

基于遗传算法的模糊优选神经网络路面性能评价模型

刘 艳¹, 康海贵^{*1}, 孙 敏²

(1. 大连理工大学 海岸和近海工程国家重点实验室, 辽宁 大连 116024;

2. 辽宁省高等级公路建设局, 辽宁 沈阳 110002)

摘要: 针对现有路面性能评价方法的不足,在模糊优选神经网络模型的基础上,引入遗传算法,建立了基于遗传算法的模糊优选神经网络的路面使用性能评价模型.该算法采用遗传算法优化神经网络权值,再用神经网络对遗传算法搜索到的近似最优解进行微调,并将模糊优选模型作为神经网络的激励函数,使模型具有明确的物理意义.应用该模型对沈大高速公路部分路段进行评价,与其他模型的对比分析表明:该方法在评价精度和效率方面取得了良好的效果,是一种实用的高速公路路面性能评价方法.

关键词: 路面性能评价;模糊优选;神经网络;遗传算法

中图分类号: U416.21 **文献标志码:** A

0 引言

在路面管理系统中,对道路各路段路面使用性能的恰当评估是系统正确决策的基础.目前,传统的路面使用性能综合评价模型主要有回归分析模型、系统分析法模型、灰色理论法模型等几类.但是回归分析模型不足以准确表征路面实测指标与专家评价结果之间的复杂联系,系统分析法中人为因素影响太重,灰色理论法模型又太依赖于评价指标的经验范围^[1].

针对以往评价模型的不足,一些新的理论与方法被引入到路面性能评价领域.何铁军等将模糊理论与神经网络有机结合,建立了路面使用性能的模糊神经网络评价模型^[2].但是,由于BP网络收敛慢、易于局部收敛,上述模型建模比较困难.胡霞光等针对BP网络模型的缺陷,发挥遗传算法全局收敛性的优点,建立了路面使用性能评价的GANN模型^[3].不过,此模型仅采用GA对BP网络的权值与阈值进行优化,没有充分发挥BP网络的优势.刘沐宇等针对上述方法的不足,建立了一种充分发挥GA和BP两者优势的路面使用性能混合GANN评价模型^[4].上述方法在预测精度和效率中的某些方面都取得了逐步的改进或提高,但如何使神经网络模型的物理意义更加明确、易于理解,

在这方面的的工作还不多见.为此,本文建立一种充分发挥遗传算法与模糊优选神经网络(FONN)优势的路面使用性能混合智能评价模型.

1 模糊优选模型

优与劣这一对立概念之间既有差异又有共维,且处于两个极点,具有中介过渡性,这是优选的模糊性,故称模糊优选.另一方面,优选是在有限论域的非劣解方案集中进行,且是对一定的标准而言,这是优选的相对性.因此可用相对隶属度定义,建立论域 U (方案集)的任一元素 u (方案)对于模糊概念优的相对隶属度(简称相对优属度)模型^[5].

设系统有满足约束条件的 n 个方案组成方案集,以 m 个目标(指标)对方案的优劣进行评价.其特征值矩阵

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{pmatrix} = (x_{ij});$$
$$i = 1, 2, \cdots, m; j = 1, 2, \cdots, n \quad (1)$$

式中 x_{ij} 为方案 j 目标 i 的特征值.

目标特征值分为越大越优、越小越优两个基本类型.对越大越优目标,其规格化公式为

$$r_{ij} = \begin{cases} 1; & x_{imax} \\ x_{ij}/x_{imax}; & \text{其他} \\ 0 & 0 \end{cases} \quad (2)$$

对越小越优目标,其规格化公式为

$$r_{ij} = \begin{cases} 1; & x_{imin} \\ x_{imin}/x_{ij}; & \text{其他} \end{cases} \quad (3)$$

