第 41 卷 第 17 期/2021 年 9 月/光学学报 研究论文

光学学报

基于 Dropout 深度信念网络的棉和涤纶含量的近红外光谱检测

韦卓[1]，李稳稳[1]，林敏[1*]，江文松[1]，周新奇[2]

[1]中国计量大学计量测试工程学院，浙江 杭州 310018；

[2]杭州谱育科技发展有限公司，浙江 杭州 310023

摘要 将近红外光谱技术与深度学习理论相结合，提出了一种基于 Dropout 深度信念网络(DBN)的棉涤混纺面料中各组分含量的快速检测方法。首先使用小波变换对原始光谱数据进行压缩处理，再构建以高斯受限玻尔兹曼机(GRBM)为核心的 DBN 模型，以保证输入数据信息的完整性；然后利用 Dropout 来防止模型过拟合，通过隐藏部分隐含层节点来减小节点之间的相互依赖，实现网络的稀疏化处理，提高了非线性建模和网络模型的泛化能力。实验结果表明：对于采用 Dropout-DBN 方法建立的棉涤混纺面料中各组分含量的分析模型，其棉、涤纶含量的预测集相关系数分别为 0.9927 和 0.9903，预测集均方根误差分别为 0.0792 和 0.0869。与其他建模方法相比，所建模型的精度和适应性显著提高，并有利于模型的传递与共享，提高了模型的智能化。

关键词 光谱学；近红外光谱；棉涤混纺面料；深度信念网络；高斯受限玻尔兹曼机；Dropout 策略

中图分类号 O657.33；TS116 **文献标志码** A **doi**：10.3788/AOS202141.1730002

Near-Infrared Spectroscopy Detection of Cotton/Polyester Content Based on Dropout Deep Belief Network

Wei Zhuo[1], Li Wenwen[1], Lin Min[1*], Jiang Wensong[1], Zhou Xinqi[2]

[1] *College of Metrology and Measurement Engineering, China Jiliang University, Hangzhou, Zhejiang* 310018, *China*;

[2] *Hangzhou Puyu Technology Inc., Hangzhou, Zhejiang* 310023, *China*

Abstract We combined near-infrared spectroscopy with the deep learning theory to propose a method for rapidly detecting the content of each component in cotton-polyester blended fabric based on the Dropout deep belief network (DBN). Firstly, wavelet transform was used to compress the original spectral data. Then, a DBN model with a Gaussian restricted Boltzmann machine (GRBM) as the core was constructed, which could ensure the integrity of input data. Finally, Dropout was used to effectively prevent the model from overfitting and the interdependence between nodes was reduced by hiding some hidden layer nodes. As a result, network sparsification was achieved and the ability of nonlinear modeling and network model generalization was enhanced. The experimental results indicate that in the analytical model of the content of each component in cotton-polyester blended fabric built by the Dropout-DBN method, the correlation coefficients of prediction set for cotton and polyester contents are respectively 0.9927 and 0.9903, and the root mean square errors of prediction set are 0.0792 and 0.0869, respectively. The model proposed in this paper has much higher accuracy and adaptability than other modeling methods, which is conducive to model transfer and sharing and improves the intelligentization of the model.

Key words spectroscopy; near-infrared spectroscopy; cotton-polyester blended fabric; deep belief network;

收稿日期：2021-02-26；**修回日期**：2021-03-14；**录用日期**：2021-03-23

基金项目：国家重点研发计划项目(2018YFF01012006)、国家重大科学仪器设备开发专项(2014YQ470377)、浙江省基本科研业务费资助项目(2021YW82)

通信作者：*linm@cjlu.edu.cn

Gaussian restricted Boltzmann machine; Dropout strategy
OCIS codes 300.6340; 120.4290; 070.4790

1 引 言

随着我国棉纺织工业的迅速发展，棉纺织品中各纤维成分的质量检测受到了生产者、消费者及各级政府监管部门的高度重视。然而，传统的检测方法，如化学溶解法和显微镜法，往往存在检测周期长、样品破坏程度高、所用化学试剂会造成环境污染和危害操作人员身体健康等缺点；因此，寻找一种绿色环保的无损快速检测定量分析技术显得尤为重要。

