

中南林业科技大学学报

Journal of Central South University of Forestry & Technology

ISSN 1673-923X，CN 43-1470/S

《中南林业科技大学学报》2026年第10期

Doi:10.14067/j.cnki.1673-923X.2026.10.021

论文标题： 基于SAE的跨树种木材密度NIR模型传递

作　　者： 李易伟，齐源达，陈承武，等

收稿日期： 2025-10-30

引文格式： 李易伟,齐源达,陈承武,等.基于SAE的跨树种木材密度NIR模型传递[J].中南林业科技大学学报,2026,46(10):231-243.

Li Y W, Qi Y D, Chen C W, et al. NIR model transfer for wood density across tree species based on stacked autoencoder[J]. Journal of Central South University of Forestry & Technology,2026, 46(10):231-243.

相关论文推荐

Recommended articles

樟子松木材密度的近红外光谱特征提取最优算法及预测模型研究

Research on the optimal algorithm for near-infrared spectral feature extraction and prediction model of *Pinus sylvestris* wood density

基于LSTM长短期记忆网络的樟子松木材气干密度NIRS模型预测

NIRS model prediction of air-dry density of *Pinus sylvestris* wood based on long short- term memory network (LSTM)

基于近红外光谱波段优选的针叶木材基本密度估测模型的优化研究

Estimation of softwood basic density based on near infrared spectral bands optimal selection

基于近红外的木屑含水率定量检测

Modeling moisture content of sawdust based on NIRS

基于不同预处理的椴树木材基本密度近红外光谱估测及模型优化

Near infrared spectral estimation and model optimization of *Tilia tuan* based on different pretreatments

基于光谱预处理的低温水曲柳原木含水率检测

Moisture content detection of *Fraxinus mandshurica* logs at low temperatures based on different spectrum pretreatments

Doi:10.14067/j.cnki.1673-923x.2026.10.021
http: //qks.csuft.edu.cn

基于 SAE 的跨树种木材密度 NIR 模型传递

李易伟，齐源达，陈承武，覃子健，孙　超，孙　皓，李耀翔
（东北林业大学 机电工程学院，黑龙江 哈尔滨 150040）

摘　要：【目的】木材密度作为木材品质评价的核心参数，在木材交易和木材加工中受到重点关注。开发高效无损的跨树种木材密度检测技术对林业资源开发和木材高效利用具有重要意义。【方法】以东北地区典型硬阔胡桃楸 *Juglans mandshurica* 和水曲柳 *Fraxinus mandshurica* 为研究对象，构建跨树种木材密度近红外光谱传递模型。通过稳定预测特征选择算法（SPFS）得到各个波段的得分排序，基于肘部法则确定波段数目并选出共同波段，引入堆栈自编码器（SAE）作为特征转换机制，结合人工 BP 神经网络预测模型构建跨树种光谱模型传递新方法。【结果】胡桃楸模型经过 SAE 传递后，水曲柳预测集决定系数 R^2 从 0.172 7 提高到 0.827 1，预测集均方根误差 RMSEP 从 0.180 1 下降到 0.049 3 g/cm^3；水曲柳模型经 SAE 传递后，胡桃楸预测集决定系数 R^2 从 0.000 9 提高到 0.884 9，RMSEP 从 0.187 8 下降到 0.032 9 g/cm^3。与传统方法分段直接校正和斜率 / 截距校正算法相比，SAE 在 R^2 与 RMSEP 指标上都有大幅度的提升。【结论】基于 SAE 的近红外传递模型可以实现不同树种木材密度的快速高效预测，实现模型在不同树种间的共享，为近红外模型的普适性提供了理论基础与技术支撑。

关键词：堆栈自编码器；人工 BP 神经网络；稳定预测特征选择；木材密度
中图分类号：S781.31　　**文献标志码：**A　　**文章编号：**1673-923X(2026)10-0231-13

NIR model transfer for wood density across tree species based on stacked autoencoder

Li Yiwei, Qi Yuanda, Chen Chengwu, Qin Zijian, Sun Chao, Sun Hao, Li Yaoxiang

(College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, Heilongjiang, China)

Abstract:【Objective】Wood density, as a key parameter for evaluating wood quality, is a focal point in both wood trading and processing. The development of efficient, non-destructive, and cross-species detection technologies for wood density is of great importance for the exploitation of forestry resources and the efficient utilization of wood.【Method】This study selected two typical hardwood species from northeast China, specifically Manchurian walnut (*Juglans mandshurica*) and Manchurian ash (*Fraxinus mandshurica*), as research subjects to establish a near-infrared (NIR) spectral transfer model for cross-species wood density prediction. A stable predictive feature selection (SPFS) algorithm was designed to score and rank spectral bands. The elbow method was applied to determine the optimal number of bands and to select common feature bands. A stacked autoencoder (SAE) was introduced as a feature transformation mechanism. Combined with an artificial backpropagation (BP) neural network prediction model, a new cross-species spectral model transfer method was constructed.【Result】Following the transfer of the *Juglans mandshurica* model based on SAE, the coefficient of determination (R^2) for the *Fraxinus mandshurica* prediction set rose from 0.172 7 to 0.827 1, and its root mean square error of prediction (RMSEP) fell from 0.180 1 to 0.049 3 g/cm^3. In the opposite transfer direction, applying SAE to the *Fraxinus mandshurica* model improved the R^2 for the *Juglans mandshurica* prediction set from 0.000 9 to 0.884 9, and reduced the RMSEP from 0.187 8 to 0.032 9 g/cm^3. These results indicate that the SAE-based method achieves substantial improvements in both R^2 and RMSEP metrics when compared to traditional techniques such as piecewise direct standardization and slope/bias correction algorithms.【Conclusion】The findings of this study demonstrate that the SAE-based NIR transfer model is effective for cross-species applications, allowing for the rapid and efficient prediction of wood density in different tree species. This approach promotes model sharing across species and offers both a theoretical basis and technical support for improving the universality of NIR models.

Keywords: stacked autoencoder; artificial BP neural network; stable predictive feature selection; wood density

收稿日期（Received）：2025-10-30　　**修订日期**（Revised）：2026-01-04
基金项目：国家重点研发计划项目（2024YFD220070406）。
第一作者：李易伟（liyiwei@nefu.edu.cn），硕士研究生。
通信作者：李耀翔（yaoxiangli@nefu.edu.cn），教授，博士，博士研究生导师。
引文格式：李易伟 , 齐源达 , 陈承武 , 等 . 基于 SAE 的跨树种木材密度 NIR 模型传递 [J]. 中南林业科技大学学报 ,2026,46(10):231-243.
Li Y W, Qi Y D, Chen C W, et al. NIR model transfer for wood density across tree species based on stacked autoencoder[J]. Journal of Central South University of Forestry & Technology,2026,46(10):231-243.

木材密度可以反映木材的干缩性、抗压抗拉强度等物理力学性质，是判断木材加工价值与工艺需求的重要依据，是提高木材利用率中应重点研究的木材材性之一，快速准确预测木材密度对于木材精细化分类及高效利用具有重要意义。

近红外（Near Infrared，NIR）光谱技术是一种绿色、简单、快速的新型分析技术，被广泛应用于各个领域，包括食品、农业、制药、生物医学、石化等。然而，近红外模型的泛化能力较差，使得模型的普适性大大受限。试验结果表明，校正模型在跨树种应用中存在显著局限性，可能导致实验结果产生较大偏差。近红外光谱模型传递技术通过数学变换消除仪器间的响应差异，其核心原理在于建立主从设备光谱空间的映射关系 [1]。传统方法以直接标准化（Direct standardization，DS）和分段直接标准化（Piecewise direct standardization，PDS）为主导，通过分段波长校正实现模型传递 [2]，但存在标准样品依赖性强、复杂基质适应性不足等缺陷 [3-4]。

随着深度学习技术的不断发展，其在木材领域的应用也日益广泛。很多研究团队对模型传递算法进行了大量创新性研究，刘翠玲等 [5] 开发的 TrAdaBoost 算法通过自适应权重调整提升跨设备知识迁移效率；王红鸿等 [6] 提出二进制蜻蜓算法搭配直接校正耦合策略，将小麦粉蛋白质模型的传递误差降低至 1.8%；傅鹏有 [7] 构建的深度特征提取网络实现了 92.7% 的跨设备识别准确率，与 Mishra 等 [8] 提出的深度校准迁移框架形成方法学互补。

当前研究主要聚焦三大方向：1）无标样传递技术，如张站鸽等 [3] 开发的 MC-UVE-VIP 两步波长筛选法；2）特征波长优选策略，如洪士军等 [4] 基于尺度不变特征变换的稳定波长筛选法使模型稳健性提升 23%；3）智能算法融合，如 Zhang 等 [9] 开发的稳定性分析特征选择算法对主从仪器的共同波长进行优化，降低了数据维数，提高了传统校准传递算法的预测性和效率。刘智健等 [10] 提出的 DS-PDS 联用技术使木质素模型决定系数提升 0.15；王红鸿等 [11] 提出的 SWCSS-DS 算法在纸浆材综纤维素传递中表现出最优稳健性。与此同时，跨树种光谱适配 [12]、水产品新鲜度检测 [13] 等复杂的模型传递场景仍面临特征漂移等挑战，这为新一代模型传递算法的研发提供了重要方向。近红外光谱技术在不同树种密度之间的模型传递研究对于提高模型适用性和准确性、促进林业资源高效利用、推动林业科学研究和技术创新，以及为林业可持续发展提供支撑等具有重要意义。