应用式(2)、(3) 将目标特征值矩阵 $\mathbf{X}$ 变换为

$$\mathbf{R} = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & & \vdots \\ r_{m1} & r_{m2} & \cdots & r_{mn} \end{pmatrix} = (r_{ij}) \quad (4)$$

根据相对隶属度定义,劣与优分别处于参考连续统的两个极点,则劣、优方案的目标相对优属度向量分别为

$$\mathbf{b} = (0 \quad 0 \quad \cdots \quad 0) \quad (5)$$

$$\mathbf{g} = (1 \quad 1 \quad \cdots \quad 1) \quad (6)$$

设方案 j 目标 i 的权重矩阵为

$$\mathbf{W} = \begin{pmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & & \vdots \\ w_{m1} & w_{m2} & \cdots & w_{mn} \end{pmatrix} = (w_{ij}) \quad (7)$$

式中 w_{ij} 为方案 j 目标 i 的权重,对任意的方案 j 满足 $\sum_{i=1}^m w_{ij} = 1$.

则方案 j 与优、劣方案的距离为

$$d_{jg} = \sum_{i=1}^m w_{ij} (1 - r_{ij}) = 1 - \sum_{i=1}^m w_{ij} r_{ij} \quad (8)$$

$$d_{jb} = \sum_{i=1}^m w_{ij} (r_{ij} - 0) = \sum_{i=1}^m w_{ij} r_{ij} \quad (9)$$

设方案 j 对优的相对隶属度为 u_j ,对劣的相对隶属度为 u_j^c ,则有

$$u_j^c = 1 - u_j \quad (10)$$

将隶属度定义为权重,则方案 j 与优、劣方案之间的权距离分别为

$$D_{jg} = u_j d_{jg} \quad (11)$$

$$D_{jb} = u_j^c d_{jb} = (1 - u_j) d_{jb} \quad (12)$$

为求解方案 j 相对优属度的最优值,令方案 j 的加权距优距离平方与加权距劣距离平方之总和最小,即目标函数为

$$\begin{aligned} \min F(u_j) &= D_{jb}^2 + D_{jg}^2 = \\ &u_j^2 \left(1 - \sum_{i=1}^m w_{ij} r_{ij}\right)^2 + \\ &(1 - u_j)^2 \left(\sum_{i=1}^m w_{ij} r_{ij}\right)^2 \end{aligned} \quad (13)$$

令 $dF(u_j)/u_j = 0$,得到模糊优选模型(图 1) 为

$$\begin{aligned} u_j &= \frac{1}{1 + \left[\frac{1 - \sum_{i=1}^m w_{ij} r_{ij}}{\sum_{i=1}^m w_{ij} r_{ij}} \right]^2} = \\ &\frac{1}{1 + \left(\frac{d_{jg}}{d_{jb}}\right)^2} = \frac{1}{1 + \left(\frac{1 - d_{jb}}{d_{jb}}\right)^2} \end{aligned} \quad (14)$$

该式的物理意义为当方案 j 距优距离 $d_{jg} > d_{jb}$ 时,方案 j 的相对优属度 $u_j > 0.5$;当 $d_{jg} < d_{jb}$ 时, $u_j < 0.5$;当 $d_{jg} = d_{jb}$ 时, $u_j = 0.5$;当 $d_{jg} = 0$ 时,即方案 j 就是最优方案, $u_j = 1$;当 $d_{jg} = 1$ 时, $u_j = 0$. 因此模糊优选模型具有清晰的数学、物理意义.




图 1 模糊优选模型 S 形函数图

Fig.1 Function diagram with S type of fuzzy optimization model

2 模糊优选神经网络模型

神经元是控制与信息处理的基本单元,具有兴奋与抑制两种常规的工作状态.从模糊集观点来看,这两种状态是模糊概念,具有中介过渡性,为此可以用模糊优选模型来描述神经网络系统中神经元的激励函数,使神经网络节点神经元的激励函数具有明确的物理含义——优选是人脑的本质属性^[5].其基本原理如下:

设神经网络(NN)的输入层节点数为 m ,隐含层节点数为 l ,输出层节点数为 g .为表述方便,用 i 表示输入层节点, k 表示隐含层节点, p 表示输出层节点.如图 2 所示.




