

# 基于粗糙集和 BP 神经网络的石化管道外腐蚀程度预测应用

王金秋<sup>1</sup>, 李为相<sup>1</sup>, 朱承飞<sup>2</sup>

(1. 南京工业大学 自动化与电气工程学院, 南京 210009; 2. 南京工业大学 材料与工程学院, 南京 210009)

**摘要:** 研究管道外腐蚀程度预测问题; 传统预测方法有专家评分系统等, 而造成管道腐蚀的原因众多, 专家对各个因素的偏好不一样, 因此这类方法个人主观因素较强, 预测的结果不够客观、准确; 为了克服个人主观影响, 提高预测精度, 提出粗糙集-BP 神经网络预测模型; 该预测模型首先利用粗糙集理论消除管道腐蚀影响因素中的冗余因素, 然后利用 BP 神经网络依据处理后的数据进行学习建模, 并测试; 仿真结果表明了该模型简洁性、快速性和有效性。

**关键词:** 粗糙集; BP 神经网络; 管道腐蚀; 预测

## Application on Petrochemical Pipeline Outside Corrosion Prediction Based on RS and BPNN

Wang Jinqiu<sup>1</sup>, Li Weixiang<sup>1</sup>, Zhu Chengfei<sup>2</sup>

(1. School of Automation and Electrical Engineering, Nanjing Polytechnic University, Nanjing 210009, China;

2. School of Materials and Engineering, Npu, Nanjing 210009, China)

**Abstract:** This article studies the outer pipe corrosion prediction. Traditional forecasting methods is an expert rating system. The pipeline corrosion caused by many reasons, Experts on various factors preferences are not the same, so a strong subjective factors of such methods, the predicted results were not objective and accurate. In order to overcome the subjective influence to improve forecasting accuracy, we put forward the Petrochemical Pipeline Outside Corrosion model based on rough set theory combined with BP neural network. The prediction model using rough set theory to eliminate redundancy factors from pipe corrosion factors first, and then use processed data modeling and testing based on BP neural network. Simulation results show that the model is simple, fast and effective.

**Keywords:** rough set; BP neural network; pipeline corrosion; prediction

## 0 引言

管道运输是现代一种较为重要的运输方式, 它在我国经济高速发展的基础上得到了广泛地应用, 在经济、国防和工业领域起到了中流砥柱的作用。使用管道运输的独特优势体现在对流体物料输送的较高的安全性上, 同时它还有成本低、效率高、输送量大、消耗小等特点。但是, 近两年随着管道使用时间的增长, 由于管道泄漏造成的事故频频发生。而管道腐蚀是很多事故的根源。2013 年 11 月 22 日的青岛原油泄漏爆炸事件的三大直接原因之一就是由于管道腐蚀造成原油泄漏, 造成的直接经济损失过亿。这起事故再次敲响了管道腐蚀的警钟。

本文利用粗糙集理论与 BP 神经网络相结合, 对管道腐蚀程度进行预测, 从而提高管道腐蚀预测的准确度。首先利用粗糙集理论对管道腐蚀的影响因素进行属性约简, 剔除冗余属性, 然后将处理后的数据输入 BP 神经网络中进行学习, 最后

获得管道腐蚀程度的预测结果。仿真结果表明了该模型的有效性。

## 1 粗糙集-BP 神经网络的管道腐蚀程度预测模型

### 1.1 粗糙集理论

#### 1.1.1 粗糙集基本概念

Z. Pawlak 提出的粗糙集理论是一种具有实用价值的数学工具, 用于处理不确定知识的数学工具, 其能够很好消除变量间的冗余信息, 简化数据输入维数, 从中发现隐含知识和潜在规律。同时, 粗糙集理论最大的优点是对数据集合的分析和处理不需要附加任何外界信息和先验知识, 所有的分析和处理工作都是完全基于数据对象本身独立完成的。因此, 消除了主观人为因素的影响。