近年来，在深度学习领域，自编码器（Autoencoder，AE）通过无监督的编码 - 解码机制实现了数据特征的高效提取与重构，其核心优势在于通过隐层空间对输入数据进行压缩表征，从而捕获数据内在的非线性特征。各种类型的 AE，如去噪自编码器（Denoising autoencoder，DAE）、变分自编码器（Variational autoencoder，VAE）和生成对抗网络（Generative adversarial network，GAN）等，已被成功应用于图像处理、语音识别和自然语言处理等领域，取得了显著的成果。堆栈自编码器（Stacked autoencoder，SAE）通过分层堆叠多个 AE 模块，进一步构建了深度层次化特征表示，这种逐层抽象的学习方式使模型具备更强的特征泛化能力。在模型可传递性方面，SAE 的预训练 - 微调范式为跨领域知识传递提供了理论依据：模型通过大规模源域数据预训练获得通用特征提取能力后，可通过少量目标域数据的微调实现参数传递，有效缓解光谱数据标注成本高、样本量不足的问题。在 NIR 光谱分析场景中，AE/SAE 的降噪重构特性可有效应对光谱信号的高维性、共线性和噪声干扰。已有研究表明，通过预训练的 SAE 模型可以对目标域数据集进行有效预测，在保持预测精度的同时显著减少目标域建模所需数据量 [3]，这为构建跨场景、跨仪器的普适性光谱分析模型提供了可行路径。

本研究针对东北地区典型硬阔胡桃楸 *Juglans mandshurica* 与水曲柳 *Fraxinus mandshurica* 近红外光谱（Near infrared spectroscopy，NIRS）密度预测模型跨树种传递中的光谱分布偏移问题，提出一种基于 SAE 的模型传递方法。通过融合非线性特征映射与直接校正策略，解决模型无法在树种之间进行传递的问题，提升跨树种模型传递的预测精度（R^2/RMSEP）与泛化能力。通过与传统算法 PDS、斜率 / 截距校正（Slope/bias correction，SBC）算法对比，突出基于 SAE 在解决模型传递问题上的独特优势。

1 材料与方法

1.1 材料制备与光谱采集

胡桃楸和水曲柳样品均采自吉林省白山市靖宇县景山实验林场（126°37′ ～ 127°00′ E，42°29′ ～ 42°40′ N）。在林地中选取 8 株标准木，

以 1 m 为间隔，沿树干方向向上截取厚度为 5 cm 的圆盘，共获取 89 个胡桃楸圆盘和 83 个水曲柳圆盘。分别按 3∶1 的比例，随机抽取 66 个胡桃楸圆盘作为校正集、23 个作为预测集。62 个水曲柳圆盘作为校正集，21 个作为预测集。

采用美国 ASD 公司生产的 LabSpec® Pro FR/A114260 便携式光谱扫描仪，在样品采伐当天基于全波段光谱范围，用强光探头对胡桃楸和水曲柳圆盘进行近红外光谱采集，光谱范围 350 ～ 2 500 nm，每 1 nm 记录 1 个信息点。样品连续扫描 30 次后自动生成 1 个光谱，每个圆盘采集光谱 3 次，保证 3 个光斑尽可能覆盖圆盘全部面积，从而确保光谱的全面性和真实性，最后取平均光谱作为该样本的最终光谱信息。

本试验研究的是木材气干密度，测定方法参考国家标准采用排水法，试验原理和步骤参考《无疵小试样木材物理力学性质试验方法第 5 部分：密度测定》[14]，木材气干密度统计信息见表 1。

表 1　胡桃楸和水曲柳木材气干密度统计值

Table 1　Statistics of air-dried density of *Juglans mandshurica* and *Fraxinus mandshurica* wood

树种 Tree species	样本集 Sample set	样本数 Number of samples / 个	最大值 Maximum value /(g·cm^{-3})	最小值 Minimum value /(g·cm^{-3})	平均值 Mean value /(g·cm^{-3})	标准差 Standard deviation
胡桃楸 *Juglans mandshurica*	校正集	66	1.033 8	0.541 6	0.760 2	0.087 5
	验证集	23	1.049 4	0.584 2	0.792 4	0.096 5
水曲柳 *Fraxinus mandshurica*	校正集	62	1.350 5	0.473 6	0.945 1	0.121 2
	验证集	21	1.043 2	0.646 3	0.938 4	0.086 9

1.2　木材 NIR 光谱数据预处理

木材 NIR 光谱数据在采集过程中不可避免地会受到仪器噪声、基线漂移、光散射效应等干扰因素的影响。为提升模型的预测性能与稳健性，在建立胡桃楸和水曲柳样本的定量分析模型前，需对其原始 NIR 光谱数据进行预处理。

采用 5 种预处理方法及其组合：Savitzky-Golay 卷积平滑（Savitzky-Golay smoothing，SGS）[15]、标准正态变量变换（Standard normal variate transformation，SNV）、SGS 结合去趋势化处理（SGS+DT）、多元散射校正（Multiplicative scatter correction，MSC）[16] 以及 SGS 结合 SNV（SGS+SNV）[17]，所有预处理操作均在 Python 环境中实现。为评价不同预处理方法的效果，后续统一采用偏最小二乘回归（Partial least squares regression，PLSR）方法建立校正模型并比较其性能。

1.3　木材 NIR 光谱波段优选

本研究分别对胡桃楸和水曲柳木材 NIR 光谱进行竞争性自适应加权采样算法（Competitive adaptive reweighted sampling，CARS）选择特征波段之后取选择波段的交集，在选择的波段上分别进行重新建模讨论；将胡桃楸和水曲柳数据混合起来进行 CARS；稳定预测特征选择算法（Stable predictive feature selection，SPFS），并搭配直接确定法、交叉验证、肘部法则法、信息熵法确定选择的波段数目等 6 种波段优选算法来选择 NIR 光谱的共同波段。评价模型选择偏最小二乘回归、支持向量回归（Support vector regression，SVR）、人工 BP 神经网络模型。

CARS 算法是一种有效的变量选择方法，尤其适用于化学光谱分析领域，能够显著提高化学光谱分析的准确性和鲁棒性 [18]。肘部法则是一种在聚类分析中用于确定最佳聚类数量的常用方法，通过绘制成本函数与聚类数量关系的曲线，寻找曲线上的“肘部”位置，从而优化聚类算法的参数选择 [19]。

SPFS 算法是一种结合稳定性分析和预测性能评估的波段优选方法，该算法的设计灵感来源于 Luai Al-Shalabi 的基于稳定性和相关性的新型特征选择算法 [20]，并结合 Welch’s t 检验光谱与密度的相关系数，以实现更有效的特征排序和选择。图 1 为针对胡桃楸和水曲柳波段优选的 SPFS 算法的步骤。

1.4　胡桃楸和水曲柳木材密度 NIR 预测模型的构建

采用人工 BP 神经网络从输入数据中提取特征，并构建密度预测模型。对于胡桃楸和水曲柳木材密度预测，深度学习模型可以表示为：

$$\hat{y} = f(X;\theta) \tag{1}$$

式中：X 是输入的近红外光谱数据；θ 是模型参数；$\hat{y}$ 是预测的树木的密度。用于预测模型的神经网络由 1 个输入层，5 个全连接层，4 个 dropout 层，1 个输出层组成，全连接层的输出维度分别为 512、256、128、32、1，Dropout 层中的损失率均为 0.2。使用 Sigmoid 为激活函数，模型训练时，

批量大小设置为 1，迭代次数为 8 000，早停次数为 1 000。选择 Adam 优化器、平滑 L1 损失（MSE）作为损失函数进行训练。初始学习率（Learning-rate）为 0.000 1，迭代次数为 8 000。设置损失下降作为早停的次数增加条件，当损失连续下降 1 000 次时，无论是否达到迭代次数都中止训练，本研究设计的 BP 神经网络定量训练模型如图 2 所示。