近红外光谱(NIR)技术是一种主流的无损检测技术，其以速度快、效率高、成本低等优势被广泛应用于食品工业、石油化工和环境监测等领域[1-7]。目前，已有学者将近红外光谱技术应用于混纺面料织物纤维成分含量检测[8]和纺织纤维原料的鉴别分类[9]等方面，例如：Sun 等[10]将近红外光谱技术与偏最小二乘支持向量机(LS-SVM)方法相结合，对混纺织物中的含棉量进行了定量分析，结果表明，该方法在混纺织物含棉量的分析上具有显著优势；李海洋等[11]将多模型方法与基于主成分分析的支持向量机(PCA-SVM)融合，建立了棉锦、棉涤两类混纺织物的近红外光谱定性分析模型，该模型的分类效果和稳定性与 PCA-SVM 模型相比得到明显提高。这些研究表明，采用近红外光谱技术对纺织品进行定量和定性分析是可行的，但分析模型采用的是偏最小二乘(PLS)、支持向量机(SVM)和极限学习机(ELM)等浅层学习方法，浅层学习对于解决简单问题非常有效，但在面对复杂的实际应用问题时，往往表现出对函数表达的不足，不利于模型的传递与共享，特别是模型的智能化。

深度学习是一种典型的无监督特征学习方法，具有更强的学习和分析问题的能力，通过对深层非线性网络结构进行充分学习，可以实现对复杂函数的高度表达。深度学习已被成功应用于汽车安全驾驶、故障诊断和目标跟踪等领域[12-13]。深度学习方法可以从高维、非线性的近红外光谱数据中提取出关键的特征信息，能够保证分析模型的准确性和稳定性，已被应用于土壤有机质预测、药品品种分类和莲子粉掺假鉴别[14-16]等方面，但在纺织品纤维成分含量检测方面的研究报道相对较少。

模型的建立是近红外光谱分析的关键，而模型的精度和适应性是近红外光谱分析的核心。本文将深度学习理论与近红外光谱技术相结合，提出了一种基于 Dropout 深度信念网络(DBN)的棉涤混纺面料中棉、涤纶含量的近红外光谱检测方法。首先使用小波变换对原始光谱进行预处理，以获取有效信息并减少模型的运算量；然后将预处理后的光谱数据作为网络模型的输入，将对应的理化分析数据作为输出，建立基于 DBN 的定量分析模型；之后引入 Dropout 的思想，以一定的概率参数随机隐藏部分隐含层节点，稀疏化网络结构，从而达到有效防止模型过拟合的目的；最终根据网络模型的最佳输出结果确定最优的 Dropout 比例，由此建立更为准确的棉涤混纺面料中棉、涤纶含量的预测模型。

2 实验材料与方法

2.1 实验仪器与样品收集

实验仪器为聚光科技(杭州)股份有限公司的 SupNIR-1520 型便携式近红外光谱仪(配备平面大光斑漫反射探头)。光谱采集软件为聚光世达近红外分析仪测量分析软件。光谱预处理及模型的建立均在 MATLAB R2018b 软件上完成，计算机运行内存为 8.00 GB，处理器为 i7-5557。

棉和涤纶含量的高低是衡量棉涤混纺织物质量优劣的重要标准。用于实验研究的 308 份棉涤样品由江西省出入境检验检疫局提供。为保证样品具有代表性，收集的样品的纤维成分含量具有一定的梯度分布，并且涵盖了颜色差异明显、薄厚程度不同、条纹种类多样且面料相对均匀的各类样品。

2.2 样品光谱的采集

使用 SupNIR-1520 型便携式近红外光谱仪采集样品的光谱数据。仪器的采集范围为 1000～1800 nm，采样间隔为 1 nm，分辨率为 10 nm，扫描次数为 30 次，采用漫反射附件，以聚四氟乙烯白板作为参比。为确保样品光谱的稳定性，在环境温度约为 25 ℃的条件下采集光谱，环境相对湿度保持在 50%～70%范围内。为确保所采集的样品光谱具有代表性，选择棉涤样品中面料分布相对均匀的区域进行光谱的采集，依据样品的厚度，对其进行“Z”字型折叠再压平，以便检测样品的内外表面(正反面)，依次采集样品正反两面的光谱数据，最后取平均值作为样品的原始光谱(用于后续的分析处理)。

