

学校代码： 10255
学 号： 1205085
中图分类法： TS104.1



学术学位博士学位论文

计算机视觉驱动的织物手感多模态评价系统构建

学位申请人：邢博
指导教师：汪军 教授
一级学科：纺织科学与工程
研究方向：数字化纺织工程
所在学院：纺织学院
提交日期：2025年3月

University Code: 10255

Student ID: 1205085

CLC Index: TS104.1



ACADEMIC DOCTORAL DISSERTATION

CONSTRUCTION OF A COMPUTER VISION- DRIVEN MULTIMODAL EVALUATION SYSTEM FOR FABRIC HAND

Author: Bo Xing

Supervisor: Prof. Jun Wang

First-level Discipline: Textile Science and Engineering

Research Field: Visual Fabric Hand Evaluation

College: College of Textiles

Date of Submission: May, 2025

博士学位答辩委员会名单

姓名	职称	单 位	备注
钟跃崎	教授	东华大学	主席
陈廷	教授	苏州大学	委员
辛斌杰	教授	上海工程技术大学	委员
杜赵群	教授	东华大学	委员
徐广标	研究员	东华大学	委员
丁倩	实验师	东华大学	秘书

答辩人：邢博

答辩地点：纺织学院 3035

答辩日期：2025 年 5 月 17 日

计算机视觉驱动的织物手感多模态评价系统构建

摘要

织物手感评价是纺织品设计与质量控制的核心环节,传统方法依赖专家触觉评价或物理仪器测量(如 KES 系统),存在一致性差、效率低、成本高等瓶颈。针对上述问题,本研究提出基于计算机视觉的织物手感评价体系,通过织物视觉表征构建、特征提取、多模态融合建模与知识发现四个层次递进式创新,突破触觉依赖的评价范式,实现织物手感的智能、可解释化评价。论文以“视觉可感知的手感性能评价”为核心假设,围绕表面、压缩、弯曲、拉伸四类可视觉化的手感性能,构建“表征验证-特征提取-数据融合-方法集成”四位一体的理论框架,在 101 种织物样本上完成系统性验证。本文主要贡献如下:

(1)建立视觉表征与手感评价的关联性验证框架。针对视觉评价的适用边界问题,提出基于信号检测理论的双面适用性测试模型,旨在验证哪些手感性能可以通过视觉表征进行评价。通过真实触觉、静态图像、动态视频三模态评价场景的对比实验,构建四因素混合效应方差分析模型,对 101 个织物样本进行感官评价。通过混合效应分析和一致性指数(CCI)计算,结果表明表面、压缩、弯曲与拉伸性能在跨场景评价中表现出较高的一致性(CCI 均大于 0.74),尤其在动态视频中,弯曲和拉伸性能的光流轨迹与触觉评分显著相关($r=-0.67$, $p<0.001$)。然而,热湿性能因视觉特征解释力不足($R^2=0.18$)且在视觉场景中的一致性较低(CCI=0.31)被排除。该研究首次通过统计模型界定视觉评价的适用性边界,为后续特征工程划定有效范围。

(2)构建多尺度视觉特征工程体系。针对视觉表征的量化难题,采用特征工程的思路,利用图像和视频处理技术提取反映手感性能的量化指标。针对 101 个样本,初步设计 33 个视觉特征,包括图像的表面特征(如粗糙度)、弯曲特征(如弯曲刚度)和悬垂特征(波形数)等。为确保特征的有效性和非冗余性,本研究引入方差膨胀因子和 Lasso 回归进行特征筛选,最终保留 22 个关键特征。这些特征与 KES 物理测量数据(粗糙度、压缩恢复率、弯曲刚度等)的一致性分析显示,平均绝对百分比误差低于 2%,且与感官评分的相关系数均在 0.79 以上,验证所提指标体系的物理可解释性和统计一致性。该体系突破传统图像特征的碎片化局限,建立具有物理可解释性的视觉指标库。

(3)设计多模态融合的端到端评价模型。为克服单一模态信息缺失问题,进一步提出一种多模态融合的端到端手感评价模型 TAIL (Textile Attribute Integration and Learning),将上述 22 个数值型特征与图像、视频数据相结合,实现手感评价的全面建

模。该模型通过动态时间规整对齐多模态特征，并采用注意力机制和时序卷积网络进行融合，针对回归任务（手感评分预测）、分类任务（风格分类）和决策任务（用途适配性推荐）进行联合训练。在 101 个样本的测试中，模型在回归任务重的均方误差（MSE）为 0.258，分类任务的 Micro-F1 值为 0.921，决策任务的准确率为 92.3%，显著优于单模态和双模态基准模型（MSE=0.412，F1=0.823）。实验结果表明，多模态融合充分利用数值数据的量化能力、图像数据的静态细节和视频数据的动态信息，实现对手感性能的全方位表征。

（4）提出可解释性增强的知识发现模型。考虑到 TAIL 模型的可解释性不足，本研究提出一种基于知识发现的织物手感评价知识发现方法，结合层次分析法（AHP）与粗糙集理论（RST）构建混合模型。该模型首先通过 AHP 优化感官描述词权重（一致性比率 $CR \leq 0.1$ ），然后利用 RST 进行属性约简和知识挖掘。在 101 个样本上提取 155 条 IF-THEN 解释性映射，如“Smooth(5)→Silk”，映射的置信度和覆盖度通过双目标 Pareto 优化得到均衡提升（调和均值提高 18.7%），实验结果显示，模型的 F1-score 达 0.91，决策准确率为 87.3%，专家评价其可理解性（4.3/5）和逻辑合理性（4.6/5）均优于传统经验映射库（3.1/5）。这一方法不仅增强评价系统的透明性，还为面料选材和产品设计提供显示化决策支持。

（5）实现智能化评价软件系统。本研究将视觉特征提取、多模态融合模型（TAIL）和 AHP-RST 解释功能集成于织物手感评价软件系统，实现从多源数据输入到手感预测与解释输出的端到端智能化流程。系统通过数据输入模块处理图像、视频和感官评分，特征提取模块生成 22 个量化指标，预测模块输出评分、分类和推荐结果，解释模块提供显式映射，可视化模块增强交互性。系统的核心优势在于其自动化与高效性，用户只需上传织物样本的多模态数据，即可获得从量化评分到风格分类，再到用途推荐的全方位评价结果，同时通过可视化界面直观展示特征分布与决策依据。相较传统手动流程，系统效率显著提升，为纺织工业的质量控制与面料选材提供高效、透明的数字化工具。

综上所述，本论文通过多阶段研究实现基于视觉表征的织物手感多层次评价，从关联性验证到特征体系构建，再到多模态融合和知识映射提取，系统解决传统方法的主观性、低效性和不可解释性问题。研究成果表明，表面、压缩、弯曲和拉伸性能可以通过视觉数据有效评价，所提出的特征工程体系和多模态模型显著提升评价精度和实用性，而知识发现方法进一步增强系统的可解释性。这些创新为纺织工程领域的数字化和智能化发展提供重要的理论贡献和技术支持。未来研究可进一步探索多模态数据（如物理测试数据和用户行为数据）的深度融合，构建更普适的知识图谱，并将评价系统应用于实时生产场景，以推动纺织行业的全面智能化。

关键词：织物手感；计算机视觉；视觉表征；感官测试；多模态融合；知识发现

Construction of a computer vision-driven multimodal evaluation system for fabric hand

ABSTRACT

Fabric hand evaluation is a critical aspect of textile design and quality control. Traditional methods rely heavily on expert tactile assessment or physical instrument measurements (e.g., the KES system), which suffer from strong subjectivity, low efficiency, and high costs. To address these challenges, this study proposes a fabric hand evaluation system based on computer vision, achieving progressive innovations through four key layers: visual representation construction, feature extraction, multimodal fusion modeling, and knowledge discovery. This approach breaks through the paradigm of tactile dependency, enabling intelligent and interpretable fabric hand assessment. Centered on the core hypothesis of "visually perceptible hand performance evaluation," the study focuses on four visually assessable hand properties—surface, compression, bending, and stretching—and establishes an integrated theoretical framework of "representation validation-feature extraction-data fusion-method integration." Systematic validation was conducted on 101 fabric samples. The main contributions of this study are as follows:

(1) Establishment of a Validation Framework for the Correlation Between Visual Representation and Hand Evaluation. To define the applicability boundaries of visual assessment, a dual-aspect applicability testing model based on signal detection theory was proposed to determine which hand properties can be effectively evaluated through visual representation. Comparative experiments were conducted across three modalities—real tactile sensation, static images, and dynamic videos—using a four-factor mixed-effects analysis of variance model to assess sensory evaluations of 101 fabric samples. Through mixed-effects analysis and consistency index (CCI) calculations, the results demonstrated high consistency ($CCI > 0.74$) across scenarios for surface, compression, bending, and stretching properties. Notably, in dynamic video scenarios, optical flow trajectories of bending and stretching properties showed significant correlation with tactile scores ($r = -0.67, p < 0.001$). However, thermal-moisture properties were excluded due to insufficient explanatory power of visual features ($R^2 = 0.18$) and low consistency in visual scenarios ($CCI = 0.31$). This study pioneers the use of statistical models to delineate the applicability boundaries of visual assessment, providing a clear scope for subsequent feature engineering.

