

文章编号:1007-9629(2021)03-0630-07

# 基于 DNN 改性沥青中 SBS 含量的预测模型

王志祥<sup>1,2</sup>, 李建阁<sup>1</sup>

(1. 长安大学 公路学院, 陕西 西安 710064; 2. 广东华路交通科技有限公司, 广东 广州 510420)

**摘要:** 为准确预测苯乙烯-丁二烯-苯乙烯嵌段共聚物(SBS)改性沥青中 SBS 的含量,采用傅里叶变换红外光谱(FTIR)采集了不同 SBS 含量改性沥青的 FTIR 图谱,建立了基于深度神经网络(DNN)改性沥青中 SBS 含量的预测模型,并研究了不同因素对模型预测精度的影响,对比评价了模型的预测精度、敏感性及适用性.结果表明:数据的降维、降噪预处理使 SBS 含量预测模型的均方误差降低了 70%;基于 DNN 改性沥青中 SBS 含量预测模型的精度高于标准曲线法和随机森林方法,其对改性沥青中 SBS 含量的预测具有较好的敏感性及适用性.

**关键词:** 道路工程; 傅里叶变换红外光谱; 深度神经网络; 改性沥青; 预测模型; 精度

中图分类号:U416

文献标志码:A

doi:10.3969/j.issn.1007-9629.2021.03.025

## Determination Model of SBS Content in Modified Asphalt Based on DNN

WANG Zhixiang<sup>1,2</sup>, LI Jiange<sup>1</sup>

(1. Highway School, Chang'an University, Xi'an 710064, China;

2. Guangdong Hualu Transportate Technology Co., Ltd., Guangzhou 510420, China)

**Abstract:** In order to determinate the content of styrene butadiene styrene block copolymer(SBS) in SBS modified asphalt accurately, the Fourier transform infrared spectroscopy(FTIR) spectra of modified asphalts containing different SBS contents were collected by using FTIR instrument, and the determination model for SBS content in modified asphalt was established based on deep neural network(DNN). The influences of different factors on the accuracy of the determination model were studied, and the accuracy, susceptibility and applicability of the model were evaluated. The results show that mean square error of the SBS content determination model is reduced by 70% by dimension reduction and noise reduction. Determination accuracy for SBS content in modified asphalt using DNN method compares favourably with that using standard curve method and random forest method. It also has good sensitivity and applicability to determination of SBS content in modified asphalt by the DNN determination model.

**Key words:** road engineering; Fourier transform infrared spectroscopy; depth neural network; modified asphalt; determination model; accuracy

苯乙烯-丁二烯-苯乙烯嵌段共聚物(SBS)改性沥青路面有效减少了车辙、坑槽、裂缝等早期病害的出现<sup>[1-2]</sup>,增加了 1~2 a 使用寿命,提高了服务水平,因此 SBS 改性沥青的研究及应用备受青睐<sup>[3-4]</sup>. SBS 用量的剧增,导致了其价格上涨,以次充好、缺斤短两的现象偶有发生,使改性沥青中 SBS 的含量

及其性能无法保证.传统评价 SBS 含量的方法主要基于改性沥青的储存稳定性,对其针入度、延度、软化点和黏度等物理性能进行测试,但该测试方法耗时长、准确性和重现性较差<sup>[5-6]</sup>;采用荧光显微镜定量检测 SBS 含量,准确性较低<sup>[7]</sup>;化学滴定方法虽然能够测试改性沥青中 SBS 的含量,但耗时长达

收稿日期:2019-11-21; 修订日期:2020-01-08

基金项目:广东省交通运输厅科技项目(科技-2016-02-004)

第一作者:王志祥(1988—),男,河南周口人,长安大学博士生.主要从事道路工程结构与材料性能研究. E-mail:dgxiang2013@163.com

2 h,并且会释放有毒气体,危害试验人员身体健康<sup>[8]</sup>;通过傅里叶变换红外光谱(FTIR)仪测定改性沥青的红外谱图<sup>[9]</sup>,基于特征峰与SBS含量的线性相关性,建立不同SBS含量改性沥青标准曲线,可以测定改性沥青中SBS的含量<sup>[10]</sup>,但是其制样的均匀性难以保证,红外光谱峰的识别与提取、数据处理繁琐且复杂,这给改性沥青中SBS含量的测定带来了困难<sup>[11]</sup>.深度神经网络(DNN)在精准预测方面具有显著优势<sup>[12]</sup>.基于DNN,本文提出了改性沥青中SBS含量的预测模型(DNN模型),旨在精准预测改性沥青中SBS的含量,提升沥青的质量,改善沥青路面的使用品质.