定义 1<sup>[1]</sup> 信息系统: 信息系统是一个有序四元组  $S = [U, A, V, f]$ , 其中  $U = \{x_1, x_2, \dots\}$  是非空有限个处理对象的集合, 称为全域。全域的元素被称为对象。  $A = C \cup D$  是全部有限个属性的集合,  $C$  是条件属性集合,  $D$  是决策属性集合, 且  $C \cap D = \emptyset$ 。设  $\alpha$  是任一属性,  $X_i$  是任一对象,  $f(X_i, \alpha)$  则表示  $X_i$  在  $\alpha$  属性的取值。

定义 2 不可分辨关系: 设  $S = [U, A, V, f]$  是信息系统, 在任意属性子集  $B \subseteq A$  上, 可定义等价关系:  $R(B) = \{(x_i, x_j) \in U^2 \mid \forall a \in B, f(x_i, a) = f(x_j, a)\}$  称为不可分辨关系。

收稿日期: 2014-06-09; 修回日期: 2014-07-14;

作者简介: 王金秋(1990-), 女, 江苏省东台市人, 硕士研究生, 主要从事智慧应急决策方向的研究。

通讯作者: 李为相(1973-), 男, 河南光山人, 博士, 副教授, 主要从事过程工业企业管理-控制一体化及应急系统、实时数据管理与挖掘、智能信息处理与智能系统、复杂不确定系统管理与优化决策等方面的研究。

定义 3 知识的约简: 已知知识库  $K = \{U, S\}$  以及其上一簇等价关系  $P \subseteq S, \forall R \subseteq P$ , 如果  $R$  满足: (1)  $R$  是独立的; (2)  $IND(R) = IND(P)$ , 我们则称  $R$  是  $P$  的一个知识约简, 记为  $R \in RED(P)$ 。

定义 4 知识的核: 给定知识库  $K = \{U, S\}$  和知识库中的一个等价关系族  $P \subseteq S, \forall R \subseteq P$ , 如果满足  $IND(P - \{R\}) \neq IND(P)$ , 我们则称  $R$  为  $P$  中必要的。如果对每个  $R \in P$ ,  $R$  都为  $P$  中必要的, 则称  $P$  为独立的, 否则称  $P$  是依赖的或不独立的。与此同时, 我们称  $P$  中所有必要的知识组成的集合称为  $P$  的核, 记为  $CORE(P)$ 。

定义 5 决策表:  $S = (U, A)$  为一知识表达系统, 且  $C, D \subset A$  是 2 个属性子集,  $A = C \cup D, C \cap D = \Phi$ ,  $C$  称为条件属性集,  $D$  称为决策属性集。具有条件属性和决策属性的知识表达系统称为决策表。记作  $T = (U, A, C, D)$ , 或简称为  $CD$  决策表。关系  $ind(C)$  和关系  $ind(D)$  的等价类分别称为条件类和决策类。

定义 6 区分矩阵: 对于决策表  $T = (U, A, C, D)$ ,  $U = \{\mu_1, \mu_2, \dots, \mu_n\}$  是论域,  $A = C \cup D, C \cap D = \phi$ ,  $C$  为条件属性集,  $D$  为决策属性集, 决策表  $T$  的区分矩阵<sup>[4]</sup>  $M_{(T)}$  是一个  $n \times n$  矩阵, 其任一元素为:

$$C_{ij} = \begin{cases} \alpha | \alpha \in C \wedge f(\alpha, \mu_i) \neq f(\alpha, \mu_j), (\mu_i, \mu_j) \notin ind(D) \\ 0, (\mu_i, \mu_j) \in ind(D) \end{cases}$$

其中  $i, j = 1, 2, \dots, n$ . (1)

1.1.2 基于区分矩阵的数据约简算法

定理 1<sup>[2]</sup> 在相容决策表中, 决策表的相对  $D$  核等于该决策表的区分矩阵即  $M_{n \times n}$  中所有单个属性元素组成的集合

$$CORE_D(C) = \{ \alpha | (\alpha \in C) \wedge (\exists c_{ij}, ((c_{ij} \in M_{n \times n}) \wedge (c_{ij} = \{ \alpha \}))) \}$$
 (2)

基于区分矩阵的数据约简步骤

Step 1: 根据决策表区分矩阵的定义, 求出区分矩阵  $M_{n \times n}$ ;

Step 2: 计算决策表的相对核  $CORE_D(C)$ , 令  $B = CORE_D(C)$ ;