2.3 样品理化值的测定

棉涤混纺面料中棉和涤纶的含量按定量化学分析方法——硫酸溶解法进行测定。具体实验步骤参照 GB/T 2910.11—2009《纺织品 定量化学分析 第 11 部分:纤维素纤维与聚酯纤维的混合物(硫酸法)》进行,对每个样品进行两次平行测定,误差均分布在±1%范围内,取算术平均值作为最终的测定结果。棉涤混纺面料样品中棉和涤纶含量的统计结果如表 1 所示。

表 1 棉涤混纺面料中各组分含量的统计结果

Table 1 Statistical results of each component content in cotton-polyester blended fabric

Component	Mass fraction /%		
	Maximum	Minimum	Mean
Cotton	99.40	5.13	52.16
Polyester	94.87	0.60	47.84

2.4 基于 Dropout 深度信念网络的近红外光谱分析

2.4.1 高斯受限玻尔兹曼机模型

深度信念网络(DBN)是一种概率生成模型,由若干层无监督的受限玻尔兹曼机(RBM)和一层有监督的反向传播(BP)网络组成,其中 RBM 由单可见层和单隐含层以层内无连接、层间全连接的方式构成。由于可见层节点($v_1,v_2,\cdots,v_i$)和隐含层节点($h_1,h_2,\cdots,h_j$)均为二值数据,在实际应用时往往会导致输入数据信息丢失,因此,考虑到 RBM 的局限性以及过程检测的要求,本文用带有高斯噪声的实数节点代替可见层的二值节点,得到高斯受限玻尔兹曼机模型(GRBM)。GRBM 结构图如图 1 所示,与之对应的 DBN 模型结构图如图 2 所示。

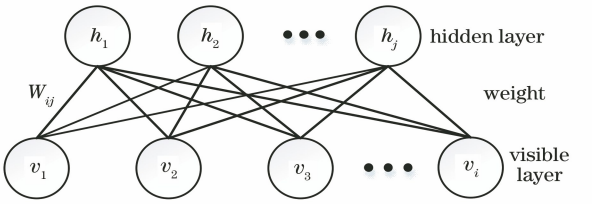

图 1 GRBM 结构图

Fig. 1 GRBM structure diagram

由图 2 可知,基于 DBN 的物质近红外光谱分析过程主要分为两个阶段:预训练和微调。将物质的光谱数据作为最底层 GRBM 的输入数据,依次向上传递、训练各层 GRBM;将低层 GRBM 的隐含层输出作为高层 GRBM 的可见层输入,完成对光谱数据的特征提取,并保留各层 GRBM 训练后的权重和偏置。将预训练得到的各层 GRBM 的参数赋值给顶层的 BP 网络,自上而下地微调网络参数,从而使整

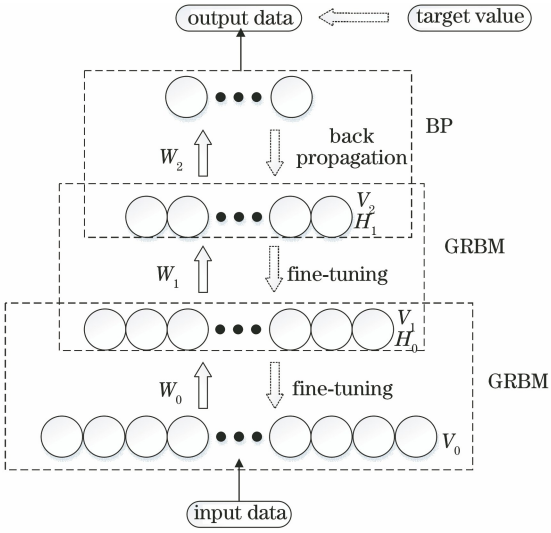

图 2 DBN 模型结构图

Fig. 2 DBN model structure diagram

个网络的实际输出值与目标理化值的误差达到最小,获得最优的近红外光谱分析模型。

GRBM 是一种能量模型,对于给定的状态(v,h),其网络能量函数为[17]

$$E_\theta(v,h)=\frac{1}{2}\sum_i\frac{(v_i-a_i)^2}{\sigma_i^2}-\sum_i\sum_j\frac{v_i}{\sigma_i}W_{ij}h_j-\sum_j b_jh_j,\tag{1}$$

