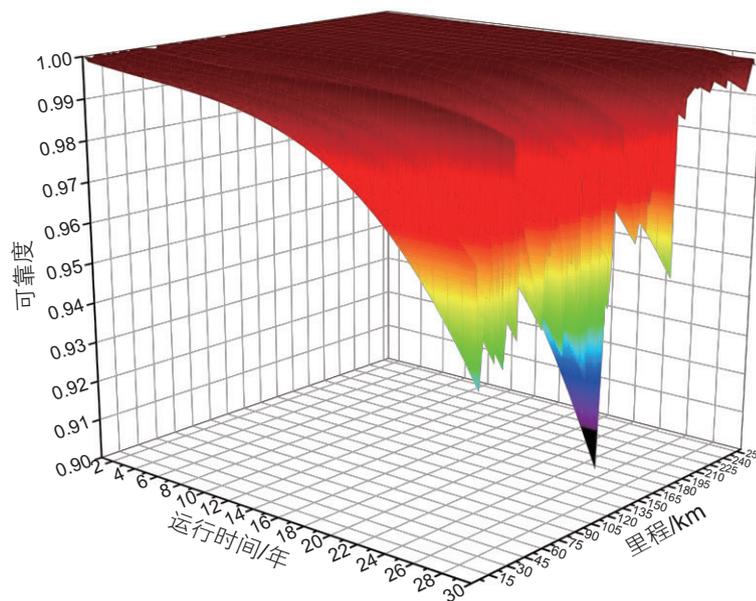


图 10 管道沿线各缺陷点可靠性随运行时间变化

Fig. 10 The variation of each defect point reliability with operation time

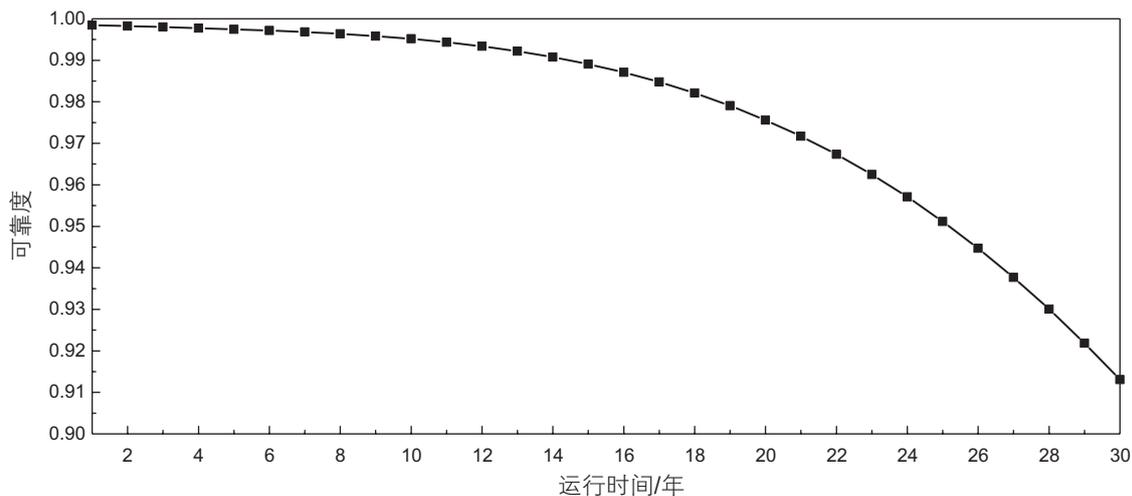


图 11 管道薄弱环节可靠性随运行时间变化

Fig. 11 The variation of pipeline vulnerable point reliability with operation time

本输入样本的选择方面,通过Sobol全局敏感性指数对影响管道结构可靠度的8个变量进行敏感性分析,结果表明对于规格及管材确定的管道,运行时间、内部压力、腐蚀速率及初始缺陷深度是影响管道结构可靠性的关键因素。在样本数据的生成方面,选用拉丁超立方抽样方法取代传统的蒙特卡罗模拟,提高了样本生成的覆盖范围。在样本数据处理方面,应用模拟退火算法与极限学习机算法构建与管道可靠性变化规律相关的代价函数。减小了样本排列顺序的不确定性