Step 3: 对任意  $c_{ij}, (i, j = 1, 2, \dots, n)$  如果  $c_{ij} \cap B \neq \Phi$ , 则  $c_{ij} = \Phi$ ; 如果  $c_{ij} = \Phi$  都成立, 则转到第五步; 否则转到第四步;

Step 4: 统计当前矩阵  $M_{n \times n}$  中每个属性出现的次数, 选取出现次数最多的元素为  $\alpha_m$ , 令  $B = B \cup \{ \alpha_m \}$ , 转到第三步;

Step 5: 输出  $B \in RED_D(C)$ , 算法结束。

1.2 BP 神经网络算法

BP 神经网络目前受到广泛的使用, 典型的 BP 神经网络由三层神经元组成, 分别是输入层、隐层、输出层, 现假设输入层有  $n$  个神经元, 隐含层有  $p$  个神经元, 输出层有  $q$  个神经元, 据此给出建模所需变量的定义。输入变量为  $X = (x_1, x_2, \dots, x_n)$ , 隐含层输入变量为  $hi = (hi_1, hi_2, \dots, hi_p)$ , 隐含层输出变量为  $ho = (ho_1, ho_2, \dots, ho_p)$ , 输出层输入变量为  $yi = (yi_1, yi_2, \dots, yi_q)$ , 输出层输出变量为  $yo = (yo_1, yo_2, \dots, yo_q)$ , 期望输出变量为  $d_o = (d_1, d_2, \dots, d_q)$ , 输入层与隐含层的连接权值为  $w_{ih}$ , 隐含层与输出层的连接权值为  $w_{ho}$ , 隐含层各神经元的阈值为  $b_h$ , 输出层各神经元的阈值为  $b_o$  [3]。

BP 神经网络的学习过程利用输入输出样本集对网络进行训练, 即对网络的权值和阈值进行学习和训练, 以使网络实现给定的输入输出映射关系。具体步骤如下:

Step 1: 通过将随机数加到网络各层权值和阈值上来初始化, 设定误差函数为  $e$ , 给定计算精度值  $\epsilon$  和最大学习次数  $M$ ;

Step 2: 输入训练的样本后根据公式 (3) ~ (6) 计算各层输出;

$$hi_h(k) = \sum_{i=1}^n w_{ih} x_i(k) - b_h \quad h = 1, 2, \dots, p$$
 (3)

$$ho_h(k) = f(hi_h(k)) \quad h = 1, 2, \dots, p$$
 (4)

$$yi_o(k) = \sum_{h=1}^p w_{ho} ho_h(k) - b_o \quad o = 1, 2, \dots, q$$
 (5)

$$yo_o(k) = f(yi_o(k)) \quad o = 1, 2, \dots, q$$
 (6)

Step 3: 计算误差  $e = \frac{1}{2} \sum_{o=1}^q (d_o(k) - yo_o(k))^2$ ;

Step 4: 检查是否所有样本完成一次训练, 如果全部完成转到 Step5, 否则转到 Step 2。

Step 5: 先根据公式 (7) 利用输出层各神经元的偏导数  $\delta_o(k)$  和隐含层各神经元的输出来调整连接权值  $w_{ho}(k)$ , 再根据公式 (8) 利用隐含层个神经元的偏导数  $\delta_h(k)$  和输入层各神经元的输入来调整连接权值  $w_{ih}$ , 最终使总误差达到精度要求。

$$w_{ho}^{N+1} = w_{ho}^N + \Delta w_{ho}(k) = w_{ho}^N + \eta \delta_o(k) ho_h(k)$$
 (7)

$$w_{ih}^{N+1} = w_{ih}^N + \Delta w_{ih}(k) = w_{ih}^N + \eta \delta_h(k) x_i(k)$$
 (8)

1.3 基于粗糙集-BP 神经网络的管道腐蚀程度预测流程

将导致管道腐蚀的相关因素使用粗糙集理论进行处理, 首先将实际数据离散化生成属性决策表; 然后进行属性约简, 将最小属性约简作为管道腐蚀程度预测中 BP 神经网络的输入变量。具体过程如下:

Step 1: 建立原始数据决策表: 从企业内部记录的运行数据中选取所需属性, 构建管道腐蚀程度预测的原始决策表;