式中:网络参数 $\theta=\{W_{ij},a_i,b_j\}$,其中 W_{ij} 为可见层节点 v_i 与隐含层节点 h_j 之间的连接权重,a_i 和 b_j 分别为可见层节点和隐含层节点的偏置;σ_i 为可见层节点 v_i 的标准差。(1)式中的各参数均为实数。

通过能量函数可以得到状态(v,h)的联合概率分布,如(2)式所示;结合 GRBM 的结构特点,可得到相应的隐含层节点和可见层节点的条件概率分布,如(3)、(4)式所示。

$$P_\theta(v,h)=\frac{1}{Z_\theta}\exp[-E_\theta(v,h)],\tag{2}$$

$$P_\theta(h_j=1\mid v)=f_{\text{sigmoid}}\left(b_j+\sum_i\frac{v_i}{\sigma_i}W_{ij}\right),\tag{3}$$

$$P_\theta(v_i=v\mid h)=N\left(a_i+\sigma_i\sum_j W_{ij}h_j,\sigma_i^2\right),\tag{4}$$

式中:配分函数 $Z_\theta=\sum_{v,h}\exp[-E_\theta(v,h)]$为归一化因子;$f_{\text{sigmoid}}=\frac{1}{1+\exp(-x)}$为激活函数;$N$ 代表高斯分布。

GRBM 的学习目的是获得网络参数 θ,使隐含层能够更好地表示可见层,通常采用 G. Hinton 提出的对比散度(CD)算法实现 GRBM 模型参数的快速更新。利用 Gibbs 采样从训练样本集中的任一状

态出发，根据(3)式计算出隐含层节点的状态，并固定该层节点，然后根据(4)式重构可见层节点。由此得到网络参数 θ 的更新规则为

$$\theta=\theta+\varepsilon(\langle v_i h_j\rangle_{\text{data}}-\langle v_i h_j\rangle_{\text{recon}}),\tag{5}$$

式中：ε 为学习率；$\langle v_i h_j\rangle_{\text{data}}$ 为输入数据的数学期望；$\langle v_i h_j\rangle_{\text{recon}}$ 为重构数据的数学期望。

2.4.2 Dropout 随机隐藏策略

具有小样本、高维度和非线性等特点的近红外光谱数据在构建深度学习网络模型时易出现过拟合的问题。为了有效地解决该问题，本文引入了一种隐式的模型融合方法——Dropout 随机隐藏策略，即：在网络训练阶段，以一定的概率 p 随机隐藏某些隐含层节点，使其不参与训练但权重被暂时保留，而在之后的网络迭代过程中，该节点可能参与训练，直至整个网络训练结束。这种处理可以稀疏化网络结构，使网络参数的更新不依赖于固定隐含层节点之间的协同作用，特征随机出现，互不影响。此时 DBN 隐含层第 j 个节点的输出为

$$h_j=X_j f_{\text{sigmoid}}\left(b_j+\sum_i\frac{v_i}{\sigma_i}W_{ij}\right)=\begin{cases}f_{\text{sigmoid}}\left(b_j+\sum_i\frac{v_i}{\sigma_i}W_{ij}\right), & \text{if } X_j=1\\ 0, & \text{if } X_j=0\end{cases},\tag{6}$$

