http://pmse.scu.edu.cn

基于机器学习数据驱动的热塑性硫化胶力学性能影响机理

李淳孝[1]，马丽凤[1,2]

（1. 上海工程技术大学 机械与汽车工程学院，上海 201620；2. 四川大学 高分子科学与工程学院，四川 成都 610041）

摘要：文中对热塑性硫化胶（TPV）的力学性能进行了深入研究，以解决其相对于传统硫化橡胶存在的弹性问题。TPV以其突出的可回收性和优良的回弹性在材料科学领域具有独特的优势，然而相对于橡胶仍面临弹性不足的问题。文中提出了一种综合的研究方法，即集成代表性体积单元（RVE）模型和机器学习方法，用以全面研究TPV的力学响应。应用支持向量机（SVM）、卷积神经网络（CNN）和随机森林算法（RF）等机器学习模型对TPV的力学性能进行预测，并验证了模型的准确性。通过重要性分析和特征相关性分析，揭示了聚丙烯（PP）和三元乙丙橡胶（EPDM）的弹性模量比对TPV性能的重要影响，并提出了相应的调节理论。该研究对于理解和预测TPV材料性能有重要意义，为材料设计和工程应用提供了深刻见解。

关键词：热塑性硫化胶；代表性体积单元模型；机器学习；力学性能

中图分类号：TQ330.1 **文献标识码：**A **文章编号：**1000-7555（2025）05-0131-09

热塑性硫化胶（TPV）是一类独特的材料，结合了硫化橡胶和塑料的优点[1~3]。其热塑性加工能力使其适用于各种制造工艺，同时保持硫化橡胶的弹性和弯曲性能。TPV可采用热塑性塑料加工设备进行加工，具有加工成本低，可连续塑性生产的优点，其常温时具有橡胶的高弹性，享有“绿色橡胶”之称。良好的弹性和柔韧性使TPV在材料科学领域具有独特的优势，是理想的弹性材料选择。

近年来，伴随着产业的不断升级，人们在实现高性能TPV方面做出了重大努力。通常，最常用的策略是改变橡胶和塑料的类别，以获得具有所需性能的TPV，如全生物基TPV、耐油TPV、耐高温TPV等[4~6]。然而，TPV作为传统硫化橡胶的替代品，仍存在一个极其重要的瓶颈问题，即TPV的弹性不如传统硫化橡胶。如何提高TPV的回弹性，进而实现TPV在工业领域中更广泛的应用已成为TPV研究的重难点。

代表性体积单元（RVE）模型是一种用于模拟材料微观结构和研究其力学行为的方法[7,8]。RVE模型能有效地捕捉TPV的微观结构特征，为其复杂的力学行为提供详细和准确的描述。到目前为止，研究人员已经付出了一些努力来建立TPV的RVE模型来进行数值模拟[9]。

机器学习是人工智能领域的一个重要分支，它探讨如何通过计算机系统学习数据的模式和规律。通过让计算机系统自动从数据中学习并改进，实现对复杂问题的解决和预测能力。通过处理大量的实验数据和复杂的非线性关系，可全面增强对TPV材料行为的理解。目前，许多学者已经使用机器学习方法来解决材料中的非线性问题并预测材料特性[10]。

受TPV、RVE模型和机器学习方法发展趋势的启发，本文开发了一种新的方法来研究TPV的力学性能及其影响机制。通过集成RVE模型和机器学习算法，在微观和宏观层面上全面研究TPV的力学响应变得可行。RVE模型有助于深入了解微观结构，

doi: 10.16865/j.cnki.1000-7555.2025.0072
收稿日期：2024-04-25
基金项目：国家自然科学基金资助项目（51903150）；上海学术/技术研究带头人项目（21XD1401100）
通讯联系人：马丽凤，主要从事新能源/智能汽车功能材料的结构设计、算法优化、仿真分析研究，E-mail: ma.lifeng-scu@foxmail.com

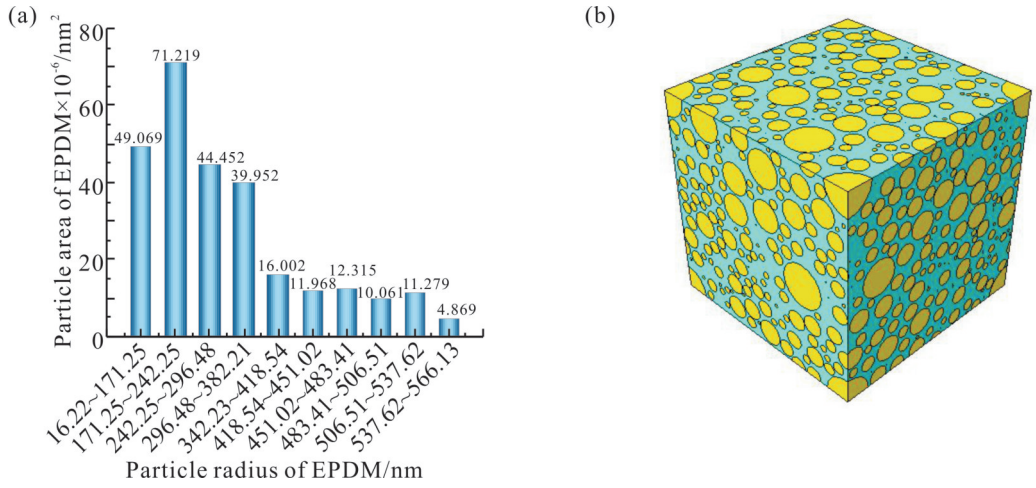


Fig. 1 (a) EPDM particle size distribution law in TPV and (b) RVE model of TPV

而数据驱动的机器学习算法增强了宏观力学行为的预测速度。这种综合方法能够使研究人员更全面、准确地了解和预测TPV材料的复杂力学性能，为材料设计和工程应用提供深刻见解。