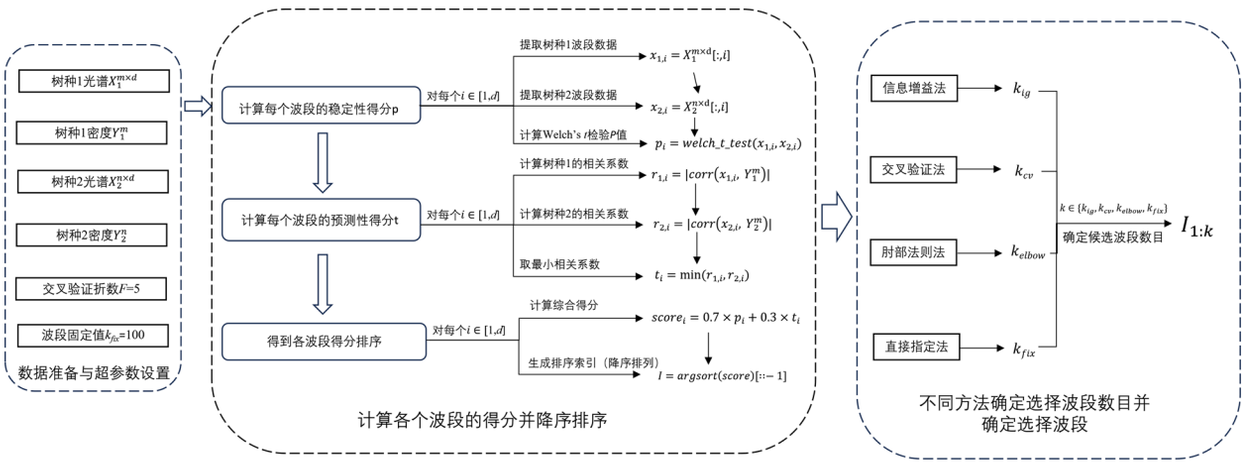


图 1 SPFS 波段选择算法详细步骤

Fig. 1 The steps of the SPFS band selection algorithm

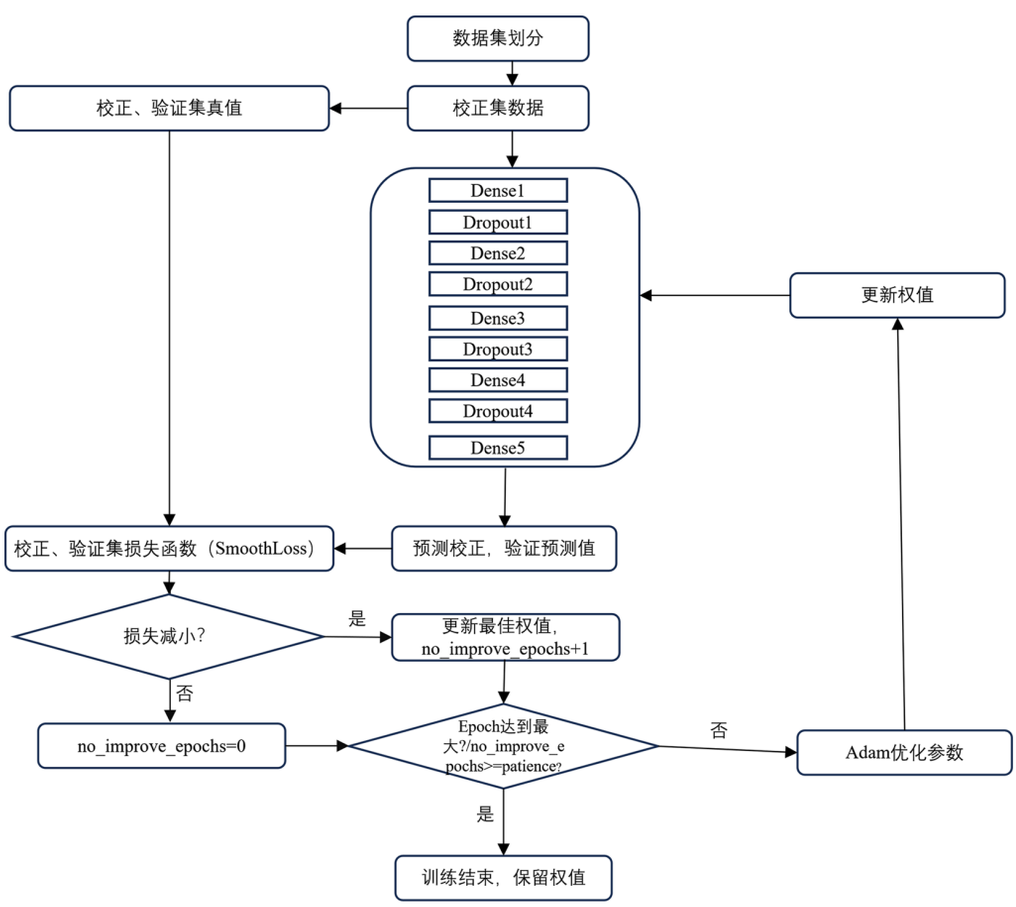


图 2 BP 神经网络预测算法流程

Fig. 2 Process of BP neural network prediction

1.5 基于 SAE 的木材密度近红外传递模型的构建

SAE 是一种深度学习模型，通过堆叠多个自编码器（Autoencoder，AE）层来学习输入数据的高阶抽象表示 [21-22]。本研究选用自编码器作为特征转换器使用，堆栈自编码器的结构可以表示为：

$$h^{(l)} = \sigma(W^{(l)} h^{(l-1)} + b^{(l)}) \quad (2)$$

$$\hat{h}^{(l-1)} = \sigma(W'^{(l)}h^{(l)} + b'^{(l)}) \quad (3)$$

式中：$h^{(l)}$ 是第 l 层的隐藏表示；$W^{(l)}$ 和 $b^{(l)}$ 是第 l 层的权重和偏置；σ 是激活函数。

SAE 可以作为特征提取器，将原始数据转换为更具代表性和区分性的特征表示。在迁移学习中，可以在源域上训练一个 SAE，然后将学习到的 SAE 结构（包括权重）迁移到目标域，作为目标域模型的特征提取层 [23]。由于 SAE 学习到的特征是通用的，因此即使源域和目标域的数据分布不同，迁移后的 SAE 仍然可以提取有用的特征 [24]。

本研究中，SAE 由 6 个线性层组成，每个线性层的输出维度分别为 512、256、128、128、256、512，层与层之间的激活函数选用修正线性单元（ReLU）。在 SAE 源域提取特征之后，将 SAE 部分编码解码器用作源域和目标域的特征转换器，提出基于 SAE 和人工 BP 神经网络的校准传递新方法。具体步骤如图 3 所示（以胡桃楸木材密度到水曲柳木材密度的传递为例），保持训练好的胡桃楸预测模型权重不动，SAE 置于输入光谱和模型之间，以水曲柳的 NIR 光谱作为输入数据，密度值作为输出数据，训练 SAE 使胡桃楸木材密度 NIR 模型可以适配水曲柳的数据集，反向传递亦然。

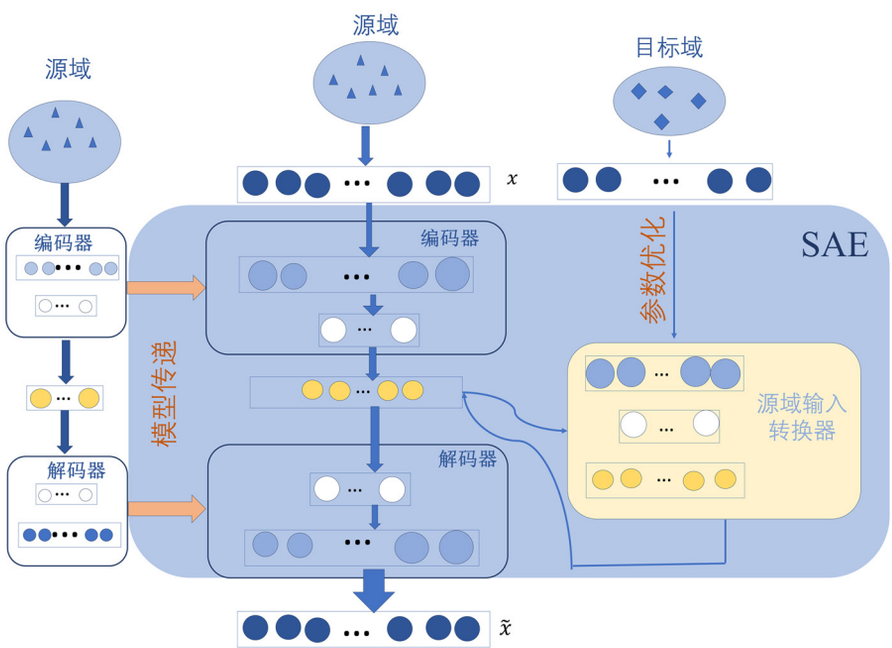


图 3　SAE 用于模型的传递示意
Fig. 3　Schematic diagram of SAE used for model transfer

1.6　对比模型的建立

本研究选择偏最小二乘回归和支持向量回归建立木材密度 NIR 预测模型，PDS 和 SBC 作为模型传递算法为参考，构造了 PLSR+PDS、PLSR+SBC、SVR+PDS 三种方法对胡桃楸和水曲柳 NIR 密度的双向传递进行数据分析。

PLSR 是一种多变量回归方法，适用于样本数量较少时的高维回归模型 [25]；SVR 是一种基于支持向量机的回归方法，能够处理非线性关系，保证模型的泛化能力 [26]；PDS 是一种光谱校正方法，在建立通用的近红外光谱分析模型时非常有用，可以提高模型在不同的仪器上的适用性 [27]；SBC 是另一种光谱校正方法。用于消除光谱数据中的线性漂移和偏差，提高模型的稳定性和准确性 [28]。

模型评价标准用于衡量模型在测试集上的性能。在本研究中，采用决定系数（R^2）、均方误差（RMSEP）等评价标准来评估对木材密度预测的精度，计算公式见参考文献 [29]。