图 2 神经网络结构图

Fig.2 Structure of neural network model

设有 n 个样本,对于样本 j 的输入为 $r_{ij}, i = 1, 2, \cdots, m; j = 1, 2, \cdots, n$. 输入层节点 i 将信息直

接传递给隐含层节点 k , 节点输出与输入相等, 即

$$u_{ij} = r_{ij} \quad (15)$$

对于隐含层节点 k , 其输入为

$$I_{kj} = \sum_{i=1}^m \omega_{ik} r_{ij} \quad (16)$$

为进行决策方案优选, 网络隐含层节点 k 和输出层节点 p 的激励函数均采用模糊优选模型(式(14)), 节点 k 的输出为

$$u_{kj} = \frac{1}{1 + \left[\left(\sum_{i=1}^m \omega_{ik} r_{ij} \right)^{-1} - 1 \right]^2} = \frac{1}{1 + (I_{kj}^{-1} - 1)^2} \quad (17)$$

式中: ω_{ik} 为节点 i, k 的连接权重。

输出层节点 p 输入为

$$I_{pj} = \sum_{k=1}^l \omega_{kp} r_{kj} \quad (18)$$

式中: ω_{kp} 为隐含层与输出层节点连接权重。

输出为

$$u_{pj} = \frac{1}{1 + \left[\left(\sum_{k=1}^l \omega_{kp} r_{kj} \right)^{-1} - 1 \right]^2} = \frac{1}{1 + (I_{pj}^{-1} - 1)^2} \quad (19)$$

网络的实际输出 u_{pj} 就是模糊优选神经网络对输入 r_{ij} 的响应, 设样本 j 的期望输出为 $M(u_{pj})$, 则其平方误差为

$$E = \frac{1}{n} \sum_{j=1}^n E_j = \frac{1}{2n} \sum_{j=1}^n \sum_{p=1}^g (u_{pj} - M(u_{pj}))^2 \quad (20)$$

网络学习的目的就是应用梯度下降法通过调整网络中的连接权重使 E 最小。

则隐含层节点与输出层节点的连接权重调整量为

$$\Delta \omega_{kp} = \frac{2\eta}{n} \sum_{j=1}^n u_{pj}^2 u_{kj} \left[\frac{1 - \sum_{k=1}^l \omega_{kp} u_{kj}}{\left(\sum_{k=1}^l \omega_{kp} u_{kj} \right)^3} \right] \times \sum_{p=1}^g (M(u_{pj}) - u_{pj}) \quad (21)$$

式中: η 是学习系数。

输入层节点与隐含层节点的连接权重调整量为

$$\Delta \omega_{ik} = \frac{2\eta}{n} \sum_{j=1}^n r_{ij} \omega_{kp} u_{kj}^2 \left[\frac{1 - \sum_{i=1}^m \omega_{ik} r_{ij}}{\left(\sum_{i=1}^m \omega_{ik} r_{ij} \right)^3} \right] \delta_{pj} \quad (22)$$

式中

$$\delta_{pj} = 2u_{pj}^2 \left[\frac{1 - \sum_{k=1}^l \omega_{kp} u_{kj}}{\left(\sum_{k=1}^l \omega_{kp} u_{kj} \right)^3} \right] \sum_{p=1}^g (M(u_{pj}) - u_{pj}) \quad (23)$$

权重调整公式为

$$\Delta \omega_{ik}(t+1) = \omega_{ik}(t) + \Delta \omega_{ik}(t+1) + \alpha \Delta \omega_{ik}(t) \quad (24)$$

$$\Delta \omega_{kp}(t+1) = \omega_{kp}(t) + \Delta \omega_{kp}(t+1) + \alpha \Delta \omega_{kp}(t) \quad (25)$$