(2) Construction of a Multiscale Visual Feature Engineering System. To tackle the challenge of quantifying visual representations, a feature engineering approach was adopted, leveraging image and video processing techniques to extract quantitative indicators reflecting hand performance. For the 101 samples, 33 visual features were initially designed, including surface characteristics (e.g., roughness), bending characteristics (e.g., bending stiffness), and drape characteristics (e.g., wave frequency). To ensure feature effectiveness and non-redundancy, variance inflation factor (VIF) and Lasso regression were employed for feature selection, resulting in 22 key features. Consistency analysis with KES physical measurement data (e.g., roughness, compression recovery rate, bending stiffness) showed an average absolute percentage error below 2%, with correlation coefficients with sensory scores exceeding 0.79, validating the physical interpretability and statistical consistency of the proposed system. This system overcomes the fragmented limitations of traditional image features, establishing a physically interpretable visual indicator library.

(3) Design of an End-to-End Multimodal Fusion Evaluation Model. To address the limitations of single-modality information, an end-to-end hand evaluation model, TAIL (Textile Attribute Integration and Learning), was developed. This model integrates the 22 numerical features with image and video data for comprehensive hand assessment. By employing dynamic time warping for multimodal feature alignment, along with attention mechanisms and temporal convolutional networks for fusion, the model supports joint training for regression tasks (hand score prediction), classification tasks (style classification), and decision tasks (usage suitability recommendation). Testing on 101 samples revealed a mean squared error (MSE) of 0.258 for regression tasks, a Micro-F1 score of 0.921 for classification tasks, and an accuracy of 92.3% for decision tasks, significantly outperforming single- and dual-modality baseline models (MSE = 0.412, F1 = 0.823). These results demonstrate that multimodal fusion effectively leverages the quantitative precision of numerical data, static details from images, and dynamic information from videos, achieving a holistic representation of hand performance.

(4) Proposal of an Interpretability-Enhanced Knowledge Discovery Model. To mitigate the interpretability shortcomings of the TAIL model, a knowledge discovery approach for fabric hand evaluation was introduced, combining Analytic Hierarchy Process (AHP) and Rough Set Theory (RST) into a hybrid model. The model first optimizes sensory descriptor weights using AHP (consistency ratio $CR \leq 0.1$), followed by RST for attribute reduction and knowledge extraction. From the 101 samples, 155 IF-THEN mappings (e.g., "Smooth(5) \rightarrow Silk") were derived, with confidence and coverage balanced through dual-objective Pareto

optimization (harmonic mean improved by 18.7%). Experimental results showed an F1-score of 0.91 and a decision accuracy of 87.3%, with expert evaluations rating interpretability (4.3/5) and logical coherence (4.6/5) higher than traditional empirical mapping libraries (3.1/5). This method not only enhances the transparency of the evaluation system but also provides explicit decision support for fabric selection and product design.

(5) Implementation of an Intelligent Evaluation Software System. This study integrates visual feature extraction, the TAIL multimodal fusion model, and AHP-RST interpretability functions into a fabric hand evaluation software system, achieving an end-to-end intelligent workflow from multisource data input to hand prediction and interpretation output. The system processes images, videos, and sensory scores through a data input module, generates 22 quantitative indicators via a feature extraction module, outputs scores, classifications, and recommendations through a prediction module, provides explicit mappings via an interpretation module, and enhances interactivity with a visualization module. Its core strength lies in automation and efficiency: users simply upload multimodal data from fabric samples to obtain comprehensive evaluation results—from quantitative scores to style classifications and usage recommendations—while visualizing feature distributions and decision rationales through an intuitive interface. Compared to traditional manual workflows, the system significantly boosts efficiency, offering a highly effective and transparent digital tool for quality control and fabric selection in the textile industry.

In summary, this dissertation achieves a multilayered fabric hand evaluation based on visual representation through phased research, spanning correlation validation, feature system construction, multimodal fusion, and knowledge mapping extraction. The findings confirm that surface, compression, bending, and stretching properties can be effectively assessed via visual data, with the proposed feature engineering system and multimodal model markedly improving evaluation accuracy and practicality, while the knowledge discovery approach further enhances system interpretability. These innovations provide significant theoretical contributions and technical support for the digitalization and intelligent advancement of textile engineering.

Doctoral Candidate: Bo Xing (Textile Materials and Textiles Design)

Supervised by Prof. Dr. Jun Wang

KEY WORDS: fabric hand, computer vision, visual representation, sensory testing, multimodal fusion, knowledge discovery

目 录

第 1 章 绪论.....	1
1.1 课题研究背景和意义.....	1
1.1.1 课题研究背景.....	1
1.1.2 课题研究意义.....	2
1.2 国内外相关文献综述.....	3
1.2.1 手感风格评价方法.....	3
1.2.2 计算机视觉.....	5
1.2.3 多模态融合.....	8
1.2.4 知识发现.....	12
1.3 当前研究中存在的主要问题.....	14
1.3.1 存在问题.....	14
1.3.2 拟解决的问题.....	15
1.4 本课题研究目标、内容及创新性.....	15
1.4.1 本课题研究目标.....	15
1.4.2 本课题研究内容.....	16
1.4.3 本课题技术路线.....	16
1.4.4 本课题创新点.....	16
第 2 章 织物手感与视觉表征关联性的跨模态证.....	18
2.1 引言.....	18
2.2 视觉-触觉跨模态评价框架构建.....	19
2.2.1 模型构建思路.....	19
2.2.2 两步评分双面适用性评价模型.....	20
2.2.3 评价指标.....	21
2.2.4 参数优化与模型改进.....	21
2.3 实验设计.....	22
2.3.1 织物样本选取.....	23
2.3.2 视觉表征创建.....	23
2.3.3 评价小组构建.....	24
2.3.4 评价方法设计.....	25
2.3.5 数据处理.....	27
2.4 实验结果.....	29
2.4.1 四因素混合效应结果.....	29
2.4.2 信号检测 d_A' 结果.....	31
2.5 分析与讨论.....	31

2.5.1 手感性能显著性分析.....	31
2.5.2 手感性能一致性分析.....	33
2.5.3 热湿性能的视觉不可评价性分析.....	35
2.6 本章小结.....	36
第3章 织物手感视觉量化指标的体系化构建与优化.....	37
3.1 引言.....	37
3.2 面向织物手感的视觉量化模型构建.....	38
3.2.1 模型构建思路.....	38
3.2.2 多尺度织物手感的视觉量化模型.....	39
3.2.3 评价指标.....	42
3.3 视觉特征指标体系设计.....	42
3.3.1 样本预处理.....	43
3.3.2 视觉特征提取与指标构建.....	43
3.3.3 指标体系概述与软件集成.....	59
3.4 特征选择与验证.....	60
3.4.1 冗余度分析.....	60
3.4.2 一致性验证.....	64
3.5 本章小结.....	71
第4章 多模态融合织物手感评价模型的设计与证.....	73
4.1 引言.....	73
4.2 TAIL 框架的整体设计.....	75
4.2.1 单模态特征预编码.....	75
4.2.2 多模态特征融合.....	77
4.2.3 注意力机制与特征加权.....	78
4.2.4 多任务预测与联合优化.....	79
4.2.5 评价指标.....	80
4.3 实验设计与数据集构建.....	82
4.3.1 数据输入与预处理.....	82
4.3.2 实验设置.....	83
4.3.3 参数配置.....	83
4.4 实验结果与分析.....	84
4.4.1 回归任务性能.....	84
4.4.2 分类任务性能.....	85
4.4.3 决策任务验证.....	87
4.4.4 对比实验.....	88
4.4.5 消融实验.....	89
4.5 本章小结.....	90
第5章 织物手感多模态评价的知识发现与解释优化.....	92

5.1 引言.....	92
5.2 AHP-RST 混合模型设计	94
5.2.1 层次分析法权重优化.....	94
5.2.2 粗糙集属性约简与知识挖掘.....	94
5.2.3 评价指标.....	96
5.2.4 对比方法.....	96
5.3 实验验证与结果分析.....	96
5.3.1 实验设计与数据准备.....	96
5.3.2 实验结果.....	98
5.3.3 结果分析.....	102
5.4 本章小结.....	102
第 6 章 织物手感评价软件系统的设计与实现	104
6.1 引言.....	104
6.2 软件架构设计.....	105
6.2.1 整体架构概述.....	105
6.2.2 模块划分与功能设计.....	106
6.2.3 技术栈与实现考虑.....	108
6.3 软件实现.....	108
6.3.1 界面开发.....	109
6.3.2 模块实现.....	110
6.4 本章小结.....	117
第 7 章 结论与展望	119
7.1 结论.....	119
7.2 不足与展望.....	120
参考文献.....	121

第 1 章 绪论

织物手感作为纺织品质量评价的核心指标,直接影响消费者的感官体验和产品的市场竞争力,是纺织工程领域的重要研究课题。传统的手感评价依赖人工主观判断或昂贵的物理测试设备,存在一致性差、效率低和成本高的问题,难以满足现代工业对高效、客观评价的需求。随着计算机视觉和人工智能技术的快速发展,利用视觉表征(如图像和视频)实现手感评价成为可能,为纺织行业的数字化和智能化转型提供新路径。本论文以织物视觉表征为核心,探索通过特征工程、多模态融合和知识发现技术,构建一套从原始数据到手感评价的端到端评价系统,旨在解决传统方法的局限性,推动织物手感评价的客观化和智能化。本章将从研究背景与意义出发,回顾相关文献,明确研究问题与目标,并概述技术路线和章节安排。