2　结果与分析

2.1　光谱预处理对木材密度 NIR 模型精度的影响

基于 5 种预处理方法处理后的 NIR 光谱数据，建立胡桃楸和水曲柳木材密度的 PLSR 近红外预测模型（表 2），探讨不同预处理方法对木材近红外模型预测精度的影响。

表 2 基于不同预处理方法的模型的胡桃楸和水曲柳木材密度 PLS 预测模型 †

Table 2 PLS prediction model of *Juglans mandshurica* and *Fraxinus mandshurica* wood density based on different preprocessing methods

树种 Tree species	预处理方式 Pretreatment method	主成分数 / 个 No. of principal component	校正集 Calibration set		预测集 Prediction set	
			决定系数 R^2	校正集均方根误差 RMSEC	决定系数 R^2	预测集均方根误差 RMSEP
胡桃楸 *Juglans mandshurica*	None	7	0.781 2	0.043 4	0.700 7	0.045 6
	MSC	7	0.913 2	0.027 3	0.532 4	0.056 9
	SGS+SNV	**7**	**0.790 4**	**0.041 8**	**0.788 3**	**0.041 0**
	SGS	5	0.723 9	0.048 8	0.550 1	0.055 9
	SGS+DT	6	0.805 5	0.040 9	0.469 7	0.060 7
	SNV	5	0.696 5	0.051 2	0.565 9	0.054 9
水曲柳 *Fraxinus mandshurica*	None	7	0.691 3	0.064 1	0.672 5	0.059 9
	MSC	14	0.985 0	0.014 1	0.622 8	0.064 2
	SGS+SNV	**11**	**0.890 5**	**0.038 2**	**0.651 8**	**0.061 7**
	SGS	9	0.686 4	0.064 6	0.636 8	0.063 0
	SGS+DT	4	0.605 3	0.072 5	0.564 1	0.069 1
	SNV	7	0.755 2	0.057 1	0.597 4	0.066 3

† 加粗字体数据为最优模型的评价参数，下同。The bolded data is the optimal model evaluation parameter, the same below.

综合分析胡桃楸与水曲柳木材密度 NIR 模型在校正集和预测集的性能指标（R^2 与 RMSEP）可知，经 SGS+SNV 预处理后，胡桃楸木材密度的 PLS 模型预测精度显著提升（R^2=0.788 3，RMSEP=0.041 0），为最优预处理方案；水曲柳虽同样以 SGS+SNV 效果最佳，但其预测精度较胡桃楸有所降低。为解析不同预处理对光谱特征关联性的影响，进一步对比 2 个树种 SGS+SNV 处理前后的同步二维相关光谱（图 4）。

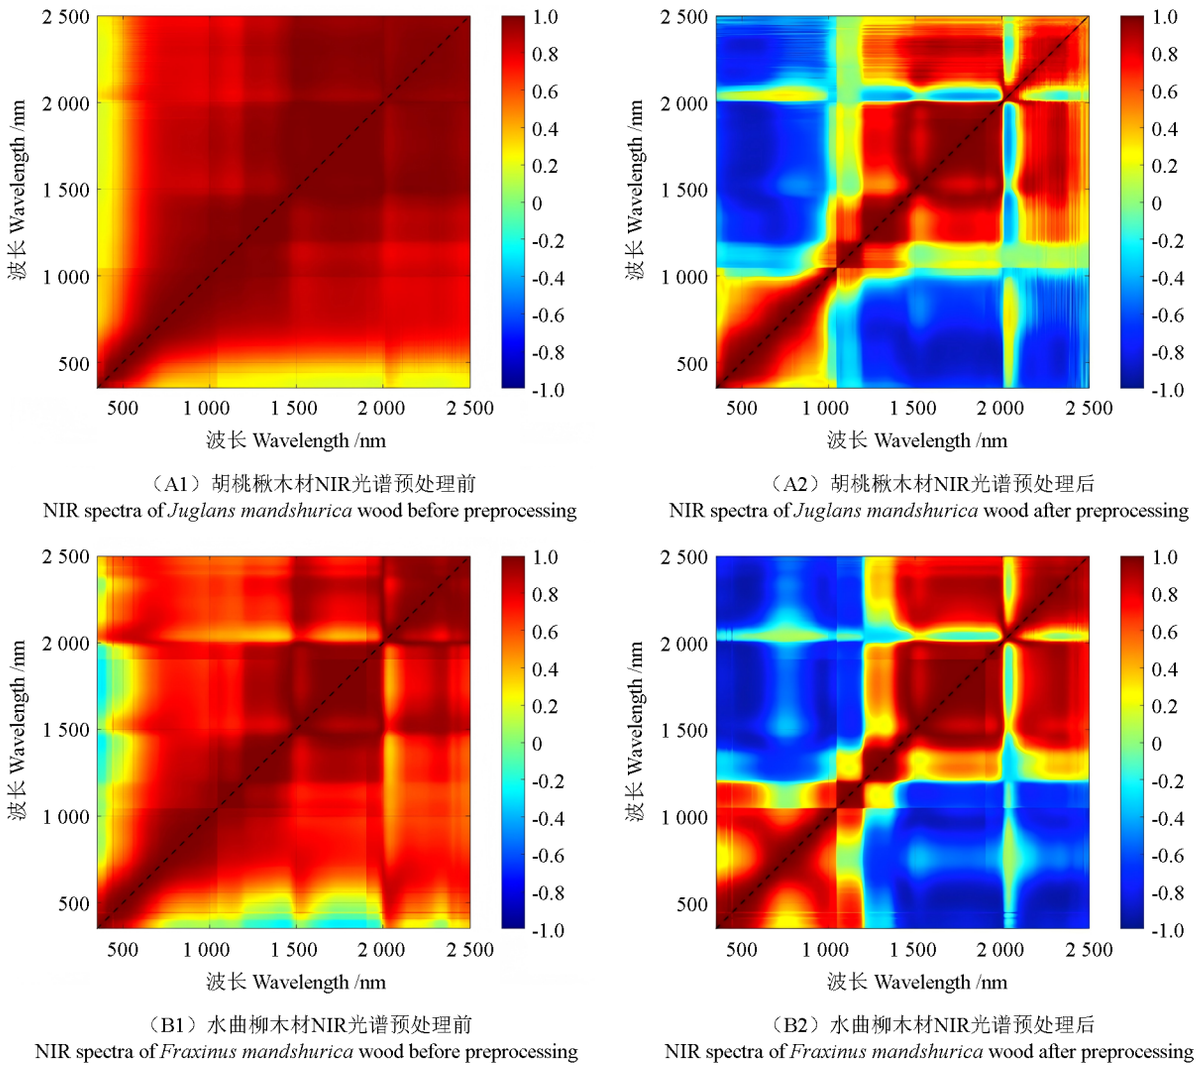
图 4 显示，木材近红外原始光谱的二维图（A1、B1）中相关信号呈弥散态：对角线自动峰轮廓模糊，表明核心振动模式被基线漂移干扰；关键化学基团区域的交叉峰弱且边界不清，反映真实特征被噪声与散射效应掩盖。经 SGS+SNV 处理后（A2、B2），图谱发生系统性转变：SGS 消除随机噪声，使自动峰锐化为清晰的带状结构，凸显木材组分的主振动模式；SNV 校正剥离表面散射效应，形成边界分明的局部高相关区域。整体上，预处理后的图谱从灰阶弥散状态（A1、B1）蜕变为红蓝对比鲜明的分层结构（A2、B2），印证经 SGS+SNV 处理后光谱信噪比与特征分离度的本质提升。这一变化验证了 SGS+SNV 对光谱质量的优化作用，为后续波段优选提供了可靠依据。基于 2 个树种预处理效果的一致性，本研究统一采用 SGS+SNV 方法。

2.2 波段优选方法对木材密度预测精度的影响

预处理后的木材 NIR 光谱数据，虽然基本剔除了木材 NIR 光谱中夹杂的随机噪声和基线偏移等问题，提高了 NIR 光谱信噪比。但木材 NIR 光谱数据仍旧是含有复杂冗余信息的高维度数据，其共线性严重干扰后续 BP 神经网络以及 SAE 提取高维特征，进而影响模型预测精度以及建模速度。为减少无关变量对建模的干扰，提高建模的精度与速度，需要提取 NIRS 数据中的特征波段。为实现胡桃楸和水曲柳木材密度 NIR 预测模型之间的双向模型传递，需要选择波长中对胡桃楸和水曲柳的预测模型均有效果的特征波段。本研究通过 SPFS 算法得到各个波段的评分排序（图 5），并搭配直接指定和交叉验证，基于得分曲线的肘部法则和信息增益等方法确定最优波段。

如图 5 所示，肘部法则确定的波段数目为 2 089 个。同时，本研究以 CARS 分别筛选最佳特征波段，把胡桃楸和水曲柳的 NIR 光谱数据混合起来进行 CARS，共计 6 种方法筛选共同波段。6 种方法筛选的波段数以及用不同建模方法在胡桃楸和水曲柳的数据集上的测试结果如表 3 所示。