## 1 试验

### 1.1 原材料

沥青采用Shell-70<sup>#</sup>基质沥青(BA),其性能指标见表1.改性剂为韩国LG411星型SBS与LG501线型SBS的混合物,二者掺配比<sup>1)</sup>为1:1;SBS颗粒色泽光亮,粒度均匀,杂质含量较少,无明显黏聚性,其性能指标见表2.根据工程经验,采用工业硫磺稳定剂(用量为沥青质量的2%)增强SBS与沥青之间的黏聚力,确保改性沥青的储存稳定性.

表1 基质沥青的性能指标

Table 1 Performance indexes of base asphalt

Index	Test result	Method
Penetration(25 °C, 5 s, 100 g)/(0.1 mm)	62	ASTM D5
Ductility(5 cm · min <sup>-1</sup> , 10 °C)/cm	42	ASTM D113
Softening point(R&B)/°C	48.5	ASTM D36
Viscosity(60 °C)/(Pa · s)	225	ASTM D4402
Density(15 °C)/(g · cm <sup>-3</sup> )	1.16	ASTM D70

表2 SBS的性能指标

Table 2 Performance indexes of SBS

Index	LG411	LG501
$w(\text{ash})/\%$	0.25	0.28
Tensile strength/MPa	14	16
Elongation at break/%	600	700
Shore hardness/A	78	80
Melt flow rate/(g · min <sup>-1</sup> )	0.04	0.02

### 1.2 FTIR 测试

采用配备ZnSe ATR附件的Controls Cary 630型FTIR,测试温度控制在20 °C左右,光谱范围为4 000~650 cm<sup>-1</sup>,波数精度高于0.005 cm<sup>-1</sup>,扫描次

数为32次,分辨率为4 cm<sup>-1</sup>.

首先通过熔融混合的方法<sup>[13]</sup>制备7种SBS含量( $w_{\text{SBS}}$ )分别为3.0%、3.5%、4.0%、4.5%、5.0%、5.5%和6.0%的SBS改性沥青,试样编号SBS-MA-3.0为 $w_{\text{SBS}}=3.0\%$ 的SBS改性沥青,其他类推.对沥青样品进行FTIR测试,结果见图1.由图1可见,与基质沥青BA相比,966、699 cm<sup>-1</sup>处是SBS改性沥青特征吸收峰,分别对应聚苯乙烯的C=C、聚丁二烯的C=C扭曲振动.966、699 cm<sup>-1</sup>处峰的高度或面积与SBS含量呈正相关关系,这为准确预测改性沥青中SBS的含量提供了重要依据.

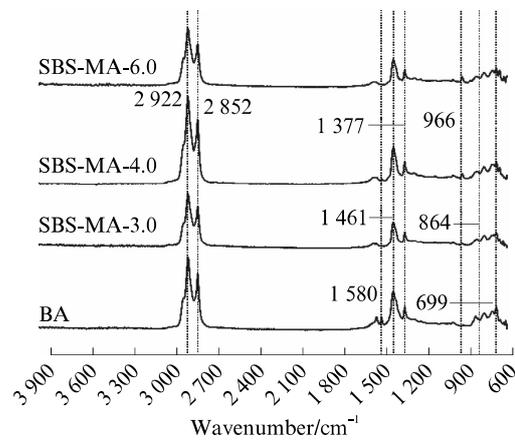


图1 基质沥青及SBS改性沥青的红外光谱图

Fig. 1 FTIR spectra of BA and SBS modified asphalt

## 2 DNN模型的建立

### 2.1 数据预处理

#### 2.1.1 降噪

制备7种SBS改性沥青和1种基质沥青的FTIR测试样品,每种样品30个,共得到240个样本.对其进行FTIR测试,得到240个FTIR图谱特征数据,并进行DNN训练与测试. FTIR图谱采用Savitzky-Golay过滤器进行平滑预处理,减少噪声干扰<sup>[14-15]</sup>,同时对异常光谱进行剔除,得到227个有效FTIR图谱.随机抽取180个有效FTIR图谱作为DNN训练样本,样本编号为1~180,剩余的47个有效FTIR图谱作为DNN测试样本,样本编号为1~47.