式中: α 是动量系数, 且 $0 < \alpha < 1$ 。

应用上述模型, 并根据神经网络的训练算法, 可确定网络的连接权重值, 使实际输出与期望输出的误差最小。

3 基于遗传算法的模糊优选神经网络模型

针对神经网络模型易于出现局部极小值, 且收敛速度较慢的缺点, 将具有全局搜索特点的遗传算法融入到模糊优选神经网络算法中。

3.1 编码方法的确定

浮点编码具有表示范围大、精度高、搜索空间大, 便于与其他方法混合使用等优点; 鉴于计算的精确、高效与方便, 建模时采用浮点编码^[6]。这同时也确定了问题的解码方法。

3.2 种群的初始化

在保证神经网络灵敏性(即每个节点的净输入均在零点附近)的前提下, 为了使 GA 优化 FONN 权值时产生尽可能多的可行解, 选用初始种群权值的范围为 $[-2, 2]$ ^[7]。

3.3 适应度的计算

GA 的适应度表征个体染色体的优良程度, 适应度越大, 染色体性能越好。但初始权值与阈值好的网络的性能并不一定好, 只有在神经网络将初始权值与阈值训练一定次数后的输出误差才能体现这个初始权值与阈值性能的优良程度。当然, 这个次数也不能太多, 否则就失去了用 GA 优化神经网络的意义; 而神经网络在训练时, 一般是在训练的前几十次时网络输出误差变化最为明显。模型采用 FONN 训练 25 次后输出误差 E 的函数 $f(E) = 1/(1+10 \times E)$ 作为适应度评价函数, 其中 E 为网络实际输出与专家评分的平均相对误差。

3.4 GA 其他参数的确定

模型种群大小选定为 35 个, 终止条件为 $E \leq \epsilon_1$ 或求得达到最大迭代次数 15 次, 选择操作采用轮盘赌方式; 交叉操作采用均匀算术交叉, 其概率为 0.6; 变异操作采用均匀变异, 其概率为 0.05。

3.5 神经网络相关参数的确定

在建模时依据网络结构设计经验规则: “大拇指规则(rules of thumb)” ($m = \frac{n+l}{2}$ 或 $m =$

$\sqrt{\frac{n+l}{2}})$ 、“金字塔规则 (geometric pyramid rule)” (从输入层到输出层节点数不断减少) 以及有人提倡的试算法隐含层神经元估计公式: $m = \sqrt{n \times l}$. 经反复试算选定了效果较好的 5-3-1 模型结构.

神经网络训练终止条件为 $E \leq \epsilon_2$ 或达到最大训练次数 (对 GA 搜索到的近似最优值进行微调 2 000 次).

3.6 评价模型的流程

本文应用 Delphi 程序来实现评价模型, 具体步骤如图 3.




图 3 评价模型流程图

Fig. 3 Flow chart of evaluation model

- (1) 确定 GA 的编码方法、终止条件及其他参数, 初始化种群;
- (2) 译码到解空间, 用 FONN 训练 25 次输出误差 E , 计算个体染色体适应度 $f(E) = 1/(1 + 10 \times E)$;
- (3) 判断是否达到遗传算法终止条件 ($E \leq \epsilon_1$ 或最大迭代次数 15), 若达到终止条件, 则转入 (5), 否则执行以下步骤;
- (4) 进行遗传操作 (选择操作、交叉操作、变异操作), 产生新一代的染色体, 转到 (2);
- (5) 用 BP 网络对 GA 搜索到的近似最优值进行微调, 提高解的精度, 直至达到神经网络微调

终止条件 ($E \leq \epsilon_2$ 或最大训练次数 2 000), 输出结果.