1 RVE模型与数据集

1.1 RVE模型

从细观结构出发，根据细观表征数据统计结果，使用蒙特卡罗模拟方法，生成三元乙丙橡胶(EPDM)/聚丙烯(PP)基TPV的周期性代表性体元模型[11,12]，如Fig.1所示。其中，EPDM粒子粒径范围为16.22~566.13 nm[13]。

模型采用节点到节点的周期性条件，在这种条件下，变形的边界表面不再保持平面。这些周期性条件的实现涉及连接节点自由度（DoF），基于周期性RVE的均匀化概念[14]，如式(1~4)所示。

$$X_{\text{Front}} - X_{\text{Back}} = \text{Assigned value} \tag{1}$$

$$X_{\text{Top,Left}} - X_{\text{Bottom,Right}} = 0 \tag{2}$$

$$Y_{\text{Top, Front, Left}} - Y_{\text{Bottom, Back, Right}} = 0 \tag{3}$$

$$Z_{\text{Front, Top, Left}} - Y_{\text{Back, Bottom, Right}} = 0 \tag{4}$$

式中：X，Y和Z——分别为沿X，Y，Z方向的位移分量，指定的值是预先记录的位移值。

1.2 EPDM与PP相本构模型

1.2.1 EPDM超弹性本构模型：EPDM相使用Neo-Hookean模型，该模型用于描述橡胶等非线性弹性材料行为的简化框架[15]。它建立在胡克定律的基础上，是常用超弹性模型中最简单的形式之一，有效地表达了本文EPDM的超弹性力学行为。该模型中弹性应变能量密度势的表达式如式(5)所示

$$W(\lambda) = \frac{\boldsymbol{\mu}}{2}\left(\bar{I}_1 - 3\right) - \frac{K}{2}(\boldsymbol{J} - 1)^2 \tag{5}$$

式中：$W(\lambda)$——应变能密度，J/m³；$\boldsymbol{\mu}$——剪切模量，Pa；$\bar{I}_1$——主应变的迹；K——体积模量，Pa；$\boldsymbol{J}$——变形梯度的雅可比行列式；λ——拉伸比。

根据弹性理论，材料的应力可以通过应变能密度函数对应的应变张量导数来计算。对于Neo-Hookean模型，应力张量的表达式为

$$\sigma_{\text{ij}} = 2\frac{\partial W}{\partial \varepsilon_{\text{ij}}} = \mu\left(\delta_{\text{ij}} - \frac{1}{3}\bar{I}_1\delta_{\text{ij}}\right) + \lambda \ln\left(J\right)J^{-1}\delta_{\text{ij}} \tag{6}$$

式中：σ_{ij}——应力张量，Pa。

1.2.2 PP弹塑性本构模型：PP基体表现出典型的弹塑性特性，并根据塑性增量J_2理论[13]被表征为各向同性硬化弹塑性材料。在这个模型中，应力的计算取决于屈服条件和流动规则。材料的屈服函数通常使用von Mises屈服条件来定义，其表达式为

$$f = \sqrt{\frac{3}{2}}\sigma_{\text{eq}} - \sigma_{\text{y}} \tag{7}$$

式中：σ_{eq}——等效应力(单位Pa)，可以通过应力张量的主应力或Hastelloy应力公式计算得到；σ_{y}——屈服强度，Pa。

根据材料的屈服函数，通过解方程$f = 0$计算材料的应力状态。塑性应变一般分解为两部分——体积变形和非体积变形，增量形式中常用的塑性应变张量表达式为

$$\varepsilon_{ij}^{p}=\varepsilon_{ij}-\frac{1}{3}\varepsilon_{kk}\delta_{ij}-\frac{1}{2}\dot{\gamma}\left(\frac{\partial f}{\partial\sigma_{ij}}\right) \tag{8}$$