#### 2.1.2 降维

每个FTIR图谱均包含900个特征(维度),227个图谱共有227×900个特征.采用奇异值分解算法对特征值数据的主成分进行降维,将输入数据转换

1)文中涉及的比值、用量、含量等均为质量比或质量分数.

成1组线性无关的特征值和相应的特征向量<sup>[16]</sup>.在保留能够代表原始数据95%以上特征的前提下进行降维,最终得到227×512个特征数据.

## 2.2 数据分类

将降噪+降维后的数据作为DNN训练和测试样本的数据库,其样本信息见表3.表3中, $N$ 为数据预处理后的数据数量, $N_{\text{train}}$ 为用来训练的数据数量, $N_{\text{test}}$ 为用来测试的数据数量.

表3 数据库样本信息  
Table 3 Samples information from database

Specimen	$\omega_{\text{SBS}}/\%$	$N_{\text{train}}$	$N_{\text{test}}$	$N$
BA	0	23	6	29
SBS-MA-3.0	3.0	23	6	29
SBS-MA-3.5	3.5	23	6	29
SBS-MA-4.0	4.0	23	6	29
SBS-MA-4.5	4.5	23 <td 6	29	
SBS-MA-5.0	5.0	23	6	29
SBS-MA-5.5	5.5	23	6	29
SBS-MA-6.0	6.0	19	5	24
Total		180	47	227

## 2.3 DNN 结构设计

为保证神经元直接快速并准确传递有效信息,对DNN结构进行设计,建立的DNN结构体系见图2.由图2可见:DNN由输入层、输出层和11个隐藏层组成,隐藏层从第2层到第12层依次排列,以提高学习的深度和模型表达能力;隐藏层神经元节点数分别设置为512、256、256、128、128、64、64、32、32、16和16,以提高计算机的处理效率,加快优化速度;同1层神经元之间没有联系,但它们与下1个相邻层的每个神经元完全相连;将式(1)中SBS改性沥青FTIR数据的特征向量 $\mathbf{X}$ 导入到包含512个神经元的输入层中; $\mathbf{X}_{(k)}$ 为 $\mathbf{X}$ 中的1个元素,为第 $k$ 个样本FTIR数据的特征向量, $k=1,2,3,\dots,m,m$ 为样本数;根据输入值 $\mathbf{X}$ ,由式(3)计算得出SBS含量的输出特征向量 $\mathbf{Y}$ .

$$\mathbf{X} = (\mathbf{X}_{(1)}, \mathbf{X}_{(2)}, \dots, \mathbf{X}_{(k)}, \dots, \mathbf{X}_{(m)})^T \quad (1)$$

$$\mathbf{X}_{(k)} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (2)$$

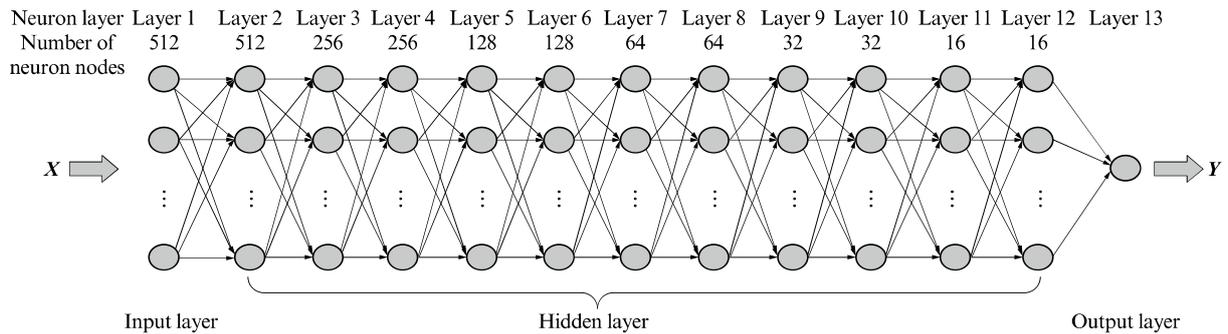


图2 DNN 结构体系  
Fig. 2 Architecture of DNN

$$\mathbf{Y} = f(\mathbf{W}_{ij}^{(l)} \dots f(\mathbf{W}_{ij}^{(2)} f(\mathbf{W}_{ij}^{(1)} \mathbf{X} + \mathbf{b}_{ij}^{(1)}) + \mathbf{b}_{ij}^{(2)}) + \dots + \mathbf{b}_{ij}^{(l)}) \quad (3)$$