对模型预测精度的影响,提高了模型的可解释性。在神经网络模型的构建方面,通过遗传算法的应用有效地减少了神经网络训练过程中神经网络模型初始权值和阈值随机性对模型预测精度的影响。通过验证集及异常点的引入增强了模型结果验证的合理性。

应用本文提出的神经网络模型对2526种工况下管道可靠度进行预测,预测结果表明本文提出的方法能够在较短的时间内获得与蒙特卡罗模拟近似程度较高的结果。利用该方法建立的模型相比于传统的神经网

络模型,在可靠度变化规律的反映能力及预测准确性方面具有明显优势。应用该模型对一段实际管道结构可靠性进行评价,评价结果表明该方法能够结合管道的工艺运行参数、缺陷几何尺寸及管道所在地区地质特征,对管道中各腐蚀缺陷可靠度随运行时间的变化过程进行快速预测,寻找到管道中的薄弱点。预测结果能够为管道腐蚀防护、维检修计划的制定、结构失效的高发地带的初步确定等提供理论指导。

参考文献

- [1] CONTI J H P, DIEFENDERFER J, LAROSE A, et al. International Energy Outlook 2016[R]. United States: Energy Information Administration, 2016: 37–40.
- [2] ELAINE L. C. Incident report criteria history[R]. Washington, DC: Pipeline and Hazardous Materials Safety Administration, 2016: 19–23.
- [3] DRÖGE M T, KENTER R. Gas pipeline incidents[R]. Ireland: European Gas Pipeline Incident Data Group, 2016: 23.
- [4] 赵永涛. 俄罗斯油气管道运营状况及事故统计分析[J]. 化工安全与环境, 2005(27): 10–12. [ZHAO Y T. Analysis on operation status and accident statistics of oil and gas pipeline in Russia[J]. Chemical Safety and Environment, 2005(27): 10–12.]
- [5] TARAEVSKYY O. Reliability process of long-term operated gas pipelines in difficult mining and geological conditions[J]. Metallurgical & Mining Industry, 2016.
- [6] WEN K, GONG J, ZHAO B, et al. The reliability-based assessment of an in-service X80 natural gas pipeline in China[C]. 2014 10th International Pipeline Conference. American Society of Mechanical Engineers, 2014: V004T13A007.
- [7] 罗更生, 周煜. 含裂纹油气管道可靠性评定方法及敏感性分析[J]. 石油学报, 2011, 32(6): 1083–1087. [LUO G S, ZHOU Y. A reliability assessment method of crack-containing oil-gas pipelines and its sensitivity analysis[J]. Acta Petrolei Sinica, 2011, 32(6): 1083–1087.]
- [8] 帅义, 帅健, 刘朝阳. 腐蚀管道可靠性评价方法研究[J]. 石油科学通报, 2017, 02: 288–297. [SHUAI Y, SHUAI J, LIU C Y. Research on the reliability methods of corroded pipeline[J]. Petroleum Science Bulletin, 2017, 02: 288–297.]
- [9] ZHANG S, ZHOU W X. An efficient methodology for the reliability analysis of corroding pipelines[C]. International Pipeline Conference. 2012: 683–692.
- [10] GONG C, ZHOU W. First-order reliability method-based system reliability analyses of corroding pipelines considering multiple defects and failure modes[J]. Structure & Infrastructure Engineering, 2017: 1–11.
- [11] EL-ABBASY M S, SENOUCI A, ZAYED T, et al. Artificial neural network models for predicting condition of offshore oil and gas pipelines[J]. Automation in Construction, 2014, 45: 50–65.
- [12] XU W Z, LI C B, CHOUNG J, et al. Corroded pipeline failure analysis using artificial neural network scheme[J]. Advances in Engineering Software, 2017, 112: 255–266.
- [13] SHI J, WANG J, MACDONALD D D. Prediction of primary water stress corrosion crack growth rates in Alloy 600 using artificial neural networks[J]. Corrosion Science, 2015, 92: 217–227.
- [14] KHALAJ G, AZIMZADEGAN T, MAHDI K. Artificial neural networks application to predict the ultimate tensile strength of X70 pipeline steels[J]. Neural Computing and Applications, 2013, 23(7–8): 2301–2308.
- [15] ZIO E, APOSTOLAKIS G E, PEDRONI N. Quantitative functional failure analysis of a thermal–hydraulic passive system by means of bootstrapped Artificial Neural Networks[J]. Annals of Nuclear Energy, 2010, 37(5): 639–649.
- [16] PEDRONI N, ZIO E, APOSTOLAKIS G E. Comparison of bootstrapped artificial neural networks and quadratic response surfaces for the estimation of the functional failure probability of a thermal–hydraulic passive system[J]. Reliability Engineering & System Safety, 2012, 95(4): 386–395.
- [17] 陈松坤, 王德禹. 基于神经网络的蒙特卡罗可靠性分析方法[J]. 上海交通大学学报(自然版), 2018, 52(6): 687–692. [CHEN S K, WANG D Y. An improved Monte Carlo reliability analysis method based on Neural Network[J]. Shanghai Jiaotong Univ. (Sci.), 2018, 52(6): 687–692.]
- [18] GIOVANIS D G, PAPAPOULOS V. Spectral representation-based neural network assisted stochastic structural mechanics[J]. Engineering Structures, 2015, 84: 382–394.
- [19] LIU L, ZHAO Y, CHANG D, et al. Prediction of short-term PV power output and uncertainty analysis[J]. Applied Energy, 2018, 228: 700–711.
- [20] XIA B, CUI D, SUN Z, et al. State of charge estimation of lithium-ion batteries using optimized Levenberg-Marquardt wavelet neural network[J]. Energy, 2018, 153: 694–705.
- [21] HUSSAIN S, ALALILI A. A hybrid solar radiation modeling approach using wavelet multiresolution analysis and artificial neural