式中：ε_{ij}——总应变张量；ε_{kk}——体积应变；δ_{ij}——张量积；$\dot{\gamma}$——等效塑性应变速率，s^{-1}。

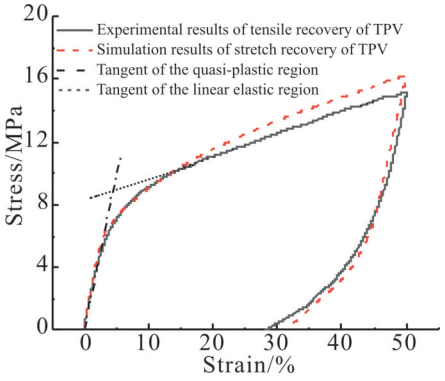


Fig. 2　Calibration of stress-strain curve data in TPV experiment and simulation

1.3　RVE模型计算结果与数据集

据实验与仿真所得的拉伸回复应力-应变曲线如Fig.2所示，显然TPV表现为近似弹塑性的拉伸行为（并不是简单的弹塑性），因此，为了方便计算和使用应力-应变曲线，本文假设拉伸过程的线弹性区域切线和类塑性区域切线为其弹性模量和塑性模量，拉伸到50%时的应力为其拉伸强度，材料回弹应变与拉伸总应变的比值为回弹率。

根据PP的力学特性[9]，改变其弹性模量E、塑性模量E_p和屈服应变，并进行有限元计算获取113组样本数据。根据EPDM相的力学特性[9]，改变其弹性模量E，并进行有限元计算获取38组样本数据。将以上共计151组样本数据作为样本集用以训练机器学习模型。

2　机器学习模型构建与重要性分析

2.1　机器学习模型

2.1.1　*支持向量机*：支持向量机（SVM）是一种强大的监督学习算法，用于分类和回归任务。它在处理线性和非线性数据上都表现出色，是机器学习中常用的模型之一。SVM的基本原理是找到一个最优的超平面，将不同类别的数据点分开。这个最优的超平面被称为决策边界。SVM的目标是最大化间隔，即2个不同类别的样本点距离决策边界的距离。

对于非线性可分的数据集，SVM通过引入核函数将原始特征映射到更高维的特征空间中，从而在高维空间中找到一个能够线性分隔样本的超平面。其核函数为

$$K(x,x')=\phi(x)^{T}\phi(x') \tag{9}$$

式中：$K(x,x')$——核函数；$\phi(x)$——将输入特征向量x映射到高维特征空间的函数。通过对原始问题进行对偶化，可以得到一个更容易求解的优化问题。对偶问题的目标函数

$$\text{minimize}_{\alpha}\frac{1}{2}\sum_{i=1}^{n}\sum_{j=1}^{n}\alpha_i\alpha_j y_i y_j K(x_i,x_j)-\sum_{i=1}^{n}\alpha_i \tag{10}$$

对偶问题的约束条件：

$$\sum_{i=1}^{n}\alpha_i y_i=0$$
$$0\leqslant\alpha_i\leqslant C,i=1,2,\cdots,n \tag{11}$$

式中：α_i——拉格朗日乘子，是惩罚参数。

2.1.2　*卷积神经网络*：卷积神经网络（CNN）是一种深度学习模型，主要通过卷积层、池化层和全连接层等组件对数据进行特征提取和分类。卷积层的作用是提取输入数据中的特征，其公式如式(12)所示

$$(f*g)(x,y)=\sum_i\sum_j f(i,j)\cdot g(x-i,y-j) \tag{12}$$

假设有1个包含N个样本的数据集，每个样本包含1个输入特征向量X和1个目标值y，CNN模型的输出$f(X)$可以表示为

$$f(X)=w_1h_1+w_2h_2+\cdots+w_nh_n+b \tag{13}$$

式中：h_i——卷积层或池化层的输出特征图；w_i——全连接层的权重参数；b——偏置项；N——样本数量。

在用于解决回归问题时，CNN通常会在输出层使用一个线性激活函数（如恒等函数），以输出连续的数值而不是类别。

2.1.3　*随机森林算法*：随机森林(RF)算法是一种基于集成学习的方法[16]，它是以决策树为基础的估计器。通过构建多个决策树，然后结合它们的预测结果来进行分类或回归。

随机森林算法采用Bagging思想来构建多个决策树[17]。在构建每个决策树时，随机森林会对原始数据集进行自助采样，得到一个新的训练集。然后，针对这个新的训练集，随机森林会构建一个决策树，但在每个节点的分裂过程中，会进一步引入随机性。分裂标准使用信息增益方法，其计算公式如下：

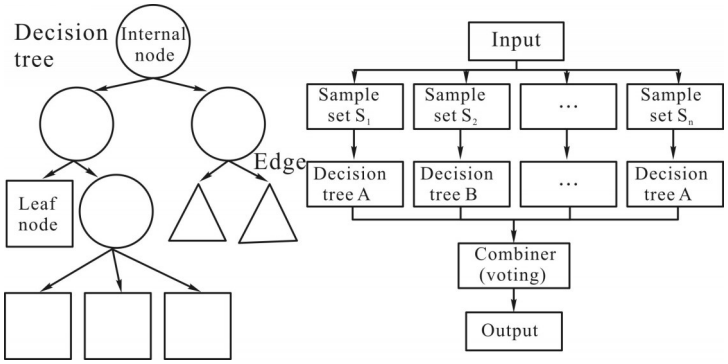


Fig. 3 Construction process of RF algorithm

$$\mathrm{IG}\left(D_{\mathrm{p}},f_{\mathrm{l}}\right)=I\left(D_{\mathrm{p}}\right)-\sum_{\mathrm{j}=1}^{\mathrm{m}}\frac{N_{\mathrm{j}}}{N_{\mathrm{p}}}I\left(D_{\mathrm{j}}\right) \tag{14}$$