其中，$p(X_j=0)=p$，p 为随机隐藏隐含层节点的比例。

3 结果与讨论

3.1 棉涤混纺样品的近红外光谱分析

选择棉涤混纺样品中棉含量较高、涤纶含量较高以及棉和涤纶含量相当的三种具有代表性的样品用于近红外光谱分析，这三种样品的原始光谱如图 3 所示。由图 3 可知：在 1000～1800 nm 光谱范围内，棉含量高的样品在 1217 nm 和 1490 nm 附近存在较宽的光谱吸收峰，这两处峰分别归属于 C—H 伸缩振动的二级倍频谱带和 O—H 伸缩振动的一级倍频谱带；涤纶含量高的样品在 1129 nm 和 1660 nm 附近有两个尖锐的吸收峰，其中 1660 nm 附近的吸收峰为 C—H 伸缩振动的一级倍频谱带[18]；棉和涤纶含量相当的则同时具有两者的吸收特征，并且各自的吸收峰强度会随着其含量的增加而增加。因此，可以利用近红外光谱检测技术实现纺织品内各纤维成分的定量分析。

3.2 光谱预处理

由于棉涤混纺样品的近红外光谱数据具有高维度、非线性等特征，因此在建立定量分析模型前，有必要对原始光谱数据进行预处理，否则会严重影响模型的运行时间和预测效果。作为一种光谱预处理方法，小波变换可以实现背景噪声与真实光谱信号的有效分离，凸显光谱的特征信息，并可起到数据压缩的作用。本文采用重构误差最小的 Daubechies2 小波基函数进行三尺度分解与重构，使光谱数据点由原先的 800 维压缩至 102 维，压缩率为 12.75%。采用小波变换对光谱进行预处理的结果如图 4 所示。通过比较棉涤混纺样品的原始光谱和重构光谱可以发现，小波变换能够保证在光谱主要特征信息基本不变的前提下，实现原始光谱数据的有效压缩，降低了模型的复杂度，缩短了建模时间。

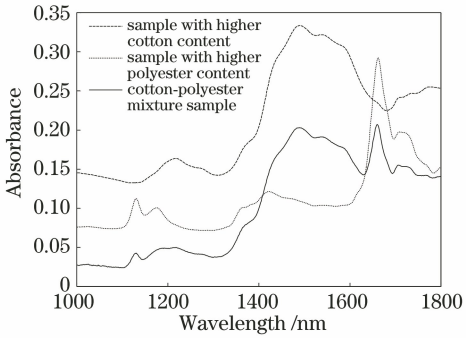

图 3 棉涤混纺织物样品的近红外光谱

Fig. 3 NIR spectra of cotton-polyester blended fabric samples

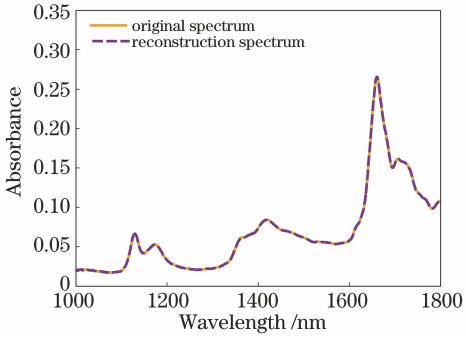

图 4 采用小波变换预处理后的光谱

Fig. 4 Spectrum preprocessed with wavelet transform

3.3 网络模型的确定

采用 SPXY 算法按照 3∶1的比例划分 308 个棉涤混纺样品，其中训练集中的 231 个样品用于建立分析模型，预测集中的 77 个样品用于检验模型的可靠性及稳定性。经小波变换降维得到的棉涤混纺样品的光谱数据为 102 维，故 DBN 第一层 GRBM 的输入层节点数设为 102；又由于本文分别对棉涤混纺样品中的棉、涤纶含量进行预测，故将最后一层 GRBM 的输出层节点数设为 1。

在建立 DBN 模型时，需要根据数据集的特征合理设计 DBN 结构，即确定最优的 GRBM 层数和各层 GRBM 的隐含层节点数。若层数和节点数过少，则易导致输入数据特征信息丢失，而过多则会有更多的参数参与网络模型的训练，模型容易发生过拟合，不利于泛化。本文采用枚举法，结合棉涤混纺样品的光谱数据特征设计了 9 种 DBN 结构，通过比较不同 DBN 结构的模型性能，确定最优的网络结构。不同 DBN 结构的模型性能比较如表 2 所示。