Step 2: 原始数据离散化: 粗糙集理论只能研究离散值对象, 因此通过建立的离散化标准来将获取的记录值进行离散化;

Step 3: 属性约简: 导致管道腐蚀的原因众多, 但这些原因并不全部会导致管道腐蚀, 不同地理环境、不同材料的管道腐蚀可能因为不同原因, 因此影响因素中可能存在着冗余信息。在保证最终管道腐蚀程度预测精度的前提下, 通过基于区分矩阵的属性约简算法删除冗余属性, 降低决策表维数。将约简之后的得到的属性变量作为 BP 神经网络的输入变量;

Step 4: 构建 BP 神经网络: 根据输入变量和输出变量确定隐层神经元的个数, 从而构建 BP 神经网络结构;

Step 5: 利用样本值对 BP 神经网络进行训练, 当达到预定的误差精度或达到最大的训练次数即停止;

Step 6: 进行管道腐蚀程度预测。

2 仿真研究

2.1 腐蚀原因分析

管道在土壤中受到的腐蚀因素较多, 且各因素交叉作用, 因此使用传统的单一指标进行腐蚀评价具有较大的局限性。通过现场考察, 从两个方面考虑管道外腐蚀的影响因素。首先是

外部土壤对管道的腐蚀；其次是管道外防腐体系所产生的作用，保护层包括外部防腐层和阴极保护。

土壤是导致埋地油气管道腐蚀主要外因。管道遭受腐蚀之后由于管壁厚度变薄导致破裂、穿孔，从而引发泄漏甚至火灾爆炸等事故<sup>[4]</sup>。究其原因，土壤是固液气三相共存的复杂环境，所以有能够构成腐蚀原电池的条件，因此可以说管道腐蚀基本都是电化学腐蚀造成的。另外直流杂散电流也是造成管道外部腐蚀的一个重要的原因。直流杂散电流主要是由电气化铁路、直流电机、电解和电镀等直流电气设备避雷接地装置等引起的。此外，由于第三方管道的外加电流保护系统不合理的设置，也有可能形成对其他管道的直流电性干扰，造成管道的迅速腐蚀、穿孔。形成对管道的直流电性干扰往往是这些直流电流被强制施加到管道上，是形成对金属管道电性腐蚀的主要因素<sup>[5]</sup>。因此常用的单项指标有土壤电阻率、氧化还原电位、土壤 PH 值、土壤含水量、土壤含盐量等。

管道外防腐层起到了阻隔管道和土壤腐蚀介质的作用，它和管道阴极保护体系共同组成了有效的管道外防腐体系。外覆盖层是埋地管道免遭外界腐蚀的第一道防线，在管道的外防腐体系中具有重要的地位。阴极保护对管道的腐蚀控制很有效，它是使金属表面成为电化学电池的阴极而达到减小其腐蚀速率的一项技术。因此防腐层和阴极保护的参数也是一项重要指标。

因此本文最终选择了 11 个影响因素，分别是土壤电阻率  $\mu_1$ 、自然电位  $\mu_2$ 、PH 值  $\mu_3$ 、含盐量  $\mu_4$ 、氧化还原电位  $\mu_5$ 、含水量  $\mu_6$ 、阴极保护运行率  $\mu_7$ 、阴极保护率  $\mu_8$ 、杂散电流（地电位梯度） $\mu_9$ 、破损点密度  $\mu_{10}$ 、管壁剩余厚度  $\mu_{11}$ 。

2.2 基于区分矩阵的粗糙集属性约简

选取的石化公司某段丙烯管线情况如下：管道材料牌号 20 钢，GC2 类管线，全长共 2340 m， $\Phi 108 \times 6$  mm 设计压力：3.5 MPa，设计温度 40 °C，设计流速 0.71 m/s，管道设计流量 20 m<sup>3</sup>/h，操作压力：出口 2.9 MPa，进口 2.5~3.0 MPa，操作温度常温，操作状态下的物料密度 497 kg/m<sup>3</sup>，连续输送，输送量为 20 m<sup>3</sup>/h，保温。