式中：$\mathrm{IG}(D_{\mathrm{p}},f_{\mathrm{l}})$——特征$f_{\mathrm{l}}$的信息增益；$I(D_{\mathrm{p}})$——父节点$p$的信息熵；$N_{\mathrm{p}}$——父节点的样本数量；$m$——特征$f_{\mathrm{l}}$的取值个数；$D_{\mathrm{j}}$——特征$f_{\mathrm{l}}$取值为$j$的子节点；$N_{\mathrm{j}}$——子节点$j$的样本数量；$I(D_{\mathrm{j}})$——子节点$j$的信息熵。

这种随机性体现在2个方面。(1)随机特征选择：在每个节点的分裂过程中，不是使用所有特征来选择最优分裂特征，而是从所有特征中随机选择一部分特征进行评估，然后选择最优的分裂特征。这样做的目的是增加每棵树之间的差异性，提高整体模型的多样性。(2)随机样本选择：在构建每棵树时，不仅对特征进行随机选择，还对样本进行随机选择。这意味着每棵树都是在一个随机抽样的训练子集上进行训练，而不是使用原始的全部训练集，进一步增加了模型的多样性。

众多决策树构成了随机森林，每棵决策树都会有一个投票结果，最终投票结果最多的类别，就是最终的模型预测结果，*RF*算法模型如Fig.3所示。

2.2 模型准确性验证

TPV及其组成材料的力学性能均呈现较强的非线性关系。以聚丙烯的弹性模量、屈服应变和塑性模量，三元乙丙橡胶的弹性模量为输入参数，以TPV在50%应变下的弹性模量、塑性模量和回弹性为输出参数，建立TPV的力学机器学习模型。通过决定系数(R^2)和平均绝对百分比误差(MAPE)对模型进行有效性验证。回归模型对样本数据的拟合好坏用决定系数检验，数值越接近于1表明拟合效果越好；平均绝对百分比误差是预测值与实际值之间的差值，其数值与模型的精度成反比。决定系数、平均绝对百分比误差的计算公式分别为

$$R^2=1-\frac{SS_{\mathrm{res}}}{SS_{\mathrm{tot}}} \tag{15}$$

$$S_{\mathrm{MAPE}}=\frac{1}{n}\sum_{\mathrm{i}=1}^{\mathrm{n}}\left|\frac{\sigma_{\mathrm{i}}^{\mathrm{S}}-\sigma_{\mathrm{i}}^{\mathrm{T}}}{\sigma_{\mathrm{i}}^{\mathrm{T}}}\right| \tag{16}$$

式中：SS_{res}——残差平方和，表示模型预测值与实际观测值之间的差异；SS_{tot}——总平方和，表示观测值与其均值之间的差异；$\sigma_{\mathrm{i}}^{\mathrm{S}}$——真实的目标值；$\sigma_{\mathrm{i}}^{\mathrm{T}}$——模型预测的目标值。

Tab. 1 Error result -TPV elastic modulus

Prediction model	R^2	S_{MAPE}
SVM	0.979	0.118
CNN	0.911	0.125
RF	0.999	0.033

Tab. 2 Error results-TPV plastic modulus

Prediction model	R^2	S_{MAPE}
SVM	0.837	0.197
CNN	0.899	0.140
RF	0.963	0.021

Tab. 3 Error results - TPV rebound ratio

Prediction model	R^2	S_{MAPE}
SVM	0.579	0.137
CNN	0.383	0.108
RF	0.961	0.015

3种算法在预测TPV弹性模量、塑性模量和回弹率时的误差结果如Tab.1，Tab.2和Tab.3所示。其中RF算法3组数据的R^2值均超过0.96，表明RF算法模型在预测TPV的各力学性能方面具有良好的准确