- networks[J]. *Applied Energy*, 2017: S030626191731379X.
- [22] AOWABIN R, AMANDA D S. Predicting heating demand and sizing a stratified thermal storage tank using deep learning algorithms[J]. *Applied Energy*, 2018, 228: 108–121.
- [23] 张振永, 张金源, 李朝, 等. 油气管道腐蚀缺陷评估方法研究综述[J]. *腐蚀与防护*, 2015, 36(1): 43–48. [ZHANG Z Y, ZHANG J Y, LI C, et al. Review on Methods of Assessment of Corrosion defects of Oil and Gas Pipeline[J]. *CORROSION & PROTECTION*, 2015, 36(1): 43–48.]
- [24] LI C Q, MAHMOODIAN M. Risk based service life prediction of underground cast iron pipes subjected to corrosion[J]. *Reliability Engineering & System Safety*, 2013, 119(119): 102–108.
- [25] SHU Z, JIRUTITIJAROEN P. Latin hypercube sampling techniques for power systems reliability analysis with renewable energy sources[J]. *IEEE Transactions on Power Systems*, 2011, 26(4): 2066–2073.
- [26] ROSHANI A, GIGLIO D. Simulated annealing algorithms for the multi-manned assembly line balancing problem: minimising cycle time[J]. *International Journal of Production Research*, 2016, 55(10): 2731–2751.
- [27] LYDEN S, HAQUE M E. A simulated annealing global maximum power point tracking approach for PV modules under partial shading conditions[J]. *IEEE Transactions on Power Electronics*, 2016, 31(6): 4171–4181.
- [28] NAJI S, KEIVANI A, SHAMSHIRBAND S, et al. Estimating building energy consumption using extreme learning machine method[J]. *Energy*, 2016, 97: 506–516.
- [29] MOHANA R S, THANGARAJ P. Machine learning approaches in improving service level agreement-based admission control for a software-as-a-service provider in cloud[J]. *Journal of Computer Science*, 2013, 9(10): 1283–1294.
- [30] ZHANG G, LUO J, ZHAO X, et al. Research on probabilistic assessment method based on the corroded pipeline assessment criteria[J]. *International Journal of Pressure Vessels & Piping*, 2012, 95(95): 1–6.
- [31] Canadian Standards Association Group, Oil and Gas Pipeline Systems: CSA Z662.15 [S]. Canada: Canadian Standards Association Group, 2015.
- [32] Miran S A . Reliability-based management of buried pipelines considering external corrosion defects[J]. 2016.
- [33] VOLKOVA E, IOOSS B, DORPE F V. Global sensitivity analysis for a numerical model of radionuclide migration from the RRC “Kurchatov Institute” radwaste disposal site[J]. *Stochastic Environmental Research & Risk Assessment*, 2008, 22(1): 17–31.

(编辑 马桂霞)