$$\mathbf{W}_{ij}^{(l)} = \begin{bmatrix} \mathbf{W}_{i1}^{(l)} & \dots & \mathbf{W}_{ij}^{(l)} \\ \vdots & & \vdots \\ \mathbf{W}_{i1}^{(l)} & \dots & \mathbf{W}_{ij}^{(l)} \end{bmatrix} \quad (4)$$

$$\mathbf{b}_{ij}^{(l)} = \begin{bmatrix} \mathbf{b}_{i1}^{(l)} & \dots & \mathbf{b}_{ij}^{(l)} \\ \vdots & & \vdots \\ \mathbf{b}_{i1}^{(l)} & \dots & \mathbf{b}_{ij}^{(l)} \end{bmatrix} \quad (5)$$

式中: $n$ 为数据维数; $\mathbf{W}_{ij}^{(l)}$ 、 $\mathbf{b}_{ij}^{(l)}$ 分别为从 $l$ 到 $l+1$ 层的权重特征向量、偏差特征向量, $i,j$ 分别为 $l$ 和 $l+1$ 层的第 $i,j$ 个神经元, $l$ 为隐藏层数量, $l=1,2,3,\dots,11$ .

为避免在DNN的反向传播过程中出现梯度消

失现象,提高计算速度和精度,同时降低DNN参数的依赖性与过度拟合的概率,采用ReLU(梯度总是0或1)作为激活函数<sup>[17]</sup>:

$$f(x) = \text{ReLU}(x) = \max(0, x) \quad (6)$$

式中: $x$ 表示输入值; $f(x)$ 表示输出值.

## 2.4 DNN 训练

DNN训练的目的是根据设定模型精度的要求,通过学习不断迭代、更新,以确定其参数( $\mathbf{W}_{ij}^{(l)}$ 、 $\mathbf{b}_{ij}^{(l)}$ ).

### 2.4.1 损失函数

DNN训练通常采用损失函数 $J$ ,使DNN模型输出特征向量 $\mathbf{Y}$ 的预测值与事先已知的用来监督预测模型的并和预测值相对应的真实值 $y$ (目标值)无限接近.用均方误差(MSE)作为损失函数 $J$ ,并以

MSE 作为模型预测精度的评价指标, MSE 值越小, 模型预测精度越高. MSE 的计算公式为:

$$\text{MSE} = J(\mathbf{W}_{ij}^{(l)}, \mathbf{b}_{ij}^{(l)}) = \frac{1}{n} \sum_1^n (\mathbf{Y}-\mathbf{y})^2 \quad (7)$$

#### 2.4.2 学习方法

学习在 DNN 训练中起着关键作用. 学习过程为: 首先将预处理后的数据以矩阵的形式输入到 DNN 中, 进行无监督学习, 该过程为前向传播中的特征学习, 权重和偏差特征向量的初始值用于训练第 1 层并生成用于训练第 2 层的特征向量数据; 依次利用产生的特征向量数据对下 1 层进行训练, 直到最后 1 层完成训练后, 得到各层相应的权重和偏差特征向量数据; 最后对数据标记后进行监督学习, 以调整 DNN 参数的权重和偏差特征向量. 依据损失函数, 采用小批量随机梯度下降法对每次迭代的参数进行更新, 设置 batch size 为 20, 参数更新如式 (8)、(9) 所示.

$$\mathbf{W}_{ij}^{(l+1)} = \mathbf{W}_{ij}^{(l)} - \eta \frac{m_w^{(l)}}{(1-\beta_1) \left( \sqrt{\frac{v_w^{(l)}}{1-\beta_2}} + \epsilon \right)} \quad (8)$$

$$\mathbf{b}_{ij}^{(l+1)} = \mathbf{b}_{ij}^{(l)} - \eta \frac{m_b^{(l)}}{(1-\beta_1) \left( \sqrt{\frac{v_b^{(l)}}{1-\beta_2}} + \epsilon \right)} \quad (9)$$

式中:  $\mathbf{W}_{ij}^{(l+1)}$ 、 $\mathbf{b}_{ij}^{(l+1)}$  分别表示从  $l+1$  到  $l+2$  层的权重特征向量、偏差特征向量;  $m_w^{(l)}$  和  $v_w^{(l)}$  分别为  $\partial J(\mathbf{W}_{ij}^{(l)}, \mathbf{b}_{ij}^{(l)}) / \partial \mathbf{W}_{ij}^{(l)}$  的指数衰减平均值和非中心方差;  $m_b^{(l)}$  和  $v_b^{(l)}$  分别为  $\partial J(\mathbf{W}_{ij}^{(l)}, \mathbf{b}_{ij}^{(l)}) / \partial \mathbf{b}_{ij}^{(l)}$  的指数衰减均值和非中心方差;  $\beta_1$ 、 $\beta_2$ 、 $\epsilon$ 、 $\eta$  为参数, 取值分别为 0.9、0.999 9、 $10^{-8}$  和 0.001.