表 3 详细展示了 BP 神经网络、SVR 和 PLSR 三种模型在 6 种不同波段选择策略下（包括 SPFS 肘部法则和信息熵法）对胡桃楸和水曲柳 2 个树种在校正集和预测集的表现。分析表 3 数据可知，采用 SPFS 肘部法则选择波段时，BP 神经网络和 SVR 模型在 2 个树种的预测集上均表现出色。具体而言，对于胡桃楸预测集，BP 神经网络模型在此方法下取得了最优的 R^2 值（R^2=0.804 3），显著优于其采用信息熵法的结果（R^2=0.161 2）；SVR 模型同样表现突出，R^2 达到 0.802 1。在水曲柳预测集上，BP 神经网络（R^2=0.900 6，RMSEP=0.027 4）



（A1）胡桃楸木材NIR光谱预处理前
NIR spectra of *Juglans mandshurica* wood before preprocessing

（A2）胡桃楸木材NIR光谱预处理后
NIR spectra of *Juglans mandshurica* wood after preprocessing

（B1）水曲柳木材NIR光谱预处理前
NIR spectra of *Fraxinus mandshurica* wood before preprocessing

（B2）水曲柳木材NIR光谱预处理后
NIR spectra of *Fraxinus mandshurica* wood after preprocessing

图 4　木材 NIR 光谱处理前后的同步二维相关光谱
Fig. 4　Synchronous two-dimensional correlation spectra of wood NIR spectra before and after preprocessing

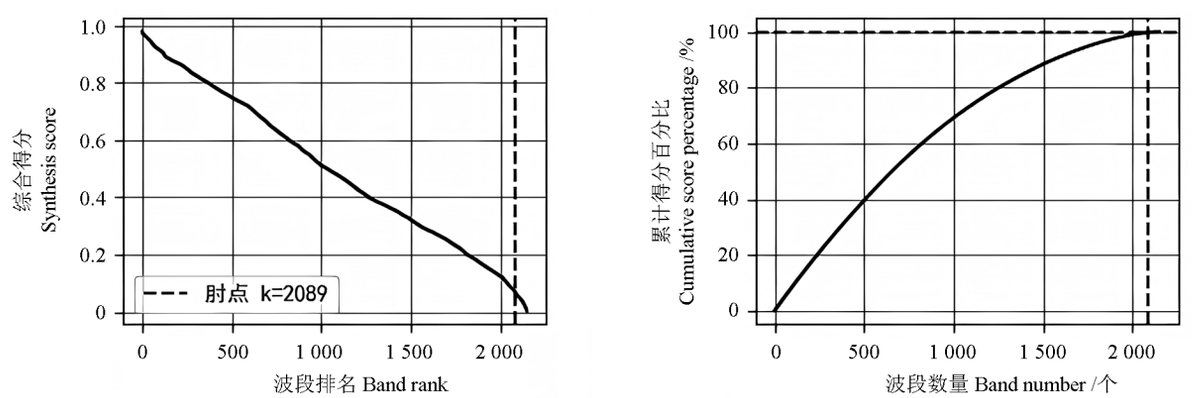


图 5　NIR 波段得分曲线的肘部法则分析
Fig. 5　Analysis of elbow rule of NIR band scoring curve

和 SVR（R^2=0.754 7，RMSEP=0.043 0）在肘部法则下的预测精度也明显优于信息熵法（SVR 在信息熵法下 R^2=0.621 4，RMSEP=0.053 5）、交叉验证法（SVR 在交叉验证法下 R^2=0.700 1，RMSEP=0.047 6）等方法，表明 SPFS 肘部法则能有效筛选出适配这 2 种模型的高信息量波段。相比之下，PLSR 模型的表现则呈现出树种差异：在胡桃楸预测集上使用 SPFS 肘部法则时表现良好（R^2=0.878 1，RMSEP=0.035 3），优于信息熵法（R^2=0.779 1，RMSEP=0.047 6）；然而在水曲柳

表 3 基于不同波段选择方法的胡桃楸和水曲柳木材密度预测模型效果

Table 3 The effect of density prediction models for *Juglans mandshurica* and *Fraxinus mandshurica* using different band selection methods

树种 Tree species	建模方法 Modeling method	波段选择方法（选择波段数目） Band selection method (No. of selected)	校正集 Calibration set		预测集 Prediction set	
			决定系数 R^2	校正集均方根误差 RMSEC	决定系数 R^2	预测集均方根误差 RMSEP
胡桃楸 *Juglans mandshurica*	BP 神经网络	分别 CARS 取交集 (61)	0.997 5	0.004 7	0.744 1	0.039 8
		混合 CARS(195)	0.992 8	0.007 9	0.247 3	0.068 3
		SPFS 直接确定 k(100)	0.789 1	0.043 2	0.119 4	0.073 9
		SPFS 肘部法则 (2 089)	0.990 9	0.0008	0.804 3	0.042 7
		SPFS 信息熵 (1 797)	0.984 9	0.0115	0.161 2	0.072 1
		SPFS 交叉验证 (120)	0.956 9	0.0196	0.196 9	0.070 6
	SVR	分别 CARS 取交集 (61)	0.971 5	0.0147	0.400 1	0.074 7
		混合 CARS(195)	0.985 8	0.0098	0.564 4	0.063 6
		SPFS 直接确定 k(100)	0.633 9	0.0551	0.531 3	0.066 1
		SPFS 肘部法则 (2 089)	0.988 5	0.0100	0.802 1	0.045 1
		SPFS 信息熵 (1 797)	0.667 8	0.0492	0.181 2	0.087 3
		SPFS 交叉验证 (120)	0.724 0	0.0454	0.394 1	0.075 1
	PLSR	分别 CARS 取交集 (61)	0.666 3	0.053 5	0.663 0	0.058 8
		混合 CARS(195)	0.867 9	0.033 6	0.848 5	0.039 4
		SPFS 直接确定 k(100)	0.633 6	0.052 0	0.331 7	0.082 7
		SPFS 肘部法则 (2 089)	0.991 9	0.008 4	0.878 1	0.035 3
		SPFS 信息熵 (1 797)	0.932 9	0.022 6	0.779 1	0.047 6
		SPFS 交叉验证 (120)	0.662 9	0.052 2	0.399 7	0.078 4
水曲柳 *Fraxinus mandshurica*	BP 神经网络	分别 CARS 取交集 (61)	0.994 8	0.008 7	0.852 0	0.033 4
		混合 CARS(195)	0.996 7	0.006 6	0.480 8	0.062 6
		SPFS 直接确定 k(100)	0.746 3	0.061 1	0.604 8	0.054 6
		SPFS 肘部法则 (2 089)	0.993 8	0.009 5	0.900 6	0.027 4
		SPFS 信息熵 (1 797)	0.988 7	0.012 9	0.558 5	0.057 7
		SPFS 交叉验证 (120)	0.743 1	0.061 4	0.488 0	0.062 1
	SVR	分别 CARS 取交集 (61)	0.926 9	0.032 7	0.834 8	0.035 3
		混合 CARS(195)	0.878 7	0.040 0	0.752 6	0.043 2
		SPFS 直接确定 k(100)	0.886 0	0.041 3	0.620 3	0.053 5
		SPFS 肘部法则 (2 089)	0.993 3	0.009 7	0.754 7	0.043 0
		SPFS 信息熵 (1 797)	0.795 9	0.052 8	0.621 4	0.053 5
		SPFS 交叉验证 (120)	0.892 4	0.039 5	0.700 1	0.047 6
	PLSR	分别 CARS 取交集 (61)	0.731 9	0.059 5	0.688 3	0.634 5
		混合 CARS(195)	0.844 7	0.044 6	0.710 3	0.061 2
		SPFS 直接确定 k(100)	0.797 5	0.054 7	0.736 7	0.058 3
		SPFS 肘部法则 (2 089)	0.762 5	0.055 1	0.734 0	0.058 6
		SPFS 信息熵 (1 797)	0.880 9	0.039 9	0.806 9	0.049 9
		SPFS 交叉验证 (120)	0.775 3	0.051 6	0.721 2	0.060 0

预测集上，其 SPFS 肘部法则下的结果（R^2=0.734 0，RMSEP=0.058 6）略逊于其采用 SPFS 信息熵方法的表现（R^2=0.806 9，RMSEP=0.049 9），尽管差距微小（$\Delta R^2 \approx 0.07$）。综合考量，虽然 PLSR 在水曲柳上使用 SPFS 肘部法则并非其绝对最优选择，但其精度（R^2=0.734 0）仍属合理范围。

为确保 BP 神经网络、SVR 和 PLSR 三种模型后续性能对比的公平性和一致性，避免因采用不同最优波段选择策略而引入额外变量干扰比较基准，本研究最终统一采用 SPFS 肘部法则选择的特征波段进行所有模型的后续建模与分析。这一选择在最大程度上保障了 BP 神经网络和 SVR 的最佳性能，同时使 PLSR 在胡桃楸样本上表现良好，在水曲柳样本上保持可接受的精度，为模型间的横向对比提供了可靠且统一的基础。