首先在现场选择 10 个测试点，按照表 2 所示的影响因素进行测量，完成表 2 的数据补充，对于腐蚀等级的判定同样依据现场实际考察情况由专家给出；再在通过相关文献的查阅，确定数据离散化的标准；最后将数据离散化后生成决策表，见表 1。

表 1 管道腐蚀影响因素决策表

	$\mu_1$	$\mu_2$	$\mu_3$	$\mu_4$	$\mu_5$	$\mu_6$	$\mu_7$	$\mu_8$	$\mu_9$	$\mu_{10}$	$\mu_{11}$	D
$\alpha_1$	0	1	0	1	0	2	0	2	1	2	2	4
$\alpha_2$	0	2	0	2	0	2	0	1	1	2	1	4
$\alpha_3$	0	2	0	2	0	2	0	1	1	1	1	3
$\alpha_4$	0	2	0	2	0	2	0	0	0	1	1	2
$\alpha_5$	0	1	0	2	0	2	0	1	1	1	1	3
$\alpha_6$	0	2	0	2	0	2	0	0	1	2	1	3
$\alpha_7$	0	1	0	2	0	1	0	0	1	0	1	2
$\alpha_8$	1	2	0	1	0	2	0	0	1	1	2	4
$\alpha_9$	0	1	2	2	0	2	0	1	1	1	1	4
$\alpha_{10}$	1	2	0	1	1	2	0	0	1	1	2	4

表 2 不同点多影响因素的测量值

序号 影响因素	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	$\alpha_6$	$\alpha_7$	$\alpha_8$	$\alpha_9$	$\alpha_{10}$
	土壤电阻率/ ( $\Omega \cdot m$ ) $\mu_1$	132.5	122.2	120.5	163.7	244.8	48.8	90.8	39.6	118.5
自然电位/ (mV) $\mu_2$	349	445	468	500	329	475	440	445	379	490
PH 值 $\mu_3$	7.93	7.98	7.78	7.56	7.96	8.09	7.94	7.92	4.7	8.14
含盐量/(%) $\mu_4$	0.08	0.13	0.14	0.19	0.30	0.21	0.11	0.07	0.17	0.09
氧化还原 电位/(mV) $\mu_5$	540.0	580.4	594.7	569.5	549.5	589.7	609.7	649.9	560.7	437.6
含水量/(%) $\mu_6$	14.9	19.5	15.9	18.3	20.1	7.98	8.86	15.8	13.4	17.3
阴极保 护运 行率/ (%) $\mu_7$	98	100	98	99	99	100	99	99	99	100
	阴极保 护率/ (%) $\mu_8$	25	32	45	90	70	84	88	92	63
杂散电流 (地电位梯 度) / (mV/m) $\mu_9$	0.9	0.7	11	0.5	0.8	1.5	1.1	0.6	2.3	1.8
破损点密度/ (处/100m) $\mu_{10}$	3.6	4.1	1.8	0.9	1.6	5.5	0	1.4	1.7	1.2
管壁剩余厚度/ (mm) $\mu_{11}$	3.7	4.2	4.5	5.1	4.8	4.3	5.0	4.1	4.6	3.9
腐蚀等级 (D)	4	4	3	2	3	3	2	3	4	4

首先通过区分矩阵  $M_{10 \times 10}$  进行属性约简我们获得了最简属性集为  $[\mu_3, \mu_5, \mu_8, \mu_{10}, \mu_{11}]$ 。将最简属性集  $[\mu_3, \mu_5, \mu_8, \mu_{10}, \mu_{11}]$  作为输入层神经元 L，决策属性 D 作为输出层神经元 N，因此 L=5，N=1，利用经验公式  $M = \sqrt{L+N} + a$  确定隐层神经元个数，其中 a 的取值范围为 [1,10]，通过计算确定隐层神经元 M=4。选取十组数据中的前八组作为训练样本，后两组作为测试样本。

分别用单一 BP 神经网络<sup>[6]</sup>和本文的粗糙集-BP 神经网络进行预测仿真比较，见图 1 和图 2。两者通过 MATLAB 仿真




图 1 单一 BP 方法训练误差样本

表4 网关冲突概率数据表

试验次数	数据数量	传统系统冲突概率/ (%)	本文系统冲突概率/ (%)
	100	11	10
2	200	13	10
3	300	15	11
4	400	14	10
5	500	16	11
6	600	16	10
7	700	20	12
8	800	21	12
9	900	23	13
10	1000	24	14