#### 2.4.3 初始化、规范化和归一化

DNN 训练过程中, 存在发散、过拟合和消失梯度等难题. 为了防止梯度消失现象出现, 采用 Xavier 方法对  $\mathbf{W}_{ij}^{(l)}$  进行初始化.  $\mathbf{W}_{ij}^{(l)}$  服从均匀分布  $U(-r, r)$ ,  $r$  由式 (10) 计算得到.

$$r = \sqrt{\frac{12}{n_{\text{input}} + n_{\text{output}}}} \quad (10)$$

式中:  $n_{\text{input}}$  和  $n_{\text{output}}$  分别为输入、输出层连接的神经元个数.

为了降低 DNN 训练过程中过拟合出现的概率, 常采 dropout 对 DNN 进行规范化, 在每次迭代中, 随机隐藏一半的神经元, 在正向和反向传播中, 隐藏的神经元都不会被激活.

通过批量归一化, 固定输入层数据, 优化求解过程, 确保梯度稳定, 加快收敛速度和学习速度, 防止梯度消失. 特征向量  $\mathbf{X}$  与矩阵特征值  $\mathbf{Z}$  之间的关系为:

$$\mathbf{Z} = \gamma \frac{\mathbf{X} - \mu}{\sqrt{\sigma^2 + \zeta}} + \beta \quad (11)$$

式中:  $\mu$ 、 $\sigma$  分别为特征向量  $\mathbf{X}$  中批量数据的平均值和标准差;  $\gamma$ 、 $\beta$  分别为由 DNN 训练得到的尺度因子和位移因子;  $\zeta$  为平滑因子, 为无穷小的数字, 防止除数为零.

#### 2.4.4 DNN 模型的效率

本文使用的计算机处理器为 Inter(R) core (TM) i7-8700 CPU @ 3.20 GHz, 显卡类型为 Nvidia Geforce GTX 1070 8G GPU. 通过 CPU 加速对 DNN 进行训练, 前向传播学习和后向反馈学习时间分别为 8.22、25.37 s.

#### 2.5 DNN 测试

DNN 测试的目的是分析预测模型准确性. 采用测试样本进行 DNN 测试, 若测试样本的均方误差小于训练样本, 说明模型预测准确性较好; 否则, 应重新调整网络结构及其参数, 直至测试样本的均方误差小于训练样本为止.

### 3 结果与讨论

#### 3.1 数据预处理对 DNN 模型预测精度的影响

其他条件相同, 以 MSE 作为评价指标, 研究了降噪+降维、仅降维、仅降噪 3 种数据预处理对 DNN 模型预测精度的影响, 结果见表 4.

表 4 数据预处理对 DNN 模型预测精度的影响  
Table 4 Effect of data preprocessings on determination accuracy of DNN model

Data preprocessing	MSE
No preprocessing	0.171
Only dimension reduction	0.160
Only noise reduction	0.061
Both noise and dimension reduction	0.057

由表 4 可见, 对比没有经过数据预处理的 DNN 模型预测精度, 仅降维预处理使 MSE 降低了 6% 左右, 而仅降噪预处理使 MSE 降低了 64%, 降维+降噪预处理的综合作用使 MSE 降低了 70%, 因此数据的降维、降噪等预处理对建立较为精确、鲁棒性较好的预测模型有重要的作用.

#### 3.2 迭代次数对 DNN 模型预测精度的影响

对训练样本集设置不同的迭代次数 ( $N_{\text{iter}}$ ), 研究其对模型预测精度的影响, 结果见图 3. 由图 3 可见: 随着训练样本集的迭代次数从 100 次增加到 3 000 次, DNN 模型的 MSE 逐渐减小, 从 3.338 减小到 0.057; 前 1 800 次迭代, MSE 波动较为明显, 单次的迭代不一定使神经网络向目标方向发展, 但

是整体趋向目标,通过反复迭代,调整权重和偏差,使网络逐渐稳定;当迭代次数从1 800次增加到2 100次,MSE缓慢下降,保持稳定在0.057;当迭代次数从2 100次增加到3 000次,MSE呈现小幅度波动.考虑训练速度,迭代次数选择2 100次.