1.1 课题研究背景和意义

1.1.1 课题研究背景

织物手感是纺织品物理性能与人类感官感知的综合体现,涵盖表面粗糙度、压缩弹性、弯曲柔韧性、拉伸强度和热湿特性等多维属性,直接决定产品的舒适性和市场接受度^[1]。在传统纺织工业中,手感评价主要依赖人工触摸,由专业人员或消费者通过感官描述(如“柔软-粗糙”“弹性-僵硬”)进行主观评分^[2],国际标准如 AATCC 202-2014^[3]和 ISO 12947-1^[4]提供规范指导。这种方法的直观性使其成为早期质量控制的基础,但其主观性强、一致性差的缺陷日益凸显。例如,Shin 等^[5]发现,不同评价者因经验和文化背景差异对手感评分存在显著偏差,难以满足工业标准化的要求。此外,人工评价效率低下,难以适应大规模生产的需求,成为制约纺织行业发展的瓶颈^[6]。

为克服主观评价的不足,研究者开发基于物理测量的客观方法,如 Kawabata 评价系统(KES)^[7]和 Fabric Assurance by Simple Testing (FAST)^[8]。KES 通过测量拉伸、剪切、弯曲等 16 个参数量化手感^[9],成为行业标杆。这些系统通过量化织物的力学性能间接推断手感,提供一定程度的客观数据。然而,KES 设备昂贵(单套成本超 10 万美元),操作复杂(单次测试耗时约 5 分钟),限制其在中小型企业中的应用;而且,力学参数与人类触觉感知的关联并非完全一致,如 KES 的摩擦系数与“柔软”感知的相关系数仅为 0.6^[10]。这些局限性促使研究者探索更高效、低成本的评价技术,推动非接触式方法的兴起。

计算机视觉技术的快速发展为织物手感评价提供新的可能性。织物的视觉表征通过图像捕捉织物表面的纹理和颜色特征^[11-13],通过视频记录动态形变行为^[14-16],为手感的客观量化开辟新路径。已有研究表明,图像的灰度共生矩阵(GLCM)能够表征表面粗

糙度^[17]，视频的光流分析可反映弯曲和拉伸特性^[14]。然而，视觉表征能否有效替代触觉评价，哪些性能可以通过图像和视频量化，仍需系统验证。如何界定视觉表征的有效边界，并建立与触觉感知的关联，是实现非接触式评价的基础问题。

另一方面，尽管视觉表征具有潜力，如何从视觉数据中提取手感相关特征并实现精准量化，也是当前研究的一个关键问题。特征工程作为计算机视觉技术的关键组成，用于提取、转换和优化视觉数据，不仅能够挖掘视觉数据中的有效信息，还为建立定量评价模型奠定基础^[18]。然而，手感作为一种复杂的多模态感知体验，其与视觉特征之间的映射关系并非线性且难以直接捕捉。如何设计一套物理意义明确且统计一致的视觉特征体系，仍是当前研究的难点。

同时，借助深度学习技术，尤其是卷积神经网络的强大特征提取能力，可以自动学习视觉数据与手感特征之间的复杂映射关系，从而实现从海量视觉数据中提取手感相关特征的目标^[12, 19]。此外，单一模态数据的局限性进一步凸显多模态融合的必要性和必要性。图像缺乏动态信息，视频难以捕捉细微纹理，单一模态难以全面表征手感的复杂性。多模态融合虽在其他领域取得进展^[20]，但在织物手感评价中尚未深入探索。如何整合数值、图像和视频数据，实现端到端评价，是亟待解决的问题。

此外，深度学习模型在提升预测精度的同时，其“黑箱”特性限制结果的可解释性，难以满足工业场景对透明决策的需求。现有知识发现方法（如粗糙集）生成的映射覆盖率和质量有限，难以直接指导面料选择或质量控制^[21]。如何通过知识发现增强评价系统的可解释性，为工业应用提供显式映射，是一个重要挑战。

1.1.2 课题研究意义

（1）学术意义

本文通过计算机视觉技术结合多模态数据融合方法，致力于构建织物手感的智能评价体系，旨在实现织物手感的客观化、数字化和智能化评价。通过系统研究织物视觉表征与机械性能之间的关联性，并构建特征体系与多模态融合模型，本研究将揭示视觉特征与织物手感之间的内在映射机制。这不仅为织物手感评价在感官-视觉跨模态研究方面提供支撑，还对推动计算机视觉与纺织工程领域的理论发展具有重要的科学价值。此外，本研究提出的多模态融合框架与知识发现方法，为织物手感评价的数字化提供系统性框架，丰富相关领域的研究体系。

（2）实用价值

本研究探索的计算机视觉技术与多模态数据融合方法的结合，有效解决传统织物手感评价过程中存在的主观性强、效率低和精准度不足等问题。通过实现织物手感的高效、精准和可解释评价，本研究提升织物评价过程的客观性和可靠性。所开发的智能评价系统在纺织行业的质量控制、远程检测和智能推荐等场景中表现出优异的适应性，且在功能性纺织品开发、虚拟试衣与智能质检等领域展现出广阔的应用前景。此外，本研究的

创新技术为纺织行业的智能化转型提供有力支持，推动行业技术升级和新材料应用。研究成果不仅为传统纺织产业的数字化转型提供技术支持，还为智能纺织品、高端功能性材料的开发开辟新的应用路径，具有显著的经济和社会价值。

1.2 国内外相关文献综述

织物手感评价是纺织工程领域的重要研究方向，其发展历程从人工主观判断逐步过渡到客观测量和数字化技术。本节回顾传统评价方法的研究现状，梳理计算机视觉、多模态融合和知识发现技术在相关领域的应用进展，分析现有研究的不足，为本论文的研究目标和方法提供理论基础。

1.2.1 手感风格评价方法

织物手感 (fabric hand)，又称织物风格，是人类通过触觉、视觉等多感官通道，对纺织品机械属性（如弯曲刚度、表面摩擦）与心理感知（如舒适度、审美价值）的综合认知反馈^[22]。其本质是物理性能与主观体验的复杂映射关系——纤维成分（棉、丝、化纤）决定基础力学特性，织造工艺（平纹、斜纹、提花）塑造微观结构，后整理技术（磨毛、压光）调控宏观表现，三者共同作用于人体感知系统，最终形成“硬挺”、“滑糯”、“蓬松”等主观评价^[23,24]。这种多维度的交互特性使得织物手感不仅是一个物理问题，更是一个涉及材料科学、心理学和文化背景的跨学科问题^[25-27]。也因此，围绕织物手感评价体系的百年发展史，是一部人类突破感官局限、探索量化真理的科技史诗。其演进脉络可划分为四大阶段（如图 1-1），每一阶段均以标志性技术突破回应时代需求，同时为下一阶段埋下革新伏笔。

主观经验主导期（1920s-1950s）。20 世纪初期，纺织工业的规模化生产催生对手感评价的初步探索。1926 年，英国纺织学家 Binns^[28]首次提出“织物手感”概念，将其定义为“织物物理属性通过触觉、视觉等感官产生的综合心理效应”。这一阶段的核心矛盾在于：工业化生产需要标准化评价，但技术手段局限于人工经验，仅能依靠有经验的检验员用感官语言对织物手感进行描述，如“柔滑”、“粗糙”等，缺乏统一标准和量化依据^[29]。各企业和实验室往往采用自定的一套术语和感官尺度，评价结果难以复现和比较^[30]。1930 年，美国学者 Peirce^[31]的悬臂梁试验成为转折点，通过弯曲刚度公式首次将手感与力学参数关联，揭示客观量化的可能性。然而，二战前的技术条件限制仪器发展，主流评价仍依赖“一捏二摸三抓四看”的工匠经验^[32]。直到 20 世纪下半叶，行业组织才开始制定手感评价标准方法（如 1990 年 AATCC 发布主客观结合的手感评定标准^[33]），主观评价的随机性和主观性问题才逐步受到重视并着手改进。

力学仪器量化期（1960s-1990s）。随着纺织科学的发展，研究者在 20 世纪 60 年代起努力将织物手感客观化。Lindberg^[34]在 1950 - 70 年代开展的一系列试验，利用专门