由表 2 可知，模型性能随着 GRBM 层数和各层 GRBM 的隐含层节点数的变化而变化。本文以网络的平均误差和各层 GRBM 的重构误差为参考指标。当 GRBM 层数确定为 3，并且 GRBM1、GRBM2 和 GRBM3 的隐含层节点数分别取 50、20、10 时，重构误差依次为 0.0973、0.0789 和 0.0619，此时网络的平均误差为 0.0794。综合比较，该网络结构是 9 种 DBN 结构中的最优网络模型，故最终确定的网络结构为 102-50-20-10。

表 2 不同 DBN 结构的模型性能比较

Table 2 Model performance comparison of different DBN structures

DBN structure	Mean error	Reconstruction error		
		GRBM1	GRBM2	GRBM3
102-90-50	0.1664	0.2152	0.1176	
102-80-50	0.1676	0.2001	0.1351	
102-70-40	0.2161	0.2569	0.1752	
102-60-30	0.1860	0.2184	0.1535	
102-50-30	0.1036	0.1055	0.1016	
102-80-40-20	0.1328	0.1521	0.1369	0.1095
102-70-30-10	0.1803	0.2291	0.1704	0.1414
102-60-20-10	0.1319	0.1504	0.1429	0.1023
102-50-20-10	0.0794	0.0973	0.0789	0.0619

Dropout 策略通过随机隐藏隐含层节点来改变网络结构，从而提高网络模型的泛化能力以及防止网络陷入局部最优。将 Dropout 比例初值设为 0.05，并以 0.05 为步长逐渐增大至 1，在各 Dropout 比例下训练网络模型。本文采用训练集交互验证的方法，选择交互验证相关系数(R_C)和交互验证均方根误差(RMSECV)作为模型性能的评价指标。模型训练结果如图 5 所示。

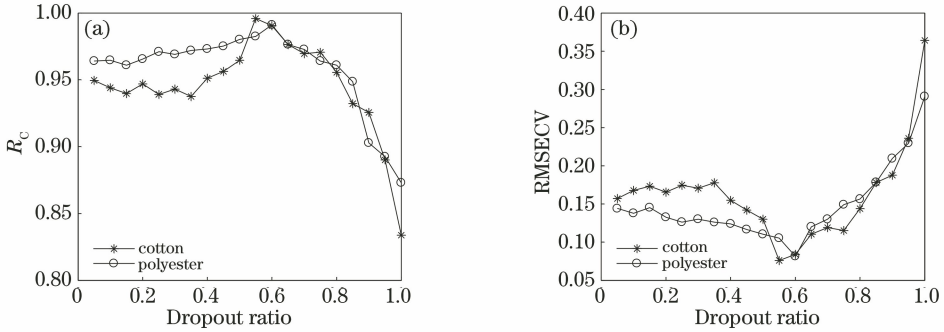

图 5 不同 Dropout 比例对应的模型训练结果。(a) R_C；(b) RMSECV

Fig. 5 Model training results with different Dropout ratios. (a) R_C; (b) RMSECV

通过比较棉涤混纺样品各组分的 R_C 和 RMSECV 在不同 Dropout 比例下的训练结果可以发现：当 Dropout 比例取 0.55 和 0.6 时，棉、涤纶含量的 R_C 达到最大，分别为 0.9959 和 0.9911，RMSECV 达到最小，分别为 0.0760 和 0.0814。此时，棉、涤纶含量的模型效果最优，故最终确定棉、涤纶的 Dropout 比例分别为 0.55 和 0.6，由此建立了棉涤混纺面料含量检测的 Dropout-DBN 模型用于后续的预测分析。

3.4 不同模型的综合比较

采用 Dropout-DBN 模型对预测集样品进行预测分析，选择预测集相关系数(R_P)和预测集均方根误差(RMSEP)作为模型预测能力的评价指标，并将所建模型与 PLS、BP-ANN 和 DBN 方法建立的棉涤混纺面料各组分含量的分析模型进行比较。在 PLS 分析模型中，采用交互验证法确定棉、涤纶的最优潜在变量数(LVs)分别为 4 和 3。在 BP-ANN 分析模型中，选择 102-12-1 的三层网络结构对棉和涤纶的含量进行预测。各模型的预测结果如表 3 所示。