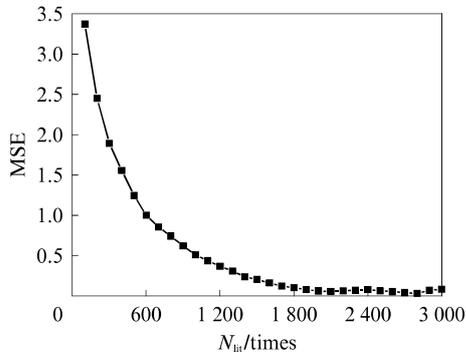


图3 迭代次数对DNN模型预测精度的影响  
Fig. 3 Influence of iteration times on determination accuracy of DNN model

### 3.3 DNN模型预测结果分析

对数据进行降维+降噪处理,迭代次数为2 100次.训练样本与测试样本 $w_{SBS}$ 的预测值(PV)与目标值(TV)见图4、5.由图4可见:训练样本的预测值在目标值附近小幅波动;样本编号为100之前,预测值与目标值基本呈现正偏差状态;样本编号在100之后,预测值与目标值出现负偏差,且呈小幅波动整体稳定状态.由图5可见:测试样本的预测值在目标值附近小幅波动, $w_{SBS}$ 的预测值稳定在目标值附近.

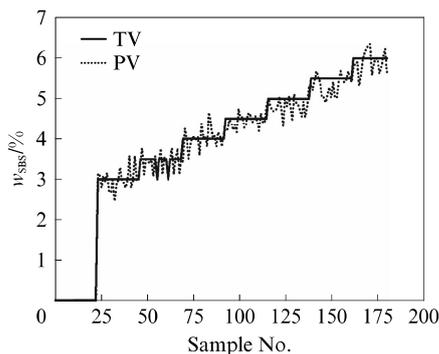


图4 训练样本的预测值与目标值  
Fig. 4 PV and TV of training samples

为进一步评价DNN模型的拟合优度,将训练样本集和测试样本集中SBS改性沥青的 $w_{SBS}$ 预测平均值与目标值进行相关性分析,结果见图6.由图6可见, $w_{SBS}$ 预测值的平均值与目标值相关系数 $R^2$ 达到0.998 9,而测试样本预测值的平均值与目

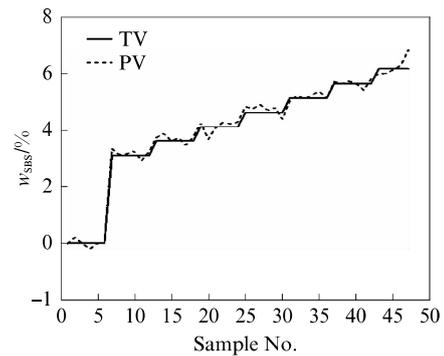


图5 测试样本的预测值与目标值  
Fig. 5 PV and TV of test samples

标值相关性更好, $R^2$ 达到0.999 6,这也说明了DNN模型的准确性和适用性,通过预测平均值的计算,可以使预测值逼近目标值.

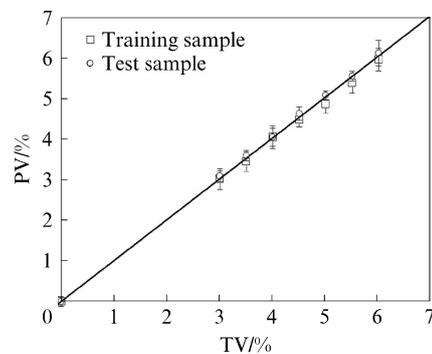


图6 不同SBS含量的预测值的平均值与目标值的相关性分析  
Fig. 6 Correlation Analysis between TV of PV

### 3.4 精度对比分析

采用与DNN模型相同的训练样本集,用传统的SBS特征峰峰面积比标准曲线法(SCM)、随机森林法(RFM)<sup>[18]</sup>分别建立预测模型,并将3种模型的预测平均值与目标值进行线性拟合;选择与训练样本相同数据预处理以及 $w_{SBS}$ 目标值为4.3%、4.7%、5.1%的样本23个,代入3种模型,采用精度(AC)作为指标评价, $\bar{Y}$ 为 $w_{SBS}$ 预测平均值,结果见表5.