仪器测试织物的弯曲、压缩、拉伸、剪切等低应力力学性能,为客观表征手感奠定基础。1960 年代末, Lundgren^[35]提出手感评价的新概念,主张采用量化指标替代纯主观描述。这一思路推动手感仪器测试技术的兴起。1972 年,日本川端 (Kawabata) 等成立手感评定标准化委员会 (HESC), 开创系统化的客观手感评价方法^[34]。他们开发出著名的 KES 手感测量系统^[7], 通过专门仪器分别测量织物的拉伸、纯弯曲、剪切、压缩以及表面摩擦和粗糙度等 16 项指标, 再基于经验公式计算出织物的主要手感值和总手感值。KES 的诞生标志着织物手感评价进入参数化时代——织物手感第一次被赋予可量化的数值。川端等人提出的手感评价方法包含初级手感值 (柔软、丰满、硬挺、光滑等几个维度) 以及综合的总手感值, 能够较好地预测人体触感^[36]。由于测量全面、结果与主观评价相关性高, KES-F 被公认为当时最完善的客观手感评价体系。然而, KES 系统造价高昂、操作复杂, 需要多台精密仪器配合使用, 这在一定程度上限制其在普通纺织企业中的推广。为提高实用性, 1980 年代澳大利亚联邦科工组织开发较简化的 FAST 系统^[8]。FAST 仅由压缩、弯曲和延伸三个测试单元组成, 主要测量织物抵抗变形的性能, 不涉及应力松弛恢复的测试。尽管信息量不及 KES-F, FAST 由于成本低、操作简单, 更适合工厂快速检测^[1]。同期美国推出 Handle-O-Meter 等^[37]专用仪器, 通过一个狭缝和探头装置测量织物的柔软度 (弯曲变形) 和表面摩擦力, 从而得到反映手感的综合读数。这类仪器可以在几秒钟内完成测试, 显著提高手感评价的一致性和效率。到 1990 年代, 随着计算技术的发展, 研究者开始尝试用模型和算法融合主客观结果。例如, Hu 等^[38]引入 Stevens 心理物理幂律模型, 将客观测量值转换为与手感觉线性相关的尺度; Kim 和 Slaten 等^[39]则采用主成分分析等统计方法提取客观测试的关键因子, 并用回归和模糊逻辑预测消费者对手感的评分; 潘宁等提出法宝仪 (PhabrOmeter)^[40], 通过信号转换手段实现织物手感的快速客观评价。总体来说, 在这一阶段, 织物手感评价实现从定性到定量的飞跃, 各种力学测试方法层出不穷, 为后来更先进的评价技术奠定基础。

仿生传感探索期 (2000s-2010s)。进入 21 世纪, 单纯的力学量化指标虽提高客观性, 但仍难以完整模拟人手的触觉体验。为进一步拉近仪器测量与人类触感的差距, 学者们开始探索仿生传感的手感测试手段, 即尽可能模拟人手触摸织物的方式来获取多维度的信息。2017 年, Yuan 等^[41]开发的 GelSight 触觉传感器, 通过弹性体涂层与光学成像结合, 实现 40 μm 分辨率的表面纹理重构, 首次将视觉与触觉数据融合。2019 年, 东华大学团队提出 QIHES 系统 (Quick-Intelligent Handle Evaluation System)^[42], 模仿人手五指动作, 集成压力、位移、图像多传感器, 实现压缩、弯曲、摩擦的原位同步测量, 设备成本降低 40%。此阶段的核心突破在于认知转变, 即手感不仅是力学参数的函数, 更是多模态感知的涌现效应。Chen 等^[43]开发一种指状滑动传感器, 在一个仿真指腹上集成柔性压电薄膜, 当传感器以恒定压力滑动于织物表面时, 表面的细微纹理会引起薄膜电荷输出的变化。通过对输出信号进行频域分析和主成分特征提取, 再用模式识别算法分类, 成功区分出不同织物的表面触感差异。实验表明, 该指尖传感器能够有效识别

5种亚麻织物的质地差别，分类准确率较高。又例如，市场上推出的 Fabric Touch Tester (FTT)^[44]将多个传感模块集成在一台设备中：同时测量织物的厚度和压缩特性、弯曲刚度、表面摩擦系数、表面粗糙度以及热通量等多达13项参数，一次试验即可获得织物触感的完整“指纹”特征。FTT的设计理念正是尽可能模拟人手触摸织物时施加的各种作用（按压、弯折、滑动触摸、手温传递等），因此被视为仿生手感测试的重要进展。仿生传感期的研究大大拓展手感客观评价的维度，使测试结果更贴近人的真实触感体验。不过，此阶段的许多技术仍处于实验室探索或样机验证阶段，设备复杂度和成本较高，尚未大规模应用于工业现场。

智能融合突破期（2020s-至今）。进入2020年代，数字化和智能技术为织物手感评价带来突破性契机。本阶段的特征是在非接触式测试和人工智能算法方面取得重要进展，实现对织物手感的快速预测和客观评价^[45]。首先，计算机视觉被用于手感相关特征的提取。通过高速摄像^[46]或三维扫描^[47]，可以记录织物的悬垂形态、表面纹理等外观信息，然后利用图像分析算法量化这些信息与手感之间的关联^[48]。其次，强大的数据驱动能力使人工智能评价成为可能。基于模式识别和深度学习的模型可以从大量已知样本中学习织物客观参数与主观手感评价之间的复杂非线性关系^[12, 49]。与传统方法相比，视觉/智能融合的手感评价具备非接触、实时、低成本的优点，无需繁杂的物理仪器接触测试，减少人为因素干扰，能够在线或远程对织物手感进行监测和控制^[50]。这一阶段的技术使得将来在纺织生产线上进行实时手感品控成为可能，也为电子商务中消费者无法触摸实物却想解织物手感的问题提供解决思路。

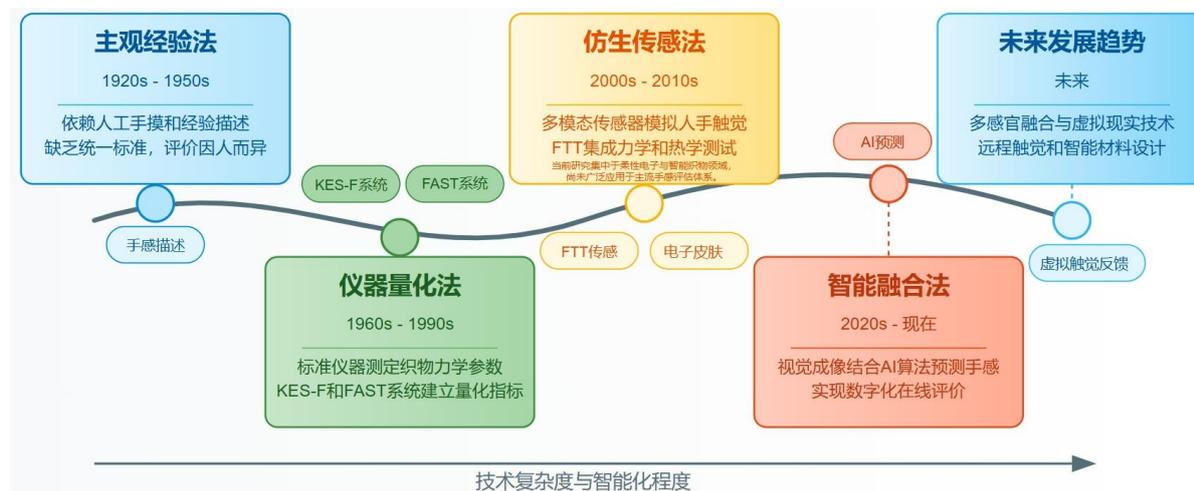


图 1-1 织物手感评价技术发展路线

Figure 1-1 Fabric hand evaluation technology development route

1.2.2 计算机视觉

织物手感作为一个复杂的多维度感知，无法通过语言描述完全量化。随着纺织工业

的现代化和消费者对高质量织物需求的增加,客观、科学的手感评价方法成为研究热点。计算机视觉技术作为一种非接触式、无损的分析工具,近年来在织物手感研究中崭露头角,通过图像分析提取表面特征,为手感的数字化和标准化提供全新视角^[51]。

计算机视觉(Computer Vision, CV)是一门利用摄像设备和算法处理图像以提取有用信息的学科,其核心包括图像采集、预处理、特征提取和模式识别(如图 1-2 所示)。在织物手感研究中,计算机视觉的应用主要集中在表面纹理、纤维排列和结构特性的分析^[13, 52]。织物表面的视觉特征(如纹理粗糙度、纤维方向性)与触觉感知密切相关,因此通过高分辨率图像捕捉这些特性,可以间接推断手感属性。