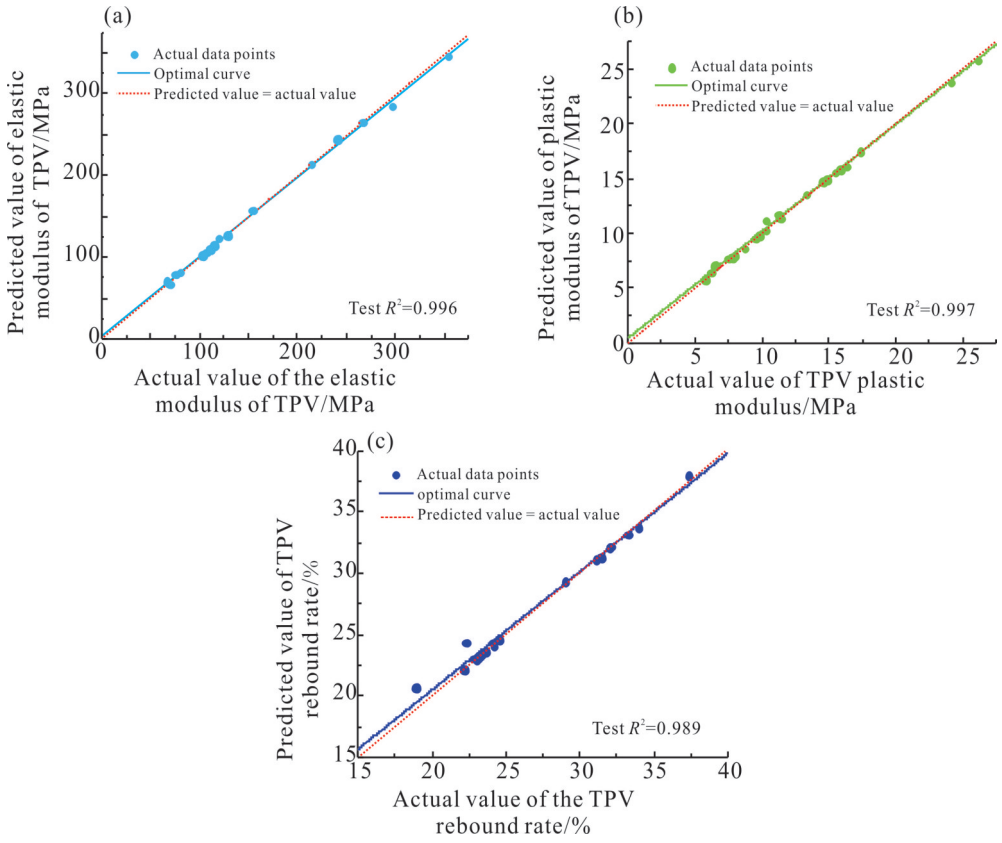


Fig. 4 Joint scatter plot of actual and predicted (a) elastic modulus, (b) plastic modulus, and (c) resilience of TPV

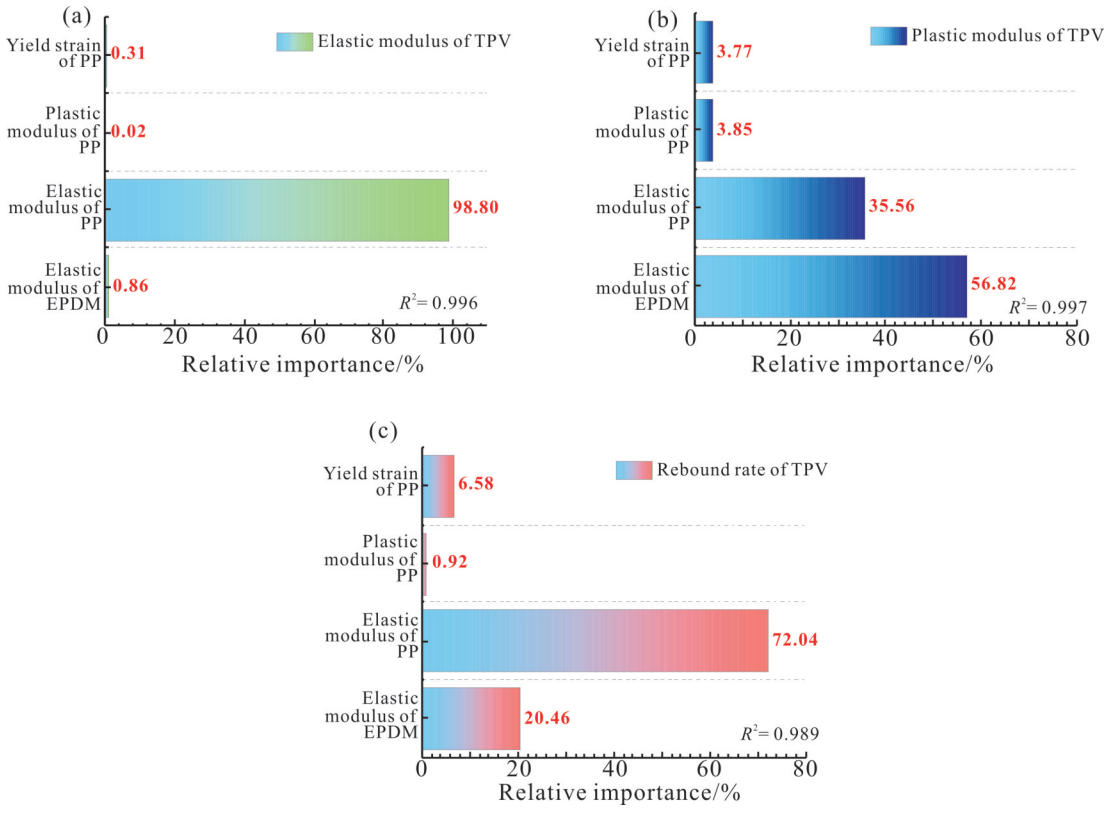


Fig. 5 Importance of different variables on the (a) elastic modulus, (b) plastic modulus, and (c) resilience of TPV