2.3　目标域中校准样品数量对模型传递效果的影响

校准转移方法的目的是通过尽可能少的校准样品来提高目标域模型的性能。 因此，确定目标域中适当的校准样本量范围是有意义的。如表 1 所示，将训练集和预测集数据按 3∶1 的比例随机划分。为进一步研究目标域中校准样品数量对校准转移的影响，将不同目标域的校准样品数量设置为 10、20、30、40、50，全部训练集样本数（胡桃楸训练集样本数为 66，水曲柳训练集样本数为 62）。使用划分的目标域测试集进行测试，针对胡桃楸和水曲柳木材密度近红外模型使用 SAE 双向传递，结果如图 6 所示。

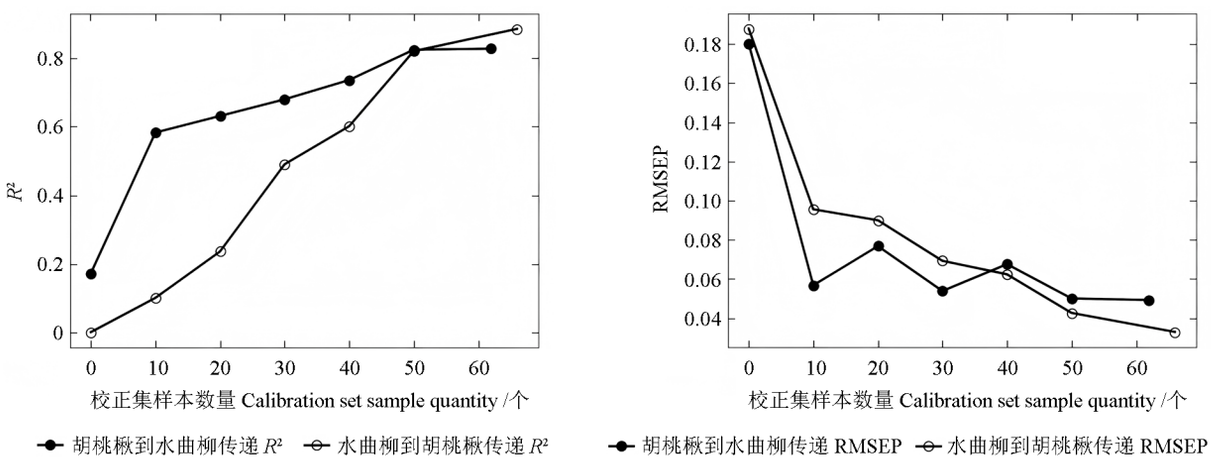


图 6　校正集样本数目对模型传递效果的影响

Fig. 6　The impact of the number of calibration set samples on the calibration transfer performance

由图 6 可以看出，随着目标域校准样本量的增加，SAE 双向传递效果呈现系统性提升。就 R^2 而言，胡桃楸木材密度模型的预测一致性显著增强，其在水曲柳预测集上的 R^2 值从样本量为 10 时的 0.172 7 持续上升至训练集全部样本（62）时的 0.827 1，增幅达 379%。水曲柳模型的在胡桃楸预测集上的改善更为显著，R^2 从初始 0.000 9（近乎无效）跃升至全样本（66）时的 0.884 9，实现近千倍增长，尤其在样本量≥ 40 时突破 0.6（样本量 40：R^2=0.601 1）。

在 RMSEP 方面，胡桃楸到水曲柳传递路径虽存在波动（样本量为 20：RMSEP=0.076 8 g/cm^3；样本量为 40：RMSEP=0.067 6 g/cm^3），但总体呈下降趋势，从样本量为 10 的 0.180 1 g/cm^3 降至全样本的 0.049 3 g/cm^3，累计降幅 72.6%；水曲柳到胡桃楸传递则表现稳定，RMSEP 从 0.187 8 g/cm^3 单调下降至 0.032 9 g/cm^3，降幅达 82.5%。

R^2 提升标志着预测可靠性增强，RMSEP 降低反映了误差控制能力的改善。综上所述，增加目标域校准样本量可显著改善 SAE 双向传递效果，具体表现为 R^2 的显著提升与 RMSEP 的明显下降，双向传递均在取训练集全部样本时传递效果最好（图 7）。

由图 7 可以看出，双向传递的预测值（PLSR-TARGET）的散点均偏离 PLSR 预测线，并且预测值的总体偏离很大。当使用一个树种的密度模型预测其他树种的光谱时，将会发生大量系统错误，对 SAE 进行校准转移后，胡桃楸和水曲柳的预测散点与 PLSR 直线接近。试验结果表明，即使对不同树种的 NIR 光谱，SAE 网络依然具有强大的传递能力，并且具有将一个树种的模型应用到不同树种的实用性。

2.4　基于不同传递方法的木材密度 NIR 传递模型性能比较

由于双向传递效果类似，本研究以胡桃楸到水曲柳的木材密度 NIR 模型传递为例，比较基于不同方法的木材密度 NIR 传递模型的性能。在没有任何模型传递（PLSR-TARGET，SVR-TARGET）的情况下，选择了 PLSR 和 SVR 作为比较。PLSR+SBC、PLSR+PDS（通过 PDS 方法传递的 PLSR 模型）、SVR+PDS（由 PDS 方法传输的 SVR 模型）以及提出的 SAE 方法，均以水曲柳全部校正集样本得出的模型为依据，得到各模型预测集的 R^2 和 RMSEP（图 8）。

对图 8 进行分析可知，传统模型传递方法在跨树种场景中普遍导致性能退化。PLSR 模型经 PDS 传递后，R^2 从目标域基准值 0.431 3 大幅降至 0.015 0（降幅 96.5%），同时 RMSEP 从 0.194 6 g/cm^3 增至 0.291 3 g/cm^3（增幅 49.7%）；虽然 SBC 传递

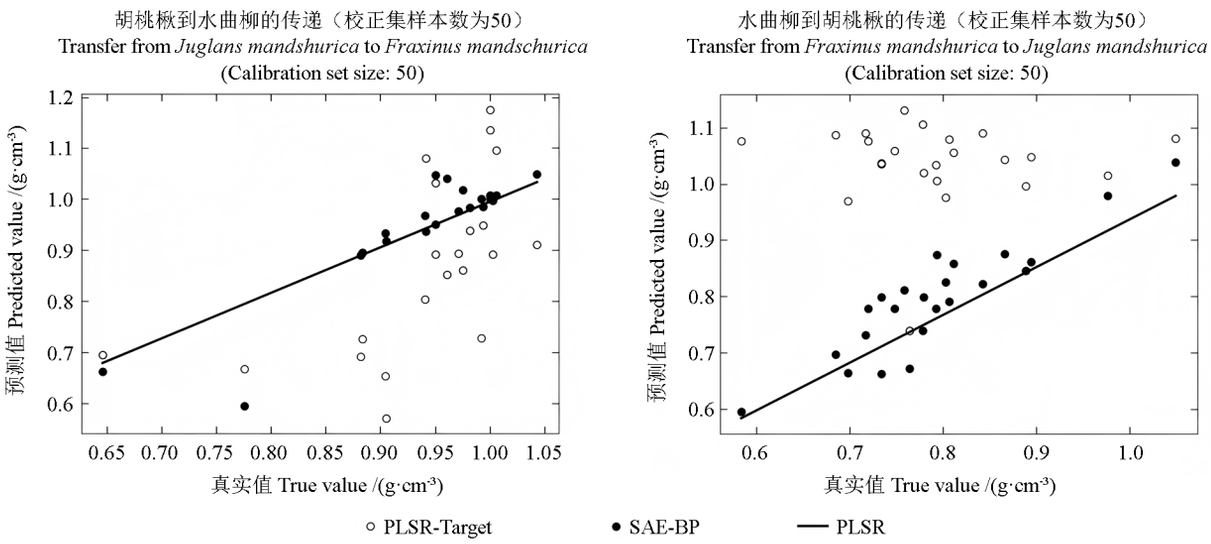


图 7 使用训练集全部样本的双向传递效果

Fig. 7 Bidirectional transfer effect diagram using all samples in the training set