根据上述实验结果能够得知, 利用本文系统能够有效降低超高频 RFID 网关的冲突的概率, 充分体现出本文系统的优越性。

#### 4 结束语

本文提出一种基于 MC13213 的多通道分布式环境监测系统的超高频 RFID 网关系统的设计方法。分别从硬件部分和软件部分进行了详细阐述。硬件部分详细介绍了网关终端节点、网关路由节点和网关中心节点的设计方法。软件部分详细阐述了网关进程之间通信机制的设计和网关任务机制数据结构程序设计方法。实验结果表明, 利用本文系统能够避免超频率 RFID 网关在通信过程中的冲突, 从而提高了环境信息采集的

准确率, 取得了令人满意的效果。

#### 参考文献:

[1] Rochwerger B, Breitgand D, Levy E, et al. The Reservoir Model and Architecture for Open Federated Cloud Computing [J]. IBM Journal of Research and Development, 2009, 53 (4): 1-17.

[2] Ali S, Siegel H J, Maheswaran M, et al. Representing Task and Machine Heterogeneities for Heterogeneous Computing systems [J]. Journal of Science and Engineering, 2000, 3 (3): 195-207.

[3] Ratnaweera A, Halgamuge S K, Watson H C. Self-Organizing Hierarchical Particle Swarm Optimizer with Time-varying Acceleration Coefficients [J]. IEEE Trans. on Evolutionary Computation, 2004, 8 (3): 240-255.

[4] 卢小青, 张宏科. 用于 IPv6 的新一代路由信息协议 (RIPng) [J]. 电信网技术, 2001 (6): 23-25.

[5] 陶志勇, 方宁, 胡明. 一种改进的基于 WSN 独立分簇的路由协议 [J]. 计算机测量与控制, 2012 (7): 2014-2016.

[6] 陈天娥, 程载和. 基于冲突树的 RFID 自适应防碰撞算法 [J]. 计算机应用, 2010 (7): 28-29

[7] 程文青, 赵梦欣, 徐晶. 改进的 RFID 动帧时隙 ALOHA 算法 [J]. 华中科技大学学报 (自然科学版), 2006 (6): 14-16.

[8] 刘嵩岩, 蔡志强, 苟鹏飞, 李瑞林. 超高频 RFID 系统信号损失与覆盖模型研究 [J]. 哈尔滨工程大学学报, 2008 (2): 5-7.

[9] 金守义, 张士杰. 面向生产线的 RFID 系统设计及通信特性分析 [J]. 计算机工程, 2008 (19): 56-57.

(上接第 268 页)




图2 RS-BP 方法训练误差样本

#### 3 结语

为了克服神经网络在预测方面的局限性, 本文利用粗糙集理论在处理冗余、不确定和模糊信息方面的优点, 将粗糙集理论与 BP 神经网络算法相结合, 利用粗糙集属性约简的重要特性, 去除冗余属性来减少 BP 神经网络输入层神经元个数, 从根本上降低了 BP 神经网络算法进行管道腐蚀程度预测的复杂度, 提高了预测速度, 弥补单一预测方法的不足。

#### 参考文献:

[1] 苗夺谦, 李道国. 粗糙集理论、算法与应用 [M]. 北京: 清华大学出版社, 2008.

[2] 刘文军, 谷云东, 李洪兴. 基于区分矩阵求决策算法的约简[J]. 北京师范大学学报, 2003, 39 (3): 311-315.

[3] 张文鸽, 吴泽宁, 逯洪波. BP 神经网络的改进及其应用 [J]. 河南科技, 2003, 21 (2): 202-206.

[4] 马涛, 张洪雷. 浅谈油气输送管道的腐蚀机理 [J]. 化学工程与装备, 2009, 11 (1): 121-122.

[5] 谢阁新. 埋地钢质管道外腐蚀检测评价综合方法研究 [D]. 北京: 北京工业大学, 2009.

[6] 韩琳, 薛静, 张通. 基于粗糙集神经网络的旋转机械故障诊断 [J]. 计算机测量与控制, 2008, 18 (1): 64-66.