性。TPV有限元结果和*RF*预测值的联合散点图如Fig.4所示。

2.3 TPV力学性能影响因素及其重要性分析

重要性分析是通过衡量每个特征对模型性能的贡献程度来实现的。随机森林中的重要性分析通常基于以下2种方法——不纯度减少和特征排列重要性。其中特征排列重要性方法通过对数据中的每个特征进行随机排列，然后观察模型性能的变化情况来衡量特征的重要性。如果某个特征对模型的性能有显著影响，那么在对该特征进行随机排列后，模型性能会明显下降，根据性能下降的程度可以评估特征的重要性。相对于不纯度减少方法该方法更为准确和可靠，它更好地考虑到了特征之间的交互作用和非线性关系，因此适用于分析TPV的非线性力学性能，不同变量对TPV的拉伸、弹性和回弹性能的重要性如Fig.5所示。

重要性分析表明，PP的弹性模量是影响TPV弹性模量的最大影响因素，如Fig.5(a)所示。连续的PP基体作为TPV的骨架，提供主要强度，并显著提高TPV的拉伸模量。

影响TPV塑性模量的因素的重要性如Fig.5(b)所示。PP和EPDM的弹性模量是2个最关键的因素。TPV的塑性行为是一种广义塑性，表现出类似于PP塑性的力学拉伸曲线。然而，在恢复过程中，它并没有表现为完全塑性，TPV的弹性远远超过其在屈服点之前的弹性行为。这种行为归因于TPV独特的“海岛”结构。TPV显示的塑性模量是PP和EPDM力学性能的组合，在达到屈服点后，TPV微观结构中PP相的主要承载部分已进入屈服阶段，逐渐开始塑性变形。同时，EPDM相保持其弹性变形能力。因此，TPV的塑性模量由PP的塑性模量和EPDM的弹性模量组成。

在TPV塑性模量的重要性分析中，PP和EPDM的弹性模量占据主导地位，这是由于在拉伸变形过程中TPV两相之间的应力传递关系。当PP相的弹性模量增加时，TPV在大变形下达到相同应变所需的应变能增加，导致TPV表现出更高的塑性模量。

PP和EPDM的弹性模量及PP的屈服应变是影响TPV回弹性的3个关键因素，如Fig.5(c)所示。其中，PP和EPDM的弹性模量是主要影响因素。PP相作为TPV中的基质网络，赋予了TPV良好的热塑性。然而，这也使得实现类似于橡胶材料的良好回弹性具有挑战性。另一方面，EPDM相是TPV中良好弹性的主要来源，能在材料内产生动态力学平衡。随着PP弹性模量的增加，这种平衡被破坏，使其表现出更多的永久性变形。因此，PP和EPDM弹性模量的大小，或两者的应变能状态，决定了TPV的内部平衡，导致更多塑性或更多弹性行为。

3 特征相关性分析

3.1 TPV重要特征与力学属性相关性分析

基于重要性分析的结果，选择了对TPV各种力学性能影响最大的因素生成了二变量部分依赖图，如Fig.6所示。

Fig.6(a)说明了TPV弹性模量随PP和EPDM弹性模量变化的分布趋势。聚丙烯弹性模量的影响占主导地位，呈现非线性趋势，随着PP弹性模量的增加，TPV的弹性模量增加。

对于TPV的塑性模量，主要影响因素同样为PP和EPDM的弹性模量，如Fig.6(b)所示。TPV的塑性模量随着PP和EPDM弹性模量的增加而成比例的增加。

影响TPV回弹性的主要因素有PP和EPDM的弹性模量，以及PP的屈服应变。考虑到PP和EPDM弹性模量之间应变能的动态平衡，将PP与EPDM弹性模量的比值合并为一个影响因素，将PP的屈服应变视为另一个因素，生成的二变量部分依赖图如Fig.6(c)所示。随着PP与EPDM弹性模量之比的增加，TPV弹性降低，永久变形程度增加。同时，随着PP塑性应变增加，在高模量比的区域，TPV的回弹性提高。然而，在模量比较小的区域，TPV弹性不会随着PP塑性应变的变化而发生显著变化。这归因于EPDM的弹性能力在模量比较小的区域占主导地位，在该区域，应变能逐渐从PP相转移到EPDM相。

3.2 TPV回弹性重要影响因素与控制机制

Fig.5(c)中重要性分析结果表明，PP和EPDM的弹性模量对TPV回弹率的相对重要性分别为72.04%和20.46%，是橡塑材料属性中对TPV回弹性影响最大的主要因素。因此，选择PP和EPDM的弹性模量之比作为研究TPV弹性的变量，得出了如