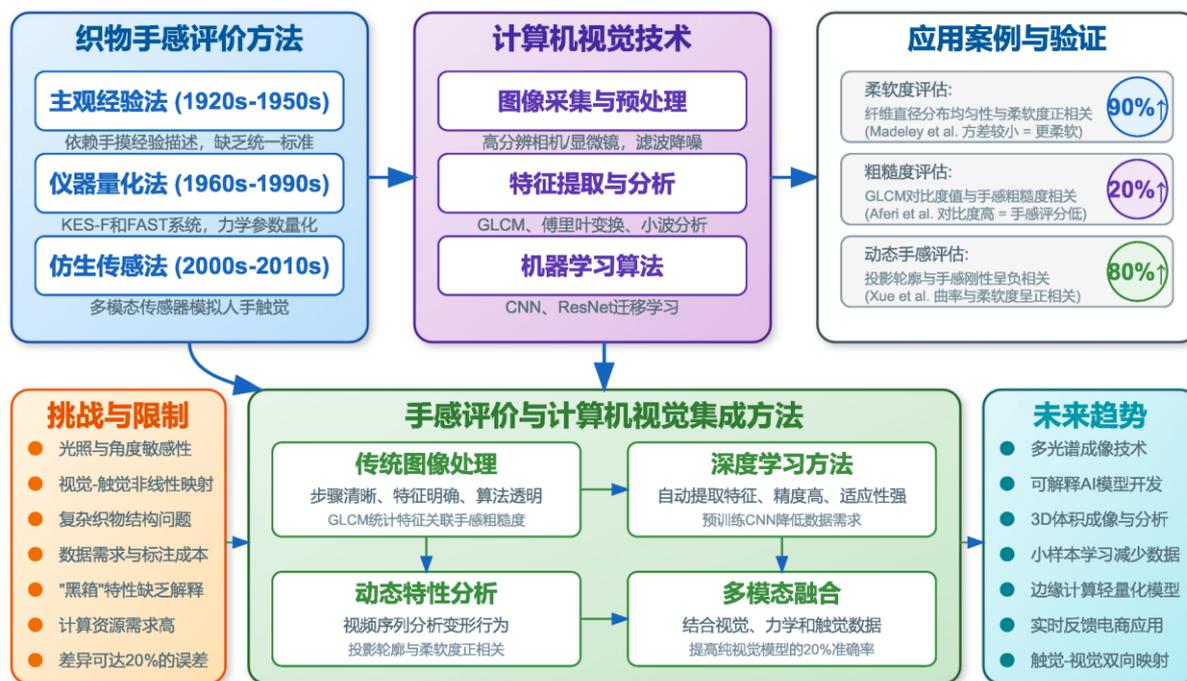


图 1-2 计算机视觉技术在织物手感评价上的应用

Figure 1-2 Application of computer vision techniques to fabric hand evaluation

图像采集是计算机视觉的第一步,通常使用光学显微镜、工业相机或扫描仪获取织物表面的二维图像。现代技术还引入三维成像(如激光三角测量法),能够记录织物的立体结构,进一步丰富数据维度。图像预处理阶段通过滤波、增强和分割技术去除噪声,突出织物纹理。例如,薛婷婷等^[53]采用高斯滤波器平滑棉织物图像,随后通过边缘检测算法提取纤维边界。特征提取则是关键环节,常用的特征包括 GLCM 描述的纹理对比度、熵值,以及傅里叶变换分析的周期性特征^[17, 54, 55]。这些特征通过数学模型与手感属性相关联,最终通过分类或回归算法实现量化评价。

织物手感的核心特性包括柔软度、粗糙度、平滑度和厚度感,这些特性与织物表面形态密切相关。计算机视觉通过量化表面特征,为揭示其与手感的关系提供数据支持。研究表明,纤维的粗细、排列方式和织物密度是影响手感的重要因素,而这些因素在图

像中表现为不同的视觉模式^[56]。例如, Madeley 等^[57]对羊毛织物进行显微成像,发现纤维直径的分布均匀性与手感柔软度呈正相关。他们利用图像分割技术,将纤维区域与背景分离,并计算纤维直径的统计特征(均值和方差),结果显示直径方差较小的织物在主观测试中被评为更柔软。此外,织物表面的粗糙度也直接影响触觉反馈。Aferi 等^[58]使用 GLCM 分析涤纶织物的纹理粗糙度,发现对比度值较高的织物对应的手感评分偏低,表明粗糙表面降低平滑度感知。这些研究证明,计算机视觉能够通过表面特征的量化,建立与手感的映射关系。

动态特性是织物手感研究的另一重要维度。织物在受力下的变形行为(如褶边、悬垂性)对手感评价有显著影响,而静态图像难以捕捉这些信息。为此,近年来研究者开始利用视频序列分析织物的动态响应。例如, Xue 等^[59]通过高速相机记录女士长裙拉伸和弯曲过程中的表面变化,提取投影轮廓和曲率特征,发现投影轮廓与手感刚性呈负相关,而曲率与柔软度呈正相关。这种动态分析不仅丰富手感评价的内容,还为功能性织物(如运动服装)的设计提供参考。

计算机视觉在织物手感研究中的应用主要分为传统图像处理和基于机器学习的方法两大类。传统方法依赖手工设计的特征和统计模型,而机器学习方法则通过数据驱动的方式自动提取特征,具有更高的灵活性和准确性。

(1) 传统图像处理

传统图像处理方法在织物手感与计算机视觉的研究中占据重要地位,尤其在深度学习技术兴起之前,是分析织物表面特征的主要手段。这些方法通常结合图像处理技术和统计分析,通过明确的步骤(如图像预处理、特征提取和相关性建模)提取织物表面的视觉信息,并将其与手感属性关联^[60-63]。尽管相较于现代机器学习方法,传统方法的灵活性和自动化程度较低,但在计算资源有限的场景下,其简单、直观和高解释性的特点仍使其具有重要价值。

传统图像处理方法的核心在于利用数学和统计工具,从织物图像中提取可量化的特征,并通过模型建立这些特征与手感特性(如柔软度、粗糙度、平滑度)的关系。其基本流程包括以下步骤:

①图像采集与预处理。通过光学显微镜、工业相机或扫描仪获取织物表面的高分辨率图像。为减少噪声和光照不均的影响,预处理步骤通常包括灰度化、高斯滤波和对比度增强。例如, Phoophat 等^[64]在分析棉织物时,使用中值滤波去除采集过程中的椒盐噪声,确保后续特征提取的准确性。

②特征提取。从预处理后的图像中提取纹理、边缘或几何特征。常用的技术包括 GLCM、小波变换^[65]和边缘检测^[66]等。这些特征旨在捕捉织物表面的视觉属性,如纤维排列的均匀性或表面粗糙度。

③相关性建模。通过统计方法(如线性回归^[25,67]、相关分析^[68,69]),将提取的特征与主观手感评分或客观力学参数(如 KES 系统的弯曲刚度)关联,实现手感量化评价。

传统方法的优势在于其算法透明、可控性强，且对计算资源的需求较低，适合实验室和小规模工业应用。然而，传统方法的局限性也不容忽视。第一，手工设计的特征依赖研究者的经验，缺乏自适应性。例如，GLCM 对方向敏感，可能无法准确描述非均匀纹理的织物。第二，特征维度有限，难以捕捉复杂织物（如提花织物）的多层次特性，导致模型泛化能力不足。第三，传统方法通常局限于单一模态（视觉数据），无法整合触觉或力学信息，与手感的综合感知存在差距。例如，表面光泽度在图像中表现为高对比度，但在触觉上可能因高摩擦而显得粗糙^[70]，这种矛盾难以通过传统方法解决。

（2）机器学习

随着机器学习和深度学习技术的发展，计算机视觉在织物手感评价中的算法复杂度不断提升，从传统的图像处理方法逐步过渡到智能化的模式识别模型。早期研究多采用基于统计的特征提取方法，例如 GLCM 和局部二值模式（LBP）。例如，Zhu 等^[71]利用 GLCM 分析亚麻织物的纹理均匀性，发现熵值较高的织物在手感测试中被评为更粗糙，而相关性较高的织物则表现出更高的平滑度。这些方法虽然计算简单，但在处理复杂织物（如混纺或多层结构）时，往往因特征维度有限而失去准确性。

深度学习技术的出现显著提升计算机视觉的性能，尤其是卷积神经网络（CNN）在织物图像分析中的应用^[72, 73]。CNN 通过多层次卷积和池化操作，能够自动提取图像中的深层特征，无需人工设计复杂的特征提取映射。Liu 等^[74]训练一个基于 CNN 的模型，对织物的表面图像进行分类，预测其柔软度等级。实验结果显示，该模型的准确率达到 92%，远超传统 GLCM 方法的 78%。此外，结合迁移学习技术，研究者可利用预训练模型（如 VGG16 或 ResNet）对小样本织物数据进行分析，进一步降低数据需求。例如，Geng 等^[75]基于 ResNet 模型对棉涤混纺织物的图像进行特征提取，成功区分不同织造工艺对手感的影响，验证深度学习在手感评价中的鲁棒性。Iqbal 等^[76]基于 ResNet-50 分类涤纶织物手感（柔软、粗糙、中等），精度达 93%，降低数据需求。

织物手感与计算机视觉的结合标志着从主观评价到客观量化的转变。传统图像处理奠定基础，机器学习提升精度，动态分析丰富维度。应用案例表明，计算机视觉在柔软度^[77]、粗糙度^[78]和动态手感评价中表现出色。尽管面临光照稳定性、复杂性适配和计算成本等挑战，未来通过技术进步（如多光谱成像^[79]、多模态融合^[80]），计算机视觉将成为织物手感研究的核心工具，为纺织品设计、质量控制和消费体验优化提供强大支持。

1.2.3 多模态融合

织物手感作为纺织品质量评价的关键指标，涵盖柔软度、粗糙度、平滑度、刚性等多维度触觉特性，传统上依赖单一感官（如触觉或视觉）的评价方法难以全面表征其复杂性。手感不仅是一种物理属性的体现，还涉及视觉、触觉甚至听觉等多感官的综合感知，受纤维类型、织造工艺和后处理等多种因素共同影响。随着传感器技术、计算机视觉和数据融合算法的进步，多模态融合成为织物手感研究的新兴方向，通过整合不同模

态的数据（如视觉图像、触觉信号、力学参数），显著提升评价的全面性和准确性。本节将深入探讨织物手感与多模态融合的研究背景、技术框架、应用案例及其发展前景（如图 1-3 所示）。