[7] Dong Y H, Yu D T. Estimation of failure probability of oil and gas transmission pipelines by fuzzy fault tree analysis [J]. Journal of Loss Prevention in the Process Industries, 2005, 4 (1): 83-88.

[8] Mandal S K, Chan F T S, Tiwari M K. Lead leak detection of pipeline: An integrated approach of rough set theory and artificial bee colony trained SVM [J]. Expert Systems with Applications, 2012, 8 (15): 3071-3080.

$$M_{10 \times 10} = \begin{pmatrix} 0 & & & & & & & & & & \\ \mu_{2_1} \mu_{1_1} \mu_{9_1} & & & & & & & & & & \\ \mu_{10_1} \mu_{1_1} & \mu_{10} & & & & & & & & & \\ \mu_{2_2} \mu_{1_1} \mu_{9_1} & & & & & & & & & & \\ \mu_{2_1} \mu_{10_1} \mu_{1_1} & \mu_{8_1} \mu_{9_1} \mu_{10_1} & & & & & & & & & \\ \mu_{4_1} \mu_{8_1} \mu_{10_1} \mu_{1_1} & \mu_{2_2} \mu_{1_1} & & & & & & & & & \\ \mu_{2_1} \mu_{1_1} \mu_{2_1} \mu_{1_1} & \mu_{8_1} & 0 & \mu_{1_2} \mu_{9_1} \mu_{9_1} & & & 0 & & & & \\ \mu_{9_1} \mu_{2_1} \mu_{9_1} \mu_{10_1} \mu_{1_1} & \mu_{2_1} \mu_{1_1} \mu_{9_1} \mu_{10_1} & \mu_{2_1} \mu_{1_1} \mu_{9_1} \mu_{10_1} & 0 & \mu_{1_1} \mu_{9_1} \mu_{10_1} & \mu_{2_1} \mu_{9_1} \mu_{10_1} & & & & & \\ \mu_{1_1} \mu_{2_1} \mu_{8_1} \mu_{10_1} & \mu_{1_1} \mu_{1_1} \mu_{8_1} \mu_{10_1} \mu_{1_1} & 0 & \mu_{1_1} \mu_{1_1} & \mu_{9_1} \mu_{11} & 0 & 0 & & & \mu_{1_1} \mu_{2_1} \mu_{9_1} & \\ & & & & & & & & & \mu_{9_1} \mu_{10_1} \mu_{1_1} & \\ 0 & 0 & \mu_{2_1} \mu_{1_1} & \mu_{2_1} \mu_{1_1} & \mu_{1_1} \mu_{1_1} & \mu_{2_1} \mu_{9_1} \mu_{9_1} \mu_{10_1} & \mu_{2_1} \mu_{9_1} \mu_{9_1} \mu_{10_1} & \mu_{1_1} \mu_{2_1} \mu_{9_1} & & & \\ 0 & 0 & \mu_{1_1} \mu_{9_1} \mu_{9_1} \mu_{1_1} & \mu_{1_1} \mu_{1_1} & \mu_{1_1} \mu_{2_1} \mu_{1_1} & \mu_{1_1} \mu_{9_1} \mu_{1_1} & \mu_{1_1} \mu_{1_1} \mu_{1_1} & \mu_{1_1} \mu_{2_1} \mu_{9_1} & & & \\ & & & \mu_{2_1} \mu_{9_1} \mu_{1_1} & \mu_{1_1} \mu_{9_1} \mu_{1_1} & \mu_{2_1} \mu_{9_1} \mu_{1_1} & \mu_{1_1} \mu_{2_1} \mu_{9_1} \mu_{1_1} & \mu_{2_1} \mu_{9_1} \mu_{1_1} & \mu_{1_1} & & 0 \end{pmatrix}_{10 \times 10}$$

得到的结果与实际结果都是一致的。但是由于基于粗糙集的 BP 神经网络输入神经元的个数少于单一 BP 神经网络输入神经元的个数, 因此隐层神经元个数同样少于后者, 可以有效的简化网络结构, 缩短训练时间, 从而说明了粗糙集-BP 神经网络进行管道腐蚀程度预测是有效的。