$$AC = \left(1 - \frac{|\bar{Y} - y|}{y}\right) \times 100\% \quad (12)$$

由表5可见:DNN模型的预测平均值与目标值线性相关系数 $R^2$ 为0.998 9,模型预测精度优于SCM和RFM模型;对于同一目标值 $w_{SBS} = 4.7\%$ 的样本,RFM模型精度优于SCM模型,而DNN模型具有更高的精度,达到98.756%.一方面,说明了DNN模型可以准确预测不局限于预测模型训练集中的 $w_{SBS}$ (3.0%、3.5%、4.0%、4.5%、5.0%、5.5%、

表 5 3 种预测模型预测精度比较  
Table 5 Comparison of determination accuracy of three determination models

Model	$R^2$	AC/%		
		$w_{SBS}=4.3\%$	$w_{SBS}=4.7\%$	$w_{SBS}=5.1\%$
SCM	0.980 5	93.256	94.365	93.687
RFM	0.975 2	94.556	95.678	94.287
DNN	0.998 9	98.256	98.756	97.689

6.0%),且能预测  $w_{SBS}$  为 3.0%~6.0% 区间任意含量值;另一方面,也说明了 DNN 模型的预测值更逼近目标值, $w_{SBS}$  目标值为 4.3%、5.1% 的样本测试结

表 6 不同改性沥青 SBS 含量结果  
Table 6 SBS content results of different modified asphalt

Result	Shell-70 <sup>#</sup>		SK-70 <sup>#</sup>			IRPC-90 <sup>#</sup>	
	LG411	LG501	$m(LG411) : m(LG501) = 7 : 3$	$m(LG411) : m(LG501) = 3 : 7$	$m(LCY3501) : m(LCY3411) = 1 : 1$	$m(LG411) : m(LG501) = 1 : 1$	$m(LCY3501) : m(LCY3411) = 2 : 1$
$N$	30	30	30	50	50	40	40
TV/%	4.5	4.5	4.8	4.6	4.9	4.0	4.7
$\bar{Y}/\%$	4.43	4.40	4.88	4.66	4.82	4.05	4.62
$ \bar{Y}-y /\%$	0.07	0.10	0.08	0.06	0.08	0.05	0.08
AC/%	98.44	97.78	98.33	98.70	98.37	98.75	98.30

由表 6 可见:DNN 模型能够准确预测不同基质沥青和 SBS 改性沥青中的 SBS 含量,且其预测值与目标值差值均在 0.10% 的范围内,精度最低为 97.78%,最高为 98.75%。由此可见,DNN 模型具有很好的敏感性和适用性,能用于准确预测不同种类的 SBS 改性沥青中 SBS 含量。

## 4 结论

(1)在进行深度神经网络(DNN)训练之前,对数据进行降噪和降维等预处理,可以提高 DNN 模型的预测精度;相比于没有进行数据预处理,经过预处理的 DNN 模型的均方误差 MSE 降低了 70%。

(2)训练样本集的 MSE 值最终保持在 0.057,目标值与预测值接近,DNN 模型具有良好的准确性.DNN 模型对 SBS 改性沥青中 SBS 含量的预测精度在 97% 以上,高于标准曲线法和随机森林法。

(3)基于 DNN 改性沥青中 SBS 含量预测模型对不同基质沥青与 SBS 改性沥青中 SBS 含量预测具有较好的敏感性和适用性。

## 参考文献:

[1] LIANG M, XIN X, FAN W Y, et al. Effects of polymerized sulfur on rheological properties, morphology and stability of SBS modified asphalt[J]. Construction and Building Materi-

als, 2017, 150:860-871.

## 3.5 敏感性与适用性分析

为了验证 DNN 模型的敏感性与适用性,选择不同品牌和标号的基质沥青(Shell-70<sup>#</sup>、韩国 SK-70<sup>#</sup>、新加坡 IRPC-90<sup>#</sup>)、SBS(LG411、LG501、LCY3501、LCY3411)制备不同  $w_{SBS}$  的 SBS 改性沥青,按照本文所述方法测试其 FTIR 图谱,同时用神经网络学习修正的 DNN 模型,对一定数量样本的验证集进行测定及精度评价,结果见表 6。

[2] HUANG W D, TANG N P. Characterizing SBS modified asphalt with sulfur using multiple stress creep recovery test[J]. Construction and Building Materials, 2015, 93:514-521.