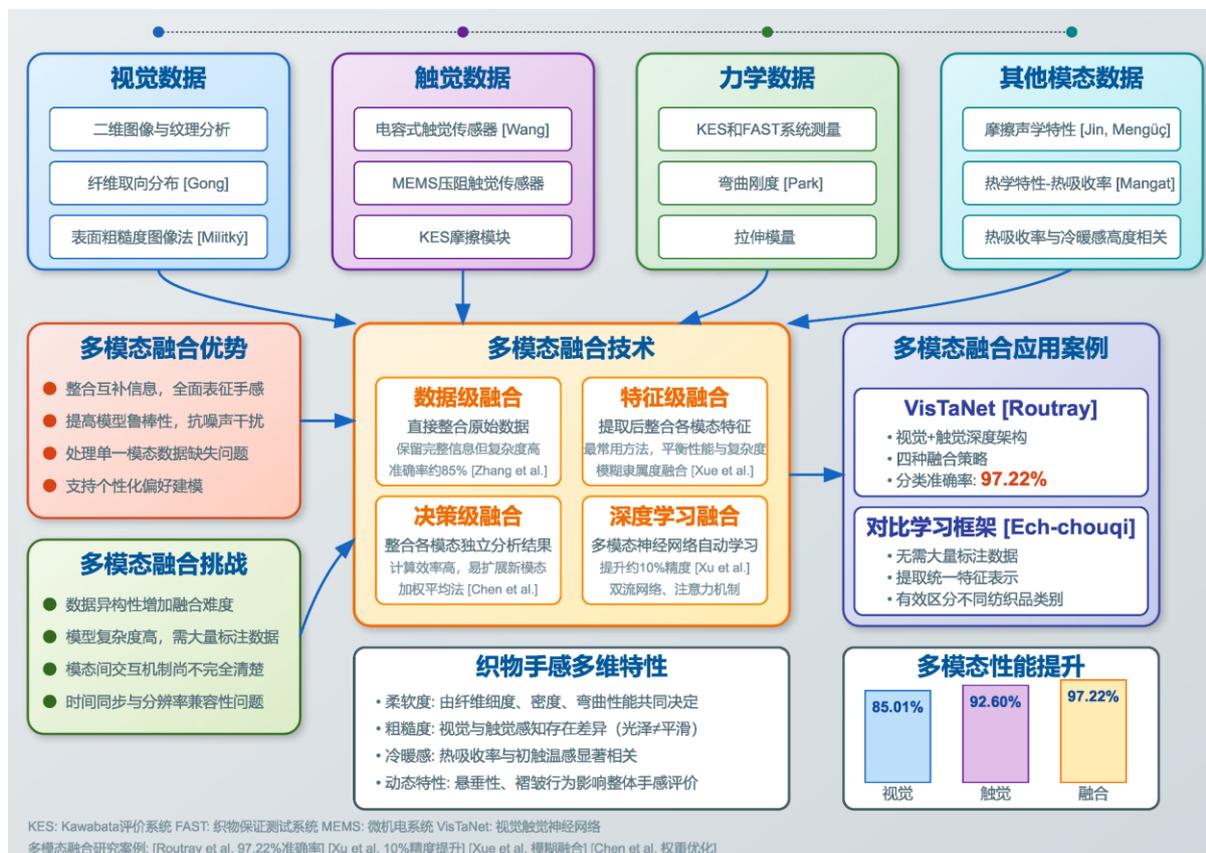


图 1-3 多模态融合技术在织物手感评价上的应用

Figure 1-3 Application of multimodal fusion techniques to fabric hand evaluation

多模态融合是指将来自不同来源或类型的数据集集成到一个统一框架中，以实现更全面的信息表达和分析。在织物手感研究中，多模态融合的目标是克服单一模态（如视觉或触觉）的局限性，捕捉手感的多样化特性。例如，视觉数据可以提供织物表面的纹理和纤维排列信息，触觉数据记录摩擦力和压力反馈，而力学数据则量化织物的刚度和弹性。单独使用任一模态都可能忽略其他感官维度，导致评价结果片面化。

传统手感评价方法，如 KES，主要依赖力学测试，测量弯曲刚度、剪切刚度和摩擦系数等参数，虽然客观性较高，但无法反映视觉感知对手感的影响。同样，计算机视觉技术虽能提取表面特征，却难以直接表征触觉体验。多模态融合通过整合这些互补信息，弥补单一方法的不足。近年来，随着传感器小型化和数据处理能力的提升，多模态融合在纺织领域的研究迅速增加。Routray 等^[81]提出 VisTaNet，一种视觉与触觉数据融合的深度架构，用于表面粗糙度分类。他们构建视觉数据集以补充触觉数据集，并采用求和、

拼接、最大池化和注意力四种融合策略。结果表明,该模型分类准确率达 97.22%,优于仅视觉(85.01%)和仅触觉(92.60%)方法。该模型可实现类似人类纹理感知,模型通过加权组合视觉和触觉模态,动态调整权重,弥补单一模态不足,从而提高分类性能。

织物手感的复杂性来源于其多感官属性和非线性特征。例如,表面光泽度在视觉上可能表现为平滑,但在触觉上因高摩擦系数而显得粗糙;纱线密度可能通过视觉呈现紧密性,但触觉反馈可能因纤维硬度而偏刚硬。多模态融合通过跨模态关联分析,能够揭示这些矛盾背后的规律,为手感的全面建模提供支持。Nada Ech-chouqi 等^[82]提出一种对比学习框架,用于整合纺织品的视觉和触觉信息。他们通过对比学习训练卷积神经网络,利用纺织品的视觉和触觉数据提取统一的特征表示,无需大量标注数据。实验结果表明,该方法能够有效捕捉两种模态的关键数据结构和特征,成功区分不同纺织品类别,为纺织品的多模态感知提供稳健的框架

在织物手感研究中,多模态数据主要来源于以下几个方面,各具特性并与手感相关。

①视觉数据。视觉数据通过计算机视觉技术采集,包括二维图像和三维表面信息。二维图像提供纹理粗糙度、纤维方向性和孔隙率等特征,通常由工业相机或显微镜获取。例如,Gong 等^[83]提出采用数字图像处理技术测量非织造布纤维取向分布的方法。通过将织物表面显微图像简化为单像素宽的纤维曲线并统计其方向,自动获得纤维取向分布,并与手工测量结果吻合良好。研究发现非织物纤维取向分布可用三角函数模型拟合,表明图像分析能够准确量化纤维取向,为织物结构(影响手感)的客观分析提供手段。Turan 等^[84]开发一种基于图像分析预测纱线内孔隙率的方法。通过获取织物纱线截面图像,计算纱线内部的空隙面积和分布,以估算织物的内部孔隙率,并与传统计算方法对比。结果证明该图像法能有效测定纱线内部孔隙率,其预测值与实验测量高度相关,为织物孔隙率(影响透气性和手感)的无损评价提供新途径。Militký 等^[85]设计一种非接触式表面粗糙度评价装置和方法。将织物绕锐边弯曲,通过摄像获取其轮廓截面,在两个正交方向上扫描得到表面轮廓。通过“截距长度法”平滑局部微观粗糙,重构整体粗糙度表面。研究表明该图像法获得的织物粗糙度曲面可替代传统触针式轮廓仪,简便快速地量化织物表面纹理粗糙度。

②触觉数据。触觉数据通过传感器测量织物表面的物理接触特性,如摩擦力、压力分布和表面硬度。常见的设备包括触觉传感器(如电容式或压阻式传感器)和 KES 系统的摩擦测试模块。例如,Wang 等^[86]使用仿指状多通道电容触觉传感器,通过机器人滑动触摸对织物进行纹理分类。该传感器在滑动接触时采集触觉信号,并提取频域特征构成低维特征向量,用于 k-NN 分类器识别不同织物。实验在不同滑动速度和压力下进行,结果显示接触压力显著影响特征,而速度影响不明显。该方法仅利用单一触觉模态和滑动动作即可将织物准确分类,最高准确率达 96%,证明触觉传感在区分精细织物质地方面的有效性。Okatani 等^[87]开发一种基于 MEMS 的柔性压阻触觉传感器,用于测定接触界面的静摩擦系数。传感器体积约 $11 \times 11 \times 2$ mm,在弹性体内嵌入十字梁电阻应

变计。通过同时测量法向和切向应变信号,提取其比值随不同表面静摩擦系数的变化关系,该微型触觉传感器实现静摩擦的定量检测,为机器人触觉感知提供有用工具。触觉数据的优点是能够直接模拟人类触觉,但受传感器分辨率和接触条件的限制,可能无法捕捉微观结构的细微变化。

③力学数据。力学数据通过拉伸、弯曲和剪切测试获得,反映织物的机械性能,如杨氏模量、弯曲刚度、剪切刚度和压缩弹性。KES 和 FAST 系统是主要工具。Park 等^[88]发现,弯曲刚度小于 $0.1 \text{ N}\cdot\text{mm}$ 的织物在手感测试中被评为柔软,而大于 $0.5 \text{ N}\cdot\text{mm}$ 的织物更刚硬。力学数据提供织物手感的物理基础,但其测量通常为静态,难以反映织物动态触觉体验。