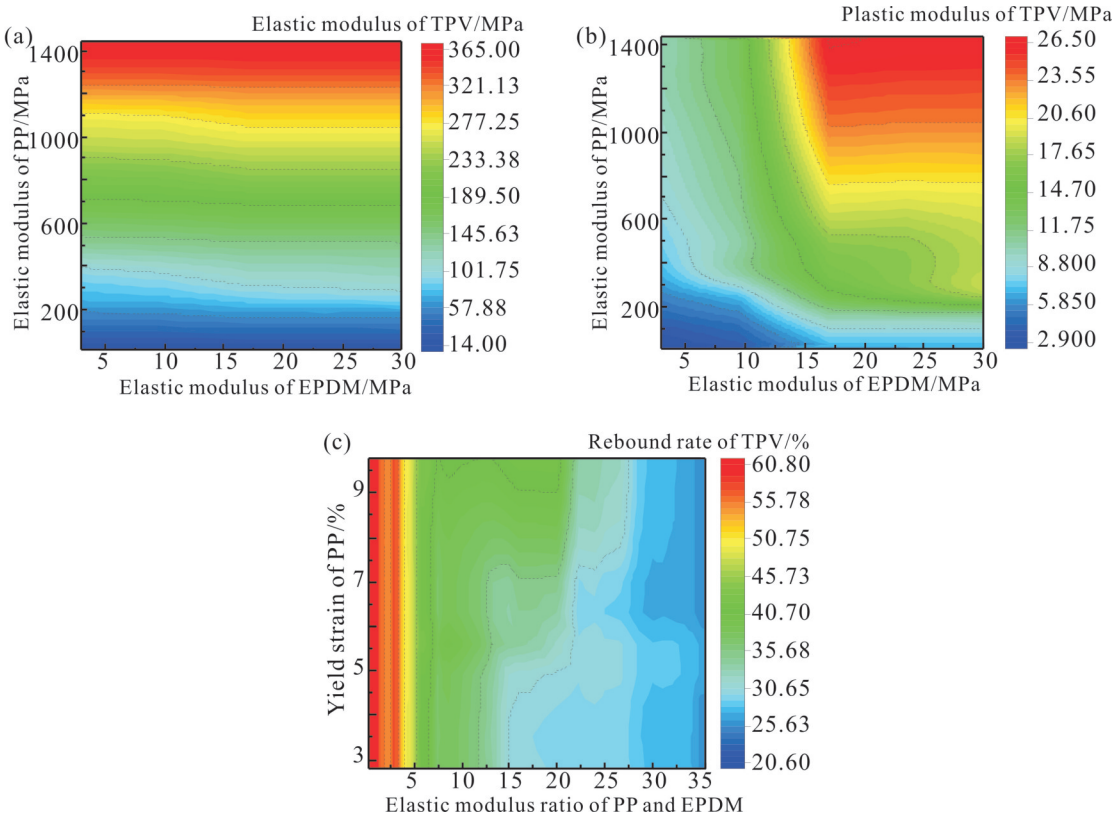


Fig. 6 Binary partial correlation diagram of important features on the (a) elastic modulus, (b) plastic modulus, and (c) resilience of TPV

Fig.7所示的结果。随着模量比的增加,TPV弹性表现出非线性下降,模量比越高,弹性越小。

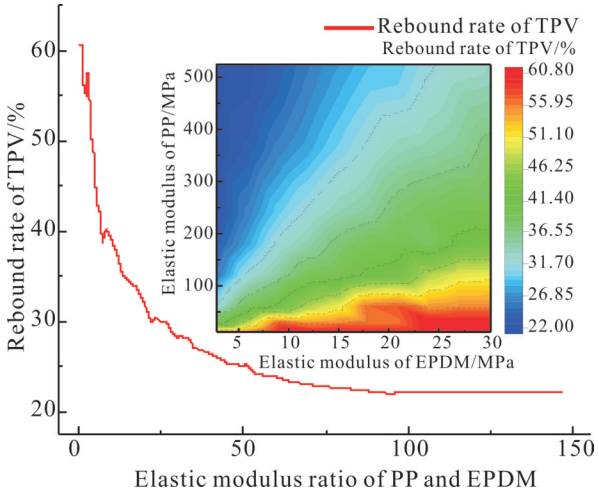


Fig. 7 Effect of elastic modulus ratio of PP and EPDM on TPV rebound rate

在合理范围内,将弹性比进一步划分为2个独立的模量,并生成二元部分依赖图。根据能量守恒原理,2种模量与它们各自对TPV弹性的贡献呈准线性关系。PP和EPDM作为弹性模量可控的TPV基体材料[18~20],调节它们的模量比将是一种提高TPV回弹性及其他力学性能的有效手段。

4　结论

本文提出了一种综合的研究方法,即集成代表性体积单元(RVE)模型和机器学习方法,以数据驱动的方式全面研究了TPV的力学响应。应用支持向量机(SVM)、卷积神经网络(CNN)和随机森林算法(RF)等机器学习模型对TPV的力学性能进行了预测,并验证了模型的准确性。通过重要性分析和特征相关性分析,揭示了PP和EPDM的弹性模量对TPV性能的重要影响,并提出了相应的调节理论。该研究对于理解和预测TPV材料性能具有重要意义,可为材料设计和工程应用提供有益的指导。

参考文献:

[1] Xu X, Ma L, Guo H, *et al.* A predictive model for the relationship between processing conditions and properties of thermoplastic vulcanizates (TPVs) via machine learning[J]. Composites Science

and Technology, 2023, 240: 110095.

[2] Jiang C, Ma L. Polyamide 6 - based thermoplastic vulcanizate for thermostability: an experimental and theoretical investigation[J]. Journal of Applied Polymer Science, 2022, 139: 51718.

[3] Liu H, Wang F, Wu W, *et al.* 4D printing of mechanically robust PLA/TPU/Fe_3O_4 magneto-responsive shape memory polymers for smart structures[J]. Composites Part B: Engineering, 2023, 248: 110382.