4 算 例

4.1 输入输出参数的选取

与一般公路相比, 高速公路自身具有交通量大、汽车轴载重、交通渠化、行车速度高等特点, 其路面使用性能的现状和发展变化规律与一般公路有所不同. 通过研究发现: 在路面破损中, 裂缝与车辙占了路面破损中的 80%~90%^[8~10]; 车辙严重是高速公路路面使用性能不同于一般公路的一个显著特点, 而裂缝在路面破损中也占有很大的比重.

为了体现高速公路的这个特点, 建模时将裂缝与车辙单独列出, 选取反映路面裂缝的最大裂缝率 (C_r) 与反映车辙的最大车辙深度 (R_d) 作为模型的输入. 除此之外, 本文还选用了平整度 σ 、强度指标 S 和抗滑能力 B 三个参数作为模型的输入, 并选用专家评分作为模型的输出.

4.2 输入输出数据的预处理

对模型的输入数据, 采用了 Sigmoid 分布变换进行归一化处理. 因为 Sigmoid 分布变换具有数据压缩功能, 能将一些异常数据的异常性变小, 减小了异常数据的异常性对建模的影响, 但同时也保留了异常数据在建模中的作用, 这样做更科学.

本文采用的 Sigmoid 分布变换形式为

$$y_i = \frac{1}{1 + be^{-ax_i}} \tag{26}$$

式中: x_i 为原评价指标值; y_i 为转换后评价指标值; a 、 b 为待定参数, 如表 1 所示.

表 1 评价指标转换的待定参数

Tab. 1 Parameters for transformation pavement performance evaluation indices

指标	原指标取优时		原指标取差时		待定参数	
	x_i	y_i	x_i	y_i	a	b
C_r	5	0.85	15.0	0.4	-0.214 0	0.060 5
R_d	5	0.85	20.0	0.4	-0.142 7	0.086 5
B	42	0.85	27.0	0.4	0.142 7	70.639 1
S	1	0.85	0.5	0.4	4.280 1	12.750 0
σ	2	0.85	4.5	0.4	-0.856 0	0.031 9

对模型的输出目标专家评分, 其取值范围为 $[0, 5]$, 直接采用线性尺度变换: $y_i = x_i/5$ 将其取值范围转化为 $[0, 1]$.

4.3 结果分析

评价模型科学性的一个很重要的方面是模型

的泛化能力. 为了检验模型的泛化能力, 在建模时采用沈大高速公路 25 组数据以 4 : 1 均匀分开分别作为训练样本与检验样本 (如表 2 所示); 为了检验模型的稳定性, 对每个模型都进行了连续 5 次的训练; 为了检验评价模型的科学性及有效性, 与回归分析模型、BP 神经网络模型及遗传神经网络模型训练结果进行了比较, 结果见表 3~7.

表 2 实验路段主观评分与实测数据一览表
Tab.2 Statistical table of subjective scores and practical data of experimental road sections

里程/km	评分	$C_r/\%$	R_d/mm	S	B	σ
19~20	4.33	4.03	4.1	2.985	29	1.680
23~24	4.11	6.34	3.4	2.260	24	1.880
36~37	3.66	2.02	9.4	2.419	34	1.725
38~39	3.40	2.30	10.0	1.910	32	1.800
57~58	4.00	2.88	5.9	0.995	36	2.290
69~70	3.00	8.14	5.9	1.095	31	1.730
71~72	2.88	2.95	3.7	1.080	30	2.140
73~74	3.43	2.30	8.3	1.090	29	2.553
76~77	4.29	2.66	4.5	1.080	32	2.190
79~80	3.38	2.88	7.8	1.160	29	2.240
89~90	2.88	2.59	14.5	0.533	36	2.114
91~92	2.50	0.65	5.5	0.762	36	4.360
94~95	2.13	14.45	6.5	0.629	32	2.450
100~101	2.38	36.12	3.3	0.714	32	2.730
105~106	2.29	14.40	2.0	0.800	31	2.800
315~316	2.50	6.00	16.0	0.400	33	3.420
316~317	1.77	5.35	18.0	0.500	29	3.650
317~318	1.87	2.00	3.0	0.500	30	2.830
318~319	2.42	6.24	5.0	0.500	31	2.800
319~320	1.90	0	1.5	0.500	29	2.340
42~41	2.55	7.80	8.0	0.400	32	3.250
88~87	2.39	6.34	9.5	0.700	31	3.290
103~102	2.40	1.80	9.5	0.300	26	3.600
108~107	2.32	8.93	9.5	0.400	28	3.460
152~151	2.56	6.00	8.0	0.700	32	2.620