由表3可知，与其他三种模型相比，Dropout-

表 3 各模型的预测结果比较

Table 3 Comparison of prediction results of different models

Model	Cotton		Polyester	
	R_P	RMSEP	R_P	RMSEP
PLS	0.9128	0.2723	0.8957	0.2978
BP-ANN	0.9618	0.1473	0.9709	0.1462
DBN	0.9864	0.1055	0.9839	0.1133
Dropout-DBN	0.9927	0.0792	0.9903	0.0869

DBN 模型的预测效果更为理想，棉、涤纶含量的 R_P 均在 0.99 以上，RMSEP 均在 0.1 以下。由此可见，近红外光谱技术与改进 DBN 模型的有机融合，为棉涤混纺面料中各组分含量的准确检测提供了新方法。Dropout-DBN 方法以其较强的学习和表达能力，更准确地挖掘出了光谱的特征信息，使得所建立的分析模型的稳健性更强并且预测精度更高，对其他领域物质组分的近红外光谱研究具有一定的借鉴意义。

4 结　　论

为了解决棉涤混纺样品光谱数据存在的高维度和非线性等问题，本团队将近红外光谱技术与 Dropout-DBN 方法融合，并验证了该融合方法用于棉涤混纺面料中各组分含量的无损检测是可行且有效的。DBN 模型是深度学习模型中的一种，本文采用 GRBM 代替传统 DBN 的基本组成 RBM，解决了输入数据信息丢失的问题；然后将 DBN 与 Dropout 策略结合，通过改变网络结构实现了网络的稀疏化处理，增强了网络模型的泛化能力。实验结果充分表明，对于采用 Dropout-DBN 方法建立的棉涤混纺面料中各组分含量检测的近红外光谱分析模型，其棉、涤纶含量的 R_P 分别为 0.9927 和 0.9903，RMSEP 分别为 0.0792 和 0.0869。与传统的建模方法相比，利用所提方法建立的模型具有较高的准确性及稳定性，不仅丰富了近红外光谱技术建模智能算法，而且为下一步模型的传递与共享奠定了基础，同时对于其他两组分混纺面料中纤维成分含量的检测研究具有参考价值。

参 考 文 献

[1] Hao Y, Wu W H, Shang Q Y, et al. Analysis model of oleic and linoleic acids in camellia oil via near-infrared spectroscopy[J]. Acta Optica Sinica, 2019, 39(9): 0930004.
郝勇, 吴文辉, 商庆园, 等. 山茶油中油酸和亚油酸近红外光谱分析模型[J]. 光学学报, 2019, 39(9): 0930004.

[2] Liu Y D, Zhang Y, Xu H, et al. Detection of sugar content of pomegranates from different producing areas based on near-infrared spectroscopy [J]. Laser & Optoelectronics Progress, 2020, 57(1): 013002.
刘燕德, 张雨, 徐海, 等. 基于近红外光谱检测不同产地石榴的糖度[J]. 激光与光电子学进展, 2020, 57(1): 013002.

[3] Wang L J, Yang Y Y. Purification and noise elimination of near infrared spectrum in rapid detection of milk components concentration by using principal component weight resetting[J]. Acta Optica Sinica, 2017, 37(10): 1030003.
王丽杰, 杨羽翼. 利用主成分权重重置实现牛奶成分浓度快速检测中近红外光谱的净化去噪[J]. 光学学报, 2017, 37(10): 1030003.

[4] Long J, Wang K, Yang M L, et al. Rapid crude oil analysis using near-infrared reflectance spectroscopy [J]. Petroleum Science and Technology, 2019, 37(3): 354-360.

[5] Li G W, Gao X H, Xiao N W, et al. Estimation of soil organic matter content based on characteristic variable selection and regression methods[J]. Acta Optica Sinica, 2019, 39(9): 0930002.
李冠稳, 高小红, 肖能文, 等. 特征变量选择和回归方法相结合的土壤有机质含量估算[J]. 光学学报, 2019, 39(9): 0930002.