[4] Xu X, Ma L, Liu C. Bio - based polylactic acid or epoxy natural rubber thermoplastic vulcanizates with dual interfacial compatibilization networks[J]. Polymer Engineering & Science, 2022, 62: 1987-1998.

[5] Ning N, Hua Y, Wu H, *et al*. Novel heat and oil- resistant thermoplastic vulcanizates based on ethylene-vinyl acetate rubber/ poly(vinylidene fluoride) [J]. RSC Advances, 2016, 6: 91594-91602.

[6] Cui Z, Jing Y, Wang L, *et al*. Thermoplastic vulcanizates with an integration of good mechanical performance and excellent resistance to high temperature and oil based on HNBR/TPEE[J]. Polymers for Advanced Technologies, 2023, 34: 1143-1153.

[7] Boyce C M, Socrate S, Kear K, *et al*. Micromechanisms of deformation and recovery in thermoplastic vulcanizates[J]. Journal of the Mechanics and Physics of Solids, 2001, 49: 1323-1342.

[8] Mao W, Yang F, Jin Z, *et al.* Experimental study and model on the low- cycle fatigue behavior of thermoplastic vulcanizates[J]. Fatigue & Fracture of Engineering Materials & Structures, 2023, 46: 2539-2550.

[9] Ma L, Li C, Liu C. Construct the relationship of the interface structure- properties for TPV via micromechanical method based on cohesive zone model[J]. Polymer, 2023, 286: 126348.

[10] He Z, Zhou W. Development of machine learning- based burst capacity models for pipelines containing dent- gouges with synthetic full- scale burst test data generated using tabular generative adversarial network[J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108090.

[11] Verho T, Fortino S, Hradil P, *et al*. Biocomposite modeling by tomographic feature extraction and synthetic microstructure reconstruction[J]. Composites Science and Technology, 2022, 230: 109713.

[12] Tian W, Chao X, Fu M W, *et al.* An algorithm for generation of RVEs of composites with high particle volume fractions[J]. Composites Science and Technology, 2021, 207: 108714.

[13] Liu C, Ma L, He C, *et al.* Prediction of comprehensive mechanical properties of thermoplastic vulcanizate (TPV) with various composition ratios based on a micromechanical method [J]. Modern Physics Letters B, 2023, 37: 2250230.

[14] Bonora N, Ruggiero A. Micromechanical modeling of composites with mechanical interface - part II: damage mechanics assessment[J]. Composites Science and Technology, 2006, 66: 323-332.

[15] Shariyat M, Khani Arani H. Dynamic behavior of heterogeneous neo- Hookean/Mooney- Rivlin plates reinforced nonuniformly by hyperelastic inclusions: proposing the correct micromechanical model[J]. Journal of Vibration and Control, 2023, 29: 1626-1643.

[16] Wang N, Song J, Sun S, *et al.* Immune signatures predict response to house dust mite subcutaneous immunotherapy in patients with allergic rhinitis[J]. Allergy, 2024, 79: 1230-1241.

[17] Li A, Xu H, Feng C, *et al.* Incomplete multi- view clustering via local and global bagging of anchor graphs[J]. Expert Systems with Applications, 2024, 248: 123402.

[18] Shen Y, Tian H, Pan W, *et al.* Unexpected improvement of both mechanical strength and elasticity of EPDM/PP thermoplastic vulcanizates by introducing β- nucleating agents[J]. Macromolecules, 2021, 54: 2835-2843.

[19] Luo F, Wang J, Bai H, *et al.* Synergistic toughening of polypropylene random copolymer at low temperature: β- modification and annealing[J]. Materials Science and Engineering: A, 2011, 528: 7052-7059.

[20] Chen G, Vahidifar A, Yu S, *et al*. Optimization of silane modification and moisture curing for EPDM toward improved physicomechanical properties[J]. Reactive and Functional Polymers, 2023, 182: 105467.

Mechanism of Influence on Mechanical Properties of Thermoplastic Vulcanizates Based on Machine Learning Data

Chunxiao Li[1], Lifeng Ma[1,2]

(*1. School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. College of Materials Science and Engineering, Sichuan University, Chengdu 610041, China*)

ABSTRACT: This paper delved into the mechanical properties of thermoplastic vulcanizates (TPV) to address the issue of elasticity compared to traditional vulcanized rubber. TPV possesses unique advantages in the field of materials science due to its outstanding recyclability and excellent resilience, yet it still faces challenges regarding insufficient elasticity compared to rubber. This study proposed a comprehensive research approach by integrating representative volume element (RVE) models and machine learning methods to comprehensively investigate the mechanical response of TPV. Machine learning models such as support vector machine (SVM), convolutional neural networks (CNN), and random forest algorithm (RF) were applied to predict the mechanical properties of TPV, and the accuracy of the models was validated. Through importance analysis and feature correlation analysis, the significant influence of the elastic modulus ratio of PP and EPDM on the performance of TPV was revealed, along with corresponding adjustment theories. This research holds significant importance for understanding and predicting the properties of TPV material, providing profound insights for material design and engineering applications.

Keywords: thermoplastic vulcanized rubber; representative volume element models; machine learning; mechanical properties