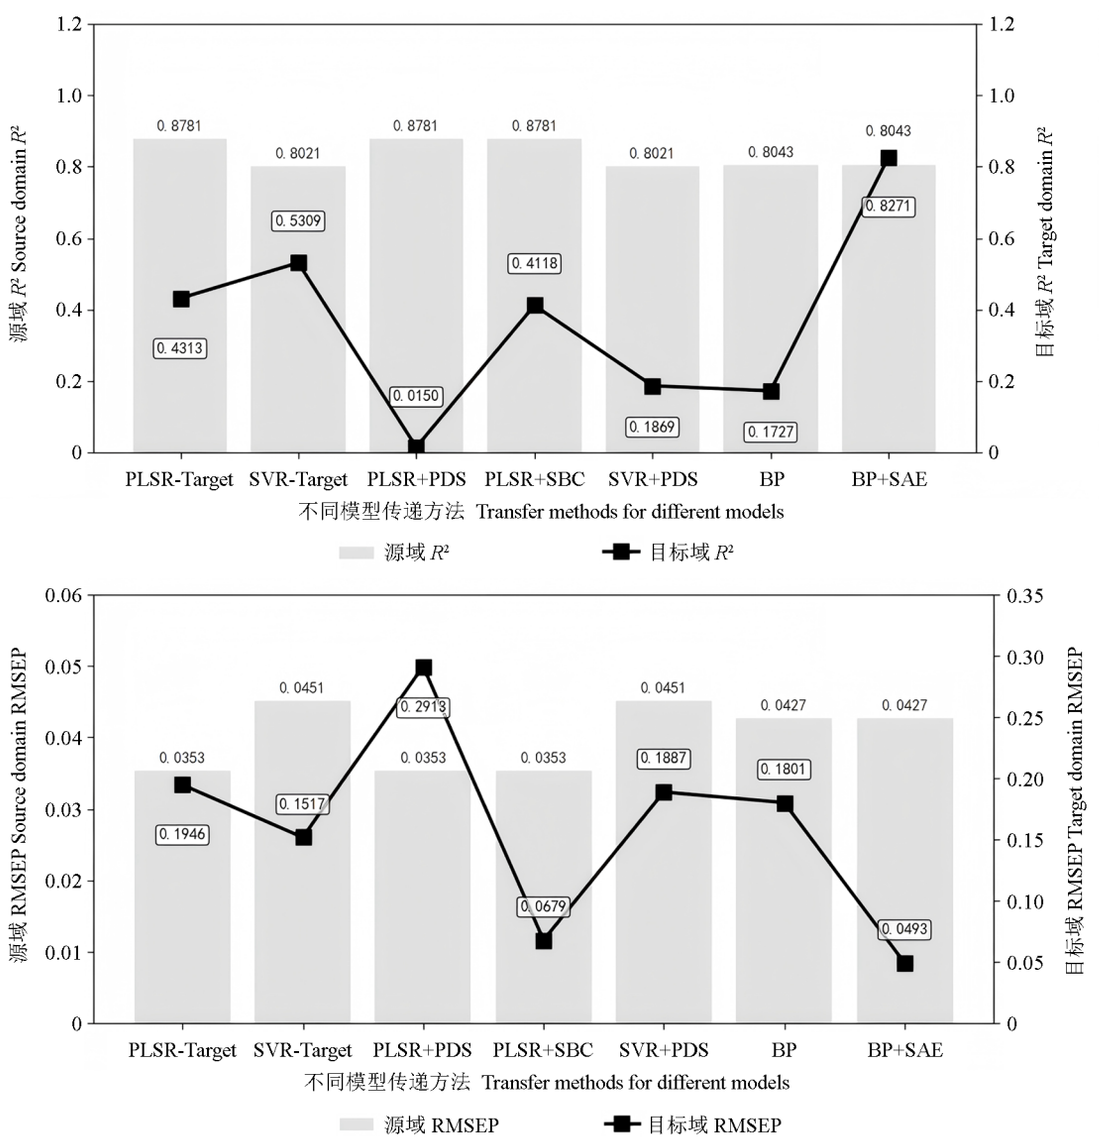


图 8 源域和目标域不同模型传递方法的 R^2 和 RMSEP

Fig. 8 R^2 and RMSEP values of transfer methods for different models between source domain and target domain

使 PLSR 模型的 RMSEP 意外降至 0.067 9 g/cm^3（降幅 65.1%），但其 R^2 仍降低至 0.411 8（降幅 4.5%），反映出误差优化的不稳定性。类似地，SVR 模型经 PDS 传递后 R^2 从 0.530 9 骤降至 0.186 9（降幅 64.7%），而 RMSEP 仅微降至 0.188 7 g/cm^3（降幅 3.1%）。这种系统性退化源于胡桃楸与水曲柳之间显著的光谱特征差异（如纤维素特征峰位移、木质素吸收强度变异），导致基于线性变换的 PDS/SBC 方法难以适配非线性特征迁移，与 Li 等 [30] 和 Chen 等 [31] 在阔叶树种中的发现一致。与此形成鲜明对比的是，本研究提出的 SAE 方法展现出显著优势：相较未传递的源域模型（R^2=0.172 7，RMSEP=0.180 1 g/cm^3），其传递后 R^2 跃升至 0.827 1（增幅 379%），RMSEP 降至 0.049 3 g/cm^3（降幅 72.6%）。更为关键的是，其性能逼近目标域独立建模的 PLSR-TARGET 模型（R^2 差距仅 5.8%）。这表明 SAE 通过深度特征提取与域自适应机制，有效解耦了树种特异性光谱干扰，保留了木材密度的核心响应特征，从而克服了跨物种传递的障碍。

3　结论与讨论

本研究通过构建基于 SAE 的跨树种模型传递框架，实现了胡桃楸与水曲柳木材密度近红外预测模型的高效双向迁移。试验结果表明，SGS+SNV 组合预处理可显著提升光谱质量，通过 Savitzky-Golay 平滑抑制高频噪声，结合标准正态变量变换消除散射效应，使胡桃楸和水曲柳模型的预测集决定系数分别达到 0.788 3 和 0.651 8。在特征波段优化方面，基于肘部法则的 SPFS 算法筛选出 2 089 个共同波段，该策略通过融合 Welch's t 检验的波段区分度评估与相关系数加权机制，在 BP 神经网络模型中表现最优（胡桃楸预测集 R^2=0.804 3，水曲柳 R^2=0.900 6），显著优于传统 CARS 方法。SAE 的核心价值体现在其跨树种传递性能：当胡桃楸模型迁移至水曲柳时，预测集 R^2 从 0.172 7 跃升至 0.827 1，RMSEP 降低了 72.6%；反向传递中 R^2 更从近乎无效的 0.000 9 提升至 0.884 9，RMSEP 下降了 82.5%，深度编码结构通过非线性特征映射有效克服了树种间光谱分布偏移问题。相比之下，传统 PDS/SBC 方法因依赖线性变换导致性能严重退化（如 PLSR+PDS 传递后 R^2 降幅达 96.5%）。本研究还发现，目标域校准样本量增至全训练集时传递效果最优，证实 SAE 需充足数据学习特征映射规律，但仅需目标域样本微调即可实现高效迁移。

尽管 SAE 展现出强大潜力，但仍存在一定局限。本研究结论主要基于东北地区胡桃楸和水曲柳 2 种硬阔叶材。因此，对蒙古栎等其他阔叶树种或针叶树种的普适性需进一步验证。考虑到针叶材和阔叶材在微观结构和宏观性质上存在显著差异，这种普适性验证尤为重要。从微观结构来看，阔叶材（如本研究的胡桃楸和水曲柳）通常具有导管（用于水分运输）和木纤维（提供支撑），其排列方式和细胞壁厚度因树种而异，导致密度、硬度等性质差异较大。而针叶材（如松、杉）则主要由管胞构成，但管胞的尺寸、纹孔特征等仍会影响其光谱响应 [32]。这些微观结构上的差异会直接影响木材对近红外光的吸收和散射特性，进而影响光谱模型的准确性。从宏观性质来看，阔叶材和针叶材在密度范围、纹理、颜色、化学成分（如木质素、纤维素、半纤维素的比例）等方面也存在明显区别 [33]。这些宏观差异同样会反映在近红外光谱中，使得针对特定树种建立的模型在应用于其他树种时可能出现预测精度下降的问题。因此，未来研究需要针对不同树种（尤其是针叶材和不同类型的阔叶材）进行试验，深入分析其光谱特征与密度之间的关系，并探索如何通过模型优化或数据预处理方法，提高模型的跨树种普适性。其次，SAE 的 6 层堆叠结构导致参数优化耗时较长，后续可通过轻量化设计（如卷积自编码器）或层数压缩提升效率。此外，当前仅聚焦气干密度单一参数，未来需探索卷积神经网络（Convolutional neural network，CNN）、长短期记忆网络（Long short-term memory，LSTM）等替代 BP 神经网络，并构建单一光谱模型同步预测木材力学强度、含水率等多指标的跨树种传递框架。总体而言，本研究证实 SAE 通过深度特征对齐机制，为近红外模型跨树种共享提供了可靠解决方案，突破了传统线性校正方法的局限性，对于推动林业资源无损检测与高效利用具有重要实践价值。

参考文献：

[1] 史云颖 , 李敬岩 , 褚小立 . 多元校正模型传递方法的进展与应用 [J]. 分析化学 ,2019,47(4):479-487.
Shi Y Y, Li J Y, Chu X L. Progress and applications of multivariate calibration model transfer methods[J]. Chinese Journal of Analytical Chemistry,2019,47(4):479-487.

[2] 王菊香 , 韩晓 , 邢志娜 . 基于 DS 算法的混胺燃料近红外光谱分析模型传递 [J]. 海军航空工程学院学报 ,2020,35(5):

414-418.

Wang J X, Han X, Xing Z N. The calibration transfer of near infrared (NIR) spectral analysis for mixed-amine fuel based on DS-PLS algorithm[J]. Journal of Naval Aeronautical and Astronautical University,2020,35(5):414-418.

[3] 张站鸽 , 倪力军 , 张立国 , 等 . 基于 MC-UVE-VIP 两步波长筛选实现近红外光谱模型的无标样传递 [J]. 分析测试学报 , 2023,42(2):204-209.