④其他模态数据。除视觉、触觉和力学数据,声音信号(如织物摩擦产生的声波)和热学特性(如导热系数)也开始被纳入多模态研究。Jin 等^[89]研究跆拳道服装织物在摩擦运动下的声学特性及其与机械性能的关系。利用专门装置以不同速度摩擦 6 种跆拳道服面料,记录其摩擦声,并计算声压级及 Zwicker 心理声学参数(响度、尖锐度、粗糙度)。同时采用 KES 测定样品的各项机械性能。结果表明,随着摩擦速度从 0.6 提高到 2.25 m/s ,织物的声压级和响度显著增加而尖锐度下降。进一步分析发现影响摩擦声的决定性因素在低速时是织物重量和最大延伸率(EM),高速时则是压缩能量(WC)。该研究揭示织物的结构/力学参数与摩擦声之间的关联,可用于优化材料以获得所需的声响手感特性。Mengüç 等^[90]比较不同织物在摩擦(布料相互摩擦)和挥动(抖动织物)两种运动下产生的总声级,并分析其与织物属性(弯曲刚度、动摩擦系数)的关系。通过声音品质分析系统获取声学参数,KES-FB 系统测量机械性能,并采用线性回归建立由机械参数预测声学特征的方程。相关分析显示,织物的低应力机械特性(如表面摩擦、弯曲柔软度)与摩擦声参数高度相关。这一研究从决策层面佐证声学信号可作为织物手感评价的一种辅助手段,因为声音特征与触觉相关指标存在显著关联。Mangat 等^[91]发明用于测量织物“冷暖感”的热吸收率概念和仪器 Alambeta。热吸收率定义为织物热导率、比热和密度乘积的平方根,数值越高表示手触时瞬间感觉越凉。通过 100 人主观触感试验验证 Alambeta 测得的热吸收率与人体对织物初触冷暖感觉之间存在显著相关性。例如,干燥的全棉织物热吸收率最低(约 $20 \text{ W}\cdot\text{s}^{0.5}/\text{m}^2\text{K}$),而湿润织物可超过 900,意味着后者初触更冰凉。该研究确立热学客观指标与手触温冷感受的一致性,为评价织物舒适触感(凉爽或温暖)提供量化依据。

这些模态数据的异构性(格式、采样率、物理意义不同)是多模态融合的挑战,同时也是其优势所在,因为不同模态间的互补性能够提供更丰富的视角。

此外,多模态融合技术根据融合层次可分为数据级融合、特征级融合和决策级融合,每种方法在织物手感研究中都有独特的应用。

①数据级融合。数据级融合直接整合原始数据,形成统一的输入向量,通常适用于时间同步性高的场景。例如,Zhang 等^[92]使用高速相机和触觉传感器同步记录羊毛织物

在拉伸过程中的图像和摩擦力数据，通过像素值与力信号的直接拼接，输入到一个线性回归模型，预测手感刚性，准确率达 85%。数据级融合的优点是保留原始信息，但对数据对齐和预处理要求较高，且计算复杂度较大。

②特征级融合。特征级融合先从各模态数据中提取特征，再进行整合，是最常用的方法。特征提取后，通过拼接、加权或降维（如 PCA）生成综合特征集。Xue 等^[93]引入模糊隶属度融合方法，将视觉和触觉感知结果关联分析。他们使用模糊包含测度来量化织物的视觉评价与触觉评价之间的关系，在特征层面对两种感官信息进行融合，成功揭示某些视觉特征对触觉属性的预测能力。

③决策级融合。决策级融合在各模态独立建模后，通过投票、加权平均或贝叶斯方法整合结果。Chen 等^[94]分别基于视觉数据（CNN 预测）和触觉数据（随机森林预测）对手感粗糙度评分，然后通过加权平均得出最终结果，权重根据模态的相关性调整。这种方法计算效率高，易于扩展到新模态，但可能因各模型间的独立性而忽略跨模态交互信息，继而减弱模型评价能力。

④深度学习驱动的融合。近年来，深度学习技术推动多模态融合的发展。多模态神经网络（如双流网络、注意力机制）能够自动学习跨模态特征间的关系。Xu 等^[80]设计一个 DeepLab3+ 模型，分别处理柔性材料（如皮革）的视觉图像和触觉信号，通过融合层整合特征，检测表面和非表面缺陷。实验表明，与纯视觉网络相比，所提出的网络表现出 10% 的显著改进。

多模态融合的优势显著。首先，它通过整合互补信息，提供对手感的全面表征。例如，视觉数据捕捉表面外观，触觉数据模拟真实接触，力学数据揭示物理本质，三者结合更接近人类感知。其次，融合模型的鲁棒性更强，能够处理单一模态数据中的噪声或缺失问题。例如，当视觉图像因光照不足而失真时，触觉和力学数据可作为补充。此外，多模态融合支持个性化建模，通过调整模态权重适应不同用户偏好。

然而，挑战同样存在。第一，数据异构性增加融合难度，各模态的时间同步、分辨率和格式差异需复杂预处理。第二，模型复杂度提高，深度学习融合需大量标注数据和高性能计算资源，限制其普及。第三，模态间的交互机制尚不完全清楚，例如视觉光泽与触觉粗糙度的矛盾如何量化，仍需理论突破。

1.2.4 知识发现

知识发现 (Knowledge Discovery in Databases, KDD) 是从海量、多源或异构数据中，改过数据清洗、特征提取、模式挖掘、结果解释等步骤，提取潜在有用信息与规律的过程（如图 1-4 所示）。

在织物手感研究中，知识发现方法可以有效揭示手感形成的多因素影响机制，例如 Imran 等^[95]在研究中指出，将数据挖掘应用于纺织数据是新兴方向，可以发现传统方法难以察觉的复杂关系，并探讨数据挖掘技术在分析服装工业数据、揭示有意义的映射和

预测服装公司工作团队的生产力绩效方面的应用。Yildirim 等^[96, 97]运用改进的 FP-Growth 关联映射算法，从纱线与织物属性的大型数据中挖掘隐藏模式。该研究提取闭合项集、极大项集等模式，揭示纱线参数与织物性能之间潜在的“IF-THEN”关系映射，实验结果证明该方法能有效挖掘纱线和织物属性间的关联知识。综上，这类数据驱动方法可以从纤维、纱线、组织结构、力学参数和主观手感评价等多源数据中提炼出对手感有影响的关键模式，从而为优化纺织品手感提供依据。

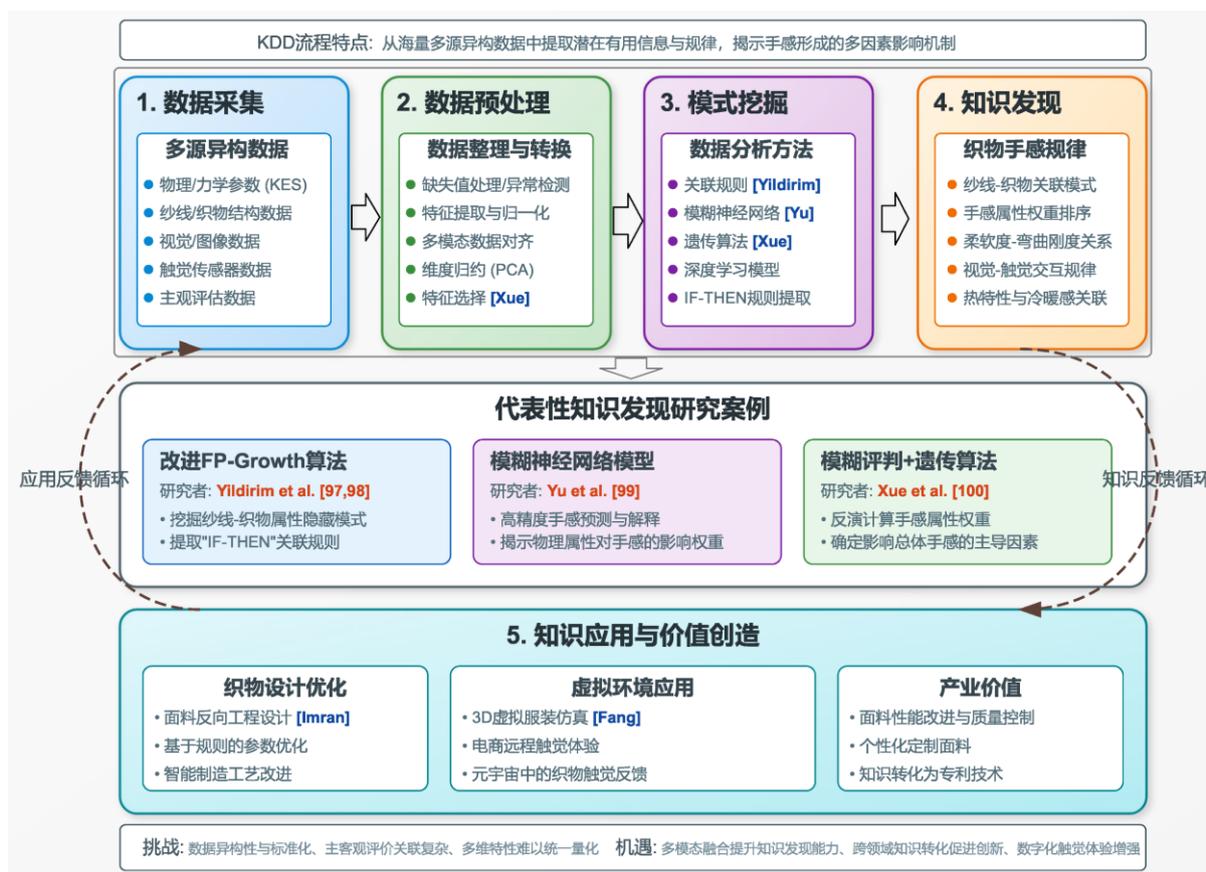


图 1-4 知识发现技术在织物手感评价上的应用

Figure 1-4 Application of knowledge discovery techniques to fabric hand evaluation