[3] YE F, YIN W, LU H. A model for the quantitative relationship between temperature and microstructure of styrene butadiene-styrene modified asphalt[J]. Construction and Building Materials, 2015, 79:397-401.

[4] LIANG M, LIANG P, FAN W Y, et al. Thermo-rheological behavior and compatibility of modified asphalt with various styrene-butadiene structures in SBS copolymers[J]. Materials and Design, 2015, 88:177-185.

[5] ISACSSON U, LU X H. Testing and appraisal of polymer modified road bitumens-state of the art [J]. Materials and Structures, 1995, 28(3):139-159.

[6] LU X H, ISACSSON U, EKBLAD J. Phase separation of SBS polymer modified bitumens[J]. Journal of Materials in Civil Engineering, 1999, 11(1):51-57.

[7] ZHU J Q, LU X H, KRINGGOS N. Experimental investigation on storage stability and phase separation behaviour of polymer-modified bitumen [J]. International Journal of Pavement Engineering, 2018, 19(9):832-841.

[8] NIU Y F, ZHU Z Q, XIAO J Y, et al. Evaluation of storage stability of styrene-butadiene-styrene block copolymer-modified asphalt via electrochemical analysis[J]. Construction and Building Materials, 2016, 107:38-43.

[9] MIRZAIYAN D, AMERI M, AMINI A, et al. Evaluation of the performance and temperature susceptibility of gilsonite-

- and SBS-modified asphalt binders[J]. Construction and Building Materials, 2019, 207: 679-692.
- [10] YAN C Q, HUANG W D, XIAO F P, et al. Proposing a new infrared index quantifying the aging extent of SBS-modified asphalt[J]. Road Materials and Pavement Design, 2018, 19(6): 1406-1421.
- [11] 王康. 红外光谱结合神经网络测定改性沥青 SBS 含量[J]. 化学研究与应用, 2018, 30(12): 1938-1942.  
WANG Kang. Determination of SBS content in modified asphalt by infrared spectroscopy combined with neural network[J]. Chemical Research and Application, 2018, 30(12): 1938-1942. (in Chinese)
- [12] AZEEZ O S, PRADHAN B, SHAFRI H Z M, et al. Modeling of CO emissions from traffic vehicles using artificial neural networks[J]. Applied Sciences, 2019, 9(2): 313.
- [13] 张帆, 李三喜, 李旭日, 等. SBS 改性沥青的制备与性能[J]. 沈阳化工大学学报, 2003(1): 25-28.  
ZHANG Fan, LI Sanxi, LI Xuri, et al. Preparation and properties of SBS modified asphalt[J]. Journal of Shenyang University of Chemical Technology, 2003(1): 25-28. (in Chinese)
- [14] FENG Z G, WANG S J, WANG H J, et al. FTIR and rheology analysis of aging on different ultraviolet absorber modified bitumens[J]. Construction and Building Materials, 2016, 115: 48-53.
- [15] LEE D, KIM J, LEE D. Robust concrete crack detection using deep learning-based semantic segmentation[J]. International Journal of Aeronautical and Space Sciences, 2019, 20: 287-299.
- [16] 朱尔一, 王小华, 杭纬. 一种三维矩阵的奇异值分解算法[J]. 光谱学与光谱分析, 2015, 35(3): 587-590.  
ZHU Eryi, WANG Xiaohua, HANG Wei. A singular value decomposition algorithm for three-dimensional matrix[J]. Spectroscopy and Spectral Analysis, 2015, 35(3): 587-590. (in Chinese)
- [17] 邢安昊, 张鹏远, 潘接林, 等. 基 SVD 的 DNN 裁剪方法和重训练[J]. 清华大学学报(自然科学版), 2016, 56(7): 772-776.  
XING Anhao, ZHANG Pengyuan, PAN Jielin, et al. DNN cutting method and retraining based on SVD[J]. Journal of Tsinghua University(Natural Science), 2016, 56(7): 772-776. (in Chinese)
- [18] 莫非凡, 范伟, 周冀衡, 等. 基于近红外光谱和随机森林方法鉴别蜂蜜真伪[J]. 食品安全质量检测学报, 2014(8): 2430-2434.  
MO Feifan, FAN Wei, ZHOU Jiheng, et al. Identification of honey based on near infrared spectroscopy and random forest method[J]. Journal of Food Safety and Quality Inspection, 2014(8): 2430-2434. (in Chinese)