表 3 评价模型训练结果

Tab.3 Training results of evaluation model

训练次序	训练次数	误差	C_1	C_2	C_3
1	1 934	0.06	0.973	0.937	0.961
2	1 782	0.06	0.975	0.935	0.960
3	2 000	0.08	0.972	0.932	0.963
4	2 000	0.07	0.963	0.923	0.951
5	1 683	0.06	0.974	0.942	0.967

注: $C_{1/2/3}$ 表示训练样本/检验样本/全部样本的专家评价数据与回归公式预测数据之间的相关性系数; 误差表示 NN 训练结束后网络输出的平均绝对误差

表 3 为该评价模型的训练结果, 其中遗传算法终止条件是平均相对误差 $E \leq 4\%$, 神经网络算法终止条件是平均相对误差 $E \leq 2\%$, 误差指平均

绝对误差; 表 4 为文献[8]中回归公式的预测数据与专家评价数据之间的相关性分析; 表 5 为 BP 神经网络训练结果; 表 6 为文献[4]中混合遗传神经网络模型训练结果; 表 7 为本文模型与文献[3]中 GANN 模型的比较分析结果.

表 4 回归公式的预测数据与专家评价数据之间的相关性分析

Tab.4 Correlation analysis of regression formulas between predictive values and expert evaluation values

公式	C_1	C_2	C_3
R_4	0.872	-0.104	0.826
R_5	0.873	-0.090	0.819

注: $R_{4/5}$ 为文献[8]中选用不同的评价指标, 采用多元回归法建立的相关性最好的 2 个回归评价模型

表 5 BP 神经网络模型训练结果

Tab.5 Training results of BP neural network model

训练次序	训练次数	误差	C_1	C_2	C_3
1	3 000	0.19	0.923	0.713	0.886
2	3 000	0.17	0.934	0.603	0.848
3	3 000	0.11	0.914	0.845	0.902
4	3 000	0.15	0.920	0.864	0.876
5	3 000	0.10	0.977	0.827	0.926

表 6 文献[4]混合遗传神经网络模型训练结果

Tab.6 Training results of mixed GANN in Lit. [4]

训练次序	训练次数	误差	C_1	C_2	C_3
1	2 000	0.07	0.965	0.930	0.952
2	1 782	0.06	0.975	0.935	0.960
3	2 000	0.08	0.972	0.932	0.963
4	2 000	0.08	0.973	0.933	0.961
5	1 563	0.06	0.976	0.940	0.966

表 7 评价模型与文献[3]中的 GANN 模型的比较

Tab.7 Comparison between evaluation model and GANN model in Lit. [3]

模型	种群大小	迭代次数	BP 网络 微调次数	相关性
GANN	50	1 253	无	0.92 以上
评价模型	40	15	小于 2 000 次	0.95 以上

由表 3~7 可以得出:

(1) 与回归模型相比, 采用类似的数据, 回归模型预测结果的相关性 C_1 、 C_2 、 C_3 都达不到 0.9, 而该模型的相关系数都达到 0.95 以上.