[6] Han Y L, Li S W, Zheng W R, et al. Prediction of soil-available nitrogen near-infrared spectroscopy based on boosting algorithm [J/OL]. Laser & Optoelectronics Progress. (2020-12-29) [2021-03-08]. http://kns.cnki.net/kcms/detail/31.1690.tn.20201228.1009.004.html.
韩亚鲁, 李绍稳, 郑文瑞, 等. 基于集成提升方法的土壤速效氮近红外光谱回归预测[J/OL]. 激光与光电子学进展. (2020-12-29) [2021-03-08]. http://kns.cnki.net/kcms/detail/31.1690.tn.20201228.1009.004.html.

[7] Xiao H, Yang Z F, Zhang L, et al. Effect of temperature on near-infrared spectrum detection of cement raw meal and compensation method [J]. Chinese Journal of Lasers, 2020, 47(1): 0111001.
肖航, 杨振发, 张雷, 等. 温度对水泥生料近红外光谱检测的影响及补偿方法[J]. 中国激光, 2020, 47(1): 0111001.

[8] Chen H, Tan C, Lin Z, et al. Rapid determination of cotton content in textiles by near-infrared spectroscopy and interval partial least squares [J]. Analytical Letters, 2018, 51(17): 2697-2709.

[9] Wang C H, Liu H Y, Wu X Y, et al. Rapid and nondestructive identification of different pure yarn fabrics based on near infrared spectroscopy[J]. Key Engineering Materials, 2015, 671: 363-368.

[10] Sun X D, Zhu K. Spectral dimensionality reduction for quantitative analysis of cotton content of blend fabrics[J]. International Journal of Clothing Science and Technology, 2019, 31(3): 326-338.

[11] Li H Y, Liu S. A new method for qualitative analysis of near infrared spectra of textiles[J]. Spectroscopy

and Spectral Analysis, 2019, 39(7): 2142-2146.
李海洋, 刘胜. 纺织品近红外光谱定性分析的一种新方法[J]. 光谱学与光谱分析, 2019, 39(7): 2142-2146.

[12] Tran D, Do H M, Sheng W H, et al. Real-time detection of distracted driving based on deep learning [J]. IET Intelligent Transport Systems, 2018, 12 (10): 1210-1219.

[13] Kwan C, Chou B, Yang J, et al. Deep learning based target tracking and classification for infrared videos using compressive measurements [J]. Journal of Signal and Information Processing, 2019, 10(4): 167-199.

[14] Shi Y, Wang R J, Wang Y B. Prediction of soil organic matter by improved auto encoder based on near-infrared spectroscopy [J]. Chinese Journal of Luminescence, 2018, 39(10): 1458-1465.
史杨, 王儒敬, 汪玉冰. 利用改进自动编码器光谱法预测土壤有机质[J]. 发光学报, 2018, 39(10): 1458-1465.

[15] Li L Q, Pan X P, Feng Y C, et al. Deep convolution network application in identification of multi-variety and multi-manufacturer pharmaceutical [J]. Spectroscopy and Spectral Analysis, 2019, 39(11): 3606-3613.
李灵巧, 潘细朋, 冯艳春, 等. 深度卷积网络的多品种多厂商药品近红外光谱分类[J]. 光谱学与光谱分析, 2019, 39(11): 3606-3613.

[16] Hu R W, Yu Y, Ni M L, et al. Identification of lotus seed flour adulteration based on near-infrared spectroscopy combined with deep belief network[J]. Food Science, 2020, 41(6): 298-303.
胡仁伟, 俞玥, 倪明龙, 等. 基于深度信念网络的近红外光谱鉴别莲子粉掺假[J]. 食品科学, 2020, 41 (6): 298-303.

[17] Hinton G E. A practical guide to training restricted Boltzmann machines[M]//Montavon G, Orr G B, Müller K R. Neural networks: tricks of the trade. Lecture notes in computer science. Heidelberg: Springer, 2012, 7700: 599-619.

[18] Workman J, Weyer L. Practical guide to interpretive near-infrared spectroscopy[M]. Chu X L, Xu Y P, Tian G Y, Transl. Beijing: Chemical Industry Press, 2009: 219-233.
杰尔·沃克曼, 洛伊斯·文依. 近红外光谱解析实用指南[M]. 褚小立, 许育鹏, 田高友, 译. 北京: 化学工业出版社, 2009: 219-233.