Zhang Z G, Ni L J, Zhang L G, et al. Standard free transfer of near infrared spectral model by two-step wavelength screening method based on MC-UVE-VIP algorithm[J]. Journal of Instrumental Analysis,2023,42(2):204-209.

[4] 洪士军 , 黄雯 , 张立国 , 等 . 基于尺度不变特征变换筛选稳定特征波长的近红外光谱模型传递方法 [J]. 分析测试学报 , 2020,39(10):1260-1266.

Hong S J, Huang W, Zhang L G, et al. A near infrared spectroscopy calibration model transfer method based on scale invariant feature transform to select stable characteristic wavelengths[J]. Journal of Instrumental Analysis,2020,39(10):1260-1266.

[5] 刘翠玲 , 徐金阳 , 孙晓荣 , 等 . 基于 TrAdaBoost 算法的近红外光谱模型传递研究 [J]. 农业机械学报 ,2022,53(2):239-245.

Liu C L, Xu J Y, Sun X R, et al. Near infrared spectroscopy calibration transfer based on TrAdaBoost algorithm[J]. Transactions of the Chinese Society of Agricultural Machinery, 2022,53(2):239-245.

[6] 王红鸿 , 陈琴 , 陈勇 , 等 . 二进制蜻蜓算法 - 直接校正算法优选标样集在小麦粉蛋白质近红外模型传递中的应用 [J]. 分析科学学报 ,2023,39(3):267-274.

Wang H H, Chen Q, Chen Y, et al. Application of BDA-DS method to optimize the selection of transfer set in near infrared model transfer of wheat flour protein[J]. Journal of Analytical Science,2023,39(3):267-274.

[7] 傅鹏有 . 面向近红外光谱建模及模型传递的深度学习研究 [D]. 桂林 : 桂林电子科技大学 ,2023:25-29.

Fu P Y. Research on deep learning for near-infrared spectroscopy modeling and model transfer[D]. Guilin: Guilin University of Electronic Technology,2023:25-29.

[8] Mishra P, Passos D. Deep calibration transfer: transferring deep learning models between infrared spectroscopy instrument[J]. Infrared Physics & Technology,2021,117:103863.

[9] Zhang Z Y, Li Y X, Li C X, et al. Algorithm of stability-analysis-based feature selection for NIR calibration transfer[J]. Sensors,2022,22:1659.

[10] 刘智健 , 熊智新 , 胡云超 , 等 . 基于直接标准化与分段直接标准化联用的木质素近红外模型传递方法研究 [J]. 分析试验室 , 2024,43(4):502-510.

Liu Z J, Xiong Z X, Hu Y C, et al. Research on near-infrared model transfer for lignin based on the combined direct standardization-piecewise direct standardization method[J]. Chinese Journal of Analysis Laboratory,2024,43(4):502-510.

[11] 王红鸿 , 汪莹 , 黄浩冉 , 等 .SWCSS-DS 算法在纸浆材综纤维素近红外分析模型传递中的应用 [J]. 分析试验室 ,2024,43(6): 864-870.

Wang H H, Wang Y, Huang H R, et al. Application of SWCSS-DS algorithm in the transfer of near infrared analysis model for holocellulose in pulpwood[J]. Chinese Journal of Analysis Laboratory,2024,43(6):864-870.

[12] 刘楠 , 刘翠玲 , 徐金阳 , 等 . 基于极限学习机自编码算法的近红外光谱模型传递的研究 [C]//2023 届中国系统仿真与虚拟现实技术高层论坛论文集 ,2023.

Liu N, Liu C L, Xu J Y, et al. Research on near-infrared spectroscopic model transfer based on extreme learning machine autoencoder algorithm[C]//Proceedings of the 2023 China systems simulation and virtual reality technology high-level forum,2023.

[13] 屈肖凯 . 不同产地鳜鱼新鲜度光谱检测模型的建立与传递方法研究 [D]. 武汉 : 华中农业大学 ,2023:59-76.

Qu X K. Research on the establishment and transfer method of the spectral detection model for the freshness of mandarin fish from different origins[D]. Wuhan: Huazhong Agricultural University, 2023:59-76.

[14] GB/T 1927.5—2021 无疵小试样木材物理力学性质试验方法 第 5 部分 : 密度测定 [S].

GB/T 1927.5-2021: Test methods for physical and mechanical properties of small clear wood specimens Part 5: determination of density[S].

[15] 彭润东 , 李耀翔 , 陈雅 , 等 . 基于 LSTM 长短期记忆网络的樟子松木材气干密度 NIRS 模型预测 [J]. 中南林业科技大学学报 ,2024,44(3):179-188.

Peng R D, Li Y X, Chen Y, et al. NIRS model prediction of air-dry density of *Pinus sylvestris* wood based on long short-term memory network (LSTM)[J]. Journal of Central South University of Forestry & Technology,2024,44(3):179-188.

[16] 张哲宇 , 李耀翔 , 王志远 , 等 . 基于 IFSR 异常样本剔除的落叶松木材密度近红外优化模型的研究 [J]. 光谱学与光谱分析 , 2022,42(11):3395-3402.

Zhang Z Y, Li Y X, Wang Z Y, et al. NIR model optimization study of larch wood density based on IFSR abnormal sample elimination[J]. Spectroscopy and Spectral Analysis,2022,42(11): 3395-3402.

[17] 阚相成 , 李耀翔 , 王立海 , 等 . 基于光谱预处理的低温水曲柳原木含水率检测 [J]. 中南林业科技大学学报 ,2022,42(11): 154-163.

Kan X C, Li Y X, Wang L H, et al. Moisture content detection of *Fraxinus mandshurica* logs at low temperatures based on different spectrum pretreatments[J]. Journal of Central South University of Forestry & Technology,2022,42(11):154-163.

[18] Wan Q L, Zhu H Q, Yang C H, et al. CAPR: an effective alternative variable selection algorithm of CARS[J]. 2023,DOI: 10.2139/ssrn.4377283.

[19] Gokhan T, Price M J, Lee M. Graphs in clusters: a hybrid approach to unsupervised extractive long document summarization using language models[J]. Artificial Intelligence Review,2024,57:189.

[20] Al-Shalabi L. New feature selection algorithm based on feature stability and correlation[J]. IEEE Access,2022,10:4699-4713.

[21] Li D Z, Liu J X, Ma X, et al. Stacked supervised auto-encoder with graph regularization for feature extraction and fault classification in chemical processes[J]. Journal of Process Control,2023, 127:102999.

[22] Wang X, Qi X M, Zhang Y. Deep learning with local spatiotemporal structure preserving for soft sensor development of complex industrial processes[J]. Applied Soft Computing,2024, 164:111974.

[23] Luo S Y, Huang X F, Wang Y Z, et al. Transfer learning based on improved stacked autoencoder for bearing fault diagnosis[J]. Knowledge-Based Systems,2022,256:109846.

[24] Guo X P, Zhao X F, Li Y. Stacked dynamic target regularization enhanced autoencoder for soft sensor in industrial processes[J]. The Canadian Journal of Chemical Engineering,2025,103: 1335-1348.

[25] 吴斑 . 基于 NIR 的制浆材材性快速检测方法研究 [D]. 北京 : 中国林业科学研究院 ,2018:17-23.
Wu T. Study on rapid measurement method for pulpwood characteristics using the near-infrared techniques[D]. Beijing: Chinese Academy of Forestry,2018:17-23.

[26] Mahanti N K, Shivashankar S, Chhetri K B, et al. Enhancing food authentication through E-nose and E-tongue technologies: current trends and future directions[J]. Trends in Food Science & Technology,2024,150:104574.

[27] 陈琴 . 基于 DS 与 PDS 的纸浆材木质素近红外分析模型传递策略研究 [D]. 南京 : 南京林业大学 ,2022:45-55.
Chen Q. Model transfer strategy of NIR analysis for pulpwood lignin based on DS and PDS[D]. Nanjing: Nanjing Forestry University,2022:45-55.

[28] Dhanoa M S, López S, Sanderson R, et al. Methodology adjusting for least squares regression slope in the application of multiplicative scatter correction to near-infrared spectra of forage feed samples[J]. Journal of Chemometrics,2023,37:e3511.

[29] Zhang Y, Hui J, Qin Q M, et al. Transfer-learning-based approach for leaf chlorophyll content estimation of winter wheat from hyperspectral data[J]. Remote Sensing of Environment, 2021,267:112724.

[30] Li J X, Yin J X, Gao R, et al. Research on calibration transfer methods in coal quality spectral analysis across instruments and coal types[J]. Analytica Chimica Acta,2025,1372:344459.

[31] Chen J H, Ling J, Lei N N, et al. BDSER-InceptionNet: a novel method for near-infrared spectroscopy model transfer based on deep learning and balanced distribution adaptation[J]. Sensors,2025,25:4008.

[32] Ruffinatto F, Negro F, Crivellaro A, et al. The macroscopic structure of wood[J]. Forests,2023,14:644.

[33] Orton C R, Parkinson D Y, Evans P D, et al. Fourier transform infrared studies of heterogeneity, photodegradation, and lignin/hemicellulose ratios within hardwoods and softwoods[J]. Applied Spectroscopy,2004,58(11):1265-1271.

[本文编校：吴　彬]