(2) 与 BP 网络模型相比, 训练结束时该模型的绝对误差基本上在 0.1 以下, C_1 达到 0.95 以上,

尤其是 C_2 达到 0.9 以上,而 BP 网络远远达不到这样的结果;而且采用连续训练时,该模型常常有收敛于同一个点的情况,而 BP 网络却没有。

(3) 与文献[3]中的 GANN 模型相比, GANN 模型中种群大小为 50, GA 迭代 1 200 多代时才得到较理想的解;而该模型的种群大小为 40, 只需迭代 15 次,再用 BP 网络进行大约 2 000 次的迭代微调就得到了较理想的解。

(4) 与文献[4]中的混合 GANN 模型相比, 该模型的训练结果仅有稍微改善。

5 结 论

(1) 相对于回归分析模型,该模型是对评价指标与专家评价结果这一关系更准确科学的表达。

(2) 相对于 BP 网络模型,该模型评价结果更稳定、精度更高,泛化能力更好。

(3) 相对于一般 GANN 模型,该模型充分发挥了 GA 和 FONN 的优点,模型结构更科学,收敛速度更快,评价精度更高。

(4) 相对于混合 GANN 模型,该模型的评价结果虽然没有明显的改善,但模型物理意义明确,易于理解。

(5) 由于神经网络初始权重的产生是随机的,算法的结果会产生不稳定现象。但如果选择了合理的模型及参数,计算结果就会相对稳定。

参考文献:

- [1] 何桂平,李宇峙,黄永根. 水泥混凝土路面综合路况的灰色评价方法研究[J]. 长沙交通学院学报, 1999, **15**(3):42-47
- [2] 何铁军,黄卫. 模糊神经网络在沥青路面使用性能评价中的应用[J]. 公路交通科技, 2000, **17**(4): 15-18
- [3] 胡霞光,王秉纲. 两种基于遗传算法的路面性能综合评价方法[J]. 长安大学学报(自然科学版), 2002, **22**(2):6-9
- [4] 刘沐宇,黄文雄,叶家军. 基于混合 GANN 的沥青路面使用性能评价[J]. 武汉理工大学学报, 2003, **25**(9):36-39
- [5] 陈守煜. 工程模糊集理论与应用[M]. 北京:国防工业出版社, 1998:51-54
- [6] 周明,孙树栋. 遗传算法原理及应用[M]. 北京:国防工业出版社, 1999:37-38
- [7] 王新苗,晏蒲柳,黄天锡. 多层前项神经网络的自适应遗传算法训练[J]. 武汉大学学报(自然科学版), 1999, **45**(3):363-366
- [8] 王茵,胡昌斌,才华,等. 高速公路沥青路面使用性能综合评价指标的研究[J]. 沈阳建筑工程学院学报, 2000, **16**(4):264-268
- [9] 胡昌斌,邓学钧,谢康和. 沈大高速公路路面使用性能综合评价模型的研究[J]. 公路, 2002(3):1-7
- [10] 李志刚,邓学钧,洪峰. 高速公路沥青路面使用性能评价模型的探讨[J]. 公路交通科技, 2000, **17**(5):15-17

Genetic algorithm-based fuzzy optimization neural network model for pavement performance evaluation

LIU Yan¹, KANG Hai-gui^{*1}, SUN Min²

(1. State Key Laboratory of Coastal and Offshore Engineering, Dalian University of Technology, Dalian 116024, China;

2. Liaoning Province Highway Construction Bureau, Shenyang 110002, China)

Abstract: In order to deal with the deficiency of existing evaluation methods for pavement performance, an intelligent evaluation model based on fuzzy optimization neural network model is proposed, which introduces genetic algorithm. Genetic algorithm is to optimize the connection weights of neural network model to achieve approximate optimal solution. The weights are to be regarded as initial values for next step that neural network is tuned finely further. Fuzzy optimization model is as activation function of neural network, so the model has explicit physical meanings. This model is applied to evaluating pavement performance of some road sections of Shenda expressway, and the comparative analysis with other models shows that the model improves evaluation precision and efficiency, and is practical.

Key words: pavement performance evaluation; fuzzy optimization; neural network; genetic algorithm