知识发现还用于关联映射与映射提取。Yu 等^[98]构建模糊神经网络 (FNN) 模型来预测织物手感，该模型在保持高预测精度的同时能给出可解释的映射集，即揭示各物理属性对手感的影响权重当前研究中存在的主要问题。他们进一步通过特征选择优化 FNN，减少计算量的同时仍能快速准确地预测手感。类似地，Xue 等^[99]采用模糊综合评判结合遗传算法的方法，反演计算出手感各感觉属性的权重。他们在感官实验中收集一组西装面料的 7 个触觉描述指标及总体偏好，利用遗传算法求解模糊评判的逆问题，提取出各触觉属性对总手感偏好的贡献权重。结果表明，该方法有效确定影响总体手感的主导因素（如柔软度、光滑度等）的相对重要性，有助于形成可解释的评价映射。综上，

关联映射挖掘和基于智能算法的映射提取为理解织物参数如何影响手感提供透明的决策映射和定量依据，这种从数据中提炼知识的过程，实现经验的科学化固化。

从织物手感中获取的知识不仅可用于评价，还可反向指导织物设计优化。过去，面料工程师往往凭借经验调整纱线粗细、组织结构或后整理工艺来改善手感，如为增加柔软度可能降低纱线捻度、加入柔软剂等。但这种经验方法具有尝试性质，难以找到全局最优方案。如今，借助预测模型和优化算法，可以在虚拟空间中尝试各种组合以找到满足目标手感的设计。例如，Fang 等^[100]等通过深度学习模型预测织物的刚度和阻尼参数，并将其应用于 3D 虚拟试衣环境中，使数字服装的褶皱和悬垂效果更接近真实，从而间接反映手感差异。随着虚拟现实^[101]和元宇宙^[102, 103]概念的发展，虚拟环境中的触觉体验备受关注。通过对织物手感的数字化刻画，人们未来或许能够在网上“摸到”衣服的质感。这对服装电商将是革命性的改变。总之，数据支持的手感研究正在从评价延伸到设计与仿真，贯穿纺织品生命周期的各个环节，推动行业向智能制造和个性化定制迈进。

总之，知识发现为手感研究提供从“数据”到“知识”的桥梁，能够将客观测试结果转化为人类可理解的手感规律，为后续的模式构建和智能决策奠定基础。

1.3 当前研究中存在的主要问题

当前手感评价面临三大范式危机：成本-效率困局，即高精度仪器如 KES 无法适配大规模质检，而低成本传感器缺乏理论验证；动静态割裂，现有系统难以同步捕捉静态纹理与动态形变；认知黑箱，深度学习模型虽提升预测精度，但决策逻辑不可解释，阻碍工业信任。针对这些危机，计算机视觉的破局路径清晰呈现：理论层面，建立视觉特征与物理参数的映射法则；技术层面，开发多模态时序对齐算法，融合图像、视频与物理数据；应用层面，构建可解释映射库，支撑透明化决策。

1.3.1 存在问题

(1) 评价方法的局限性。人工评价依赖专家主观判断，受经验和文化背景影响，评分一致性差。物理测试方法如 KES 系统虽能量化力学参数，但设备昂贵（单套成本超 10 万美元），操作复杂（单次测试约 5 分钟），且力学参数与感官感知的相关性有限。些局限导致传统方法难以满足工业化生产对高效、客观评价的需求。

(2) 视觉表征的边界问题。计算机视觉在织物手感评价中的应用虽具潜力，但其适用边界尚未明确。视觉特征的解释力和一致性不足，难以替代触觉感知。这种局限性限制视觉评价的全面性。

(3) 多模态融合的挑战。单一模态的局限性促使研究转向多模态融合，但现有研究在这方面仍显不足。图像缺乏动态信息，视频难以捕捉细微纹理，单一模态无法全面表征手感复杂性。虽然多模态融合在其他领域（如情感分析）取得进展，但在织物手感

评价中的应用尚处起步阶段。如何有效整合数值、图像和视频数据，实现端到端评价，仍是当前研究的重大挑战。

(4) 可解释性不足。深度学习模型虽提升预测精度，但其“黑箱”特性限制结果的可解释性，难以满足工业场景对透明决策的需求。现有知识发现方法生成的映射覆盖率和质量有限，无法直接指导面料选择或质量控制，缺乏可解释性的评价体系难以满足实际应用需求。

1.3.2 拟解决的问题

(1) 明确视觉评价的适用性

针对视觉表征在织物手感评价中的适用边界问题，拟构建一个验证框架，系统分析视觉评价的有效范围。通过设计基于信号检测理论的双面适用性测试，结合真实触觉、静态图像和动态视频三模态评价场景，验证手感性能的可视化潜力。重点研究表面、压缩、弯曲、拉伸、热湿性能的适用性，揭示视觉与触觉感知的关联机制。这一研究将为非接触式评价提供理论依据，明确视觉表征的应用边界，为后续特征提取奠定基础。

(2) 构建织物手感视觉量化指标

针对手感视觉表征量化难题，拟采用特征工程方法，设计一套多尺度的视觉特征体系。通过图像和视频处理技术提取反映手感性能的量化指标，涵盖表面粗糙度、压缩回复、弯曲刚度和拉伸模量等属性。利用统计方法筛选特征，确保其非冗余性与物理可解释性，并通过一致性分析验证其与感官评分和物理测量的相关性。这一体系将突破传统图像特征的碎片化局限，为手感评价提供高效、可靠的视觉指标库。

(3) 开发多模态融合模型

针对单一模态信息缺失的挑战，拟开发一个多模态融合的端到端手感评价模型，整合数值、图像和视频数据，全面表征织物手感。模型通过动态时间规整对齐模态特征，采用注意力机制和时序卷积网络进行融合，支持回归、分类和决策任务的联合训练。目标是提升预测精度，实现从原始数据到手感评价的直接映射。这一模型将为织物手感评价提供高效、精准的解决方案，支持工业场景的实时应用。

1.4 本课题研究目标、内容及创新性

1.4.1 本课题研究目标

织物手感评价领域长期面临主观经验依赖性强、客观仪器成本高、动态行为表征不足及模型决策逻辑不可解释四大核心问题。本课题以计算机视觉为核心技术手段，提出“视觉可感知的手感性能评价”理论假设，旨在构建覆盖视觉表征验证、多模态融合建模与知识映射提取的全链条研究框架。研究目标聚焦以下三维度：

(1) 界定手感视觉评价的可行性边界。通过跨场景感官实验与统计模型，明确表

面、弯曲、压缩、拉伸、热湿性能的视觉可评价性。

(2) 建立物理可解释的视觉特征体系。基于计算机视觉和特征工程技术,从图像和视频数据中提取反映手感性能的量化指标,设计并筛选一套高效、非冗余的特征体系,确保其与感官评分和物理测量的相关性与区分度。

(3) 开发高效多模态融合模型。将织物视觉表征,设计多模态融合模型,实现从原始输入到手感评分、手感分类和面料选择的直接映射,通过联合训练满足回归、分类和决策任务的需求,提升评价精度和效率。

1.4.2 本课题研究内容

本论文的研究内容主要包括以下几点:

(1) 视觉表征关联性验证

针对现有视觉表征与手感感官评价关联性研究中存在的实证缺乏和传统评分一致性差的问题,设计并开发一种基于两步评分的手感双面适用性测试标准化范式。该范式通过真实触摸、静态图像和动态视频三种场景,系统地验证视觉表征与感官评价之间的关联性。

(2) 系统化的手感视觉量化指标构建

针对手感多维属性视觉表征数据基础不足的问题,提出一种基于特征工程的视觉表征体系。利用图像和视频处理技术,从图像中提取纹理和边缘特征,从视频中提取形变特征。结合物理驱动的特征选择方法,筛选出一套高效、非冗余的量化指标,构建反映手感性能的视觉表征指标体系。

(3) 多模态融合的端到端手感评价模型构建

针对织物手感评价中多模态数据融合不足的问题,开发 TAIL (Textile Attribute Integration and Learning) 框架。该框架整合数值型视觉指标、图像和视频数据,实现从原始输入到手感评价的端到端建模。在 TAIL 框架中,采用动态时间规整对齐模态特征,通过时序注意力模块和时序卷积网络融合多模态信息,支持回归、分类和面料决策任务的联合优化。

1.4.3 本课题技术路线

本论文以织物手感视觉评价为核心,旨在通过计算机视觉技术实现织物手感的客观评价,解决传统方法的主观性、低效性和不可解释性问题。基于 1.3 节提出的研究问题与目标,设计一条多阶段、递进式技术路线图,从视觉-触觉关联性验证到手感特征体系构建,再到多模态融合和知识发现,逐步构建从原始数据到手感评价的端到端评价系统。本论文的主要研究思路及技术路线如图 1-5 所示。

1.4.4 本课题创新点

(1) 视觉表征关联性验证的标准化范式。本论文设计基于两步评分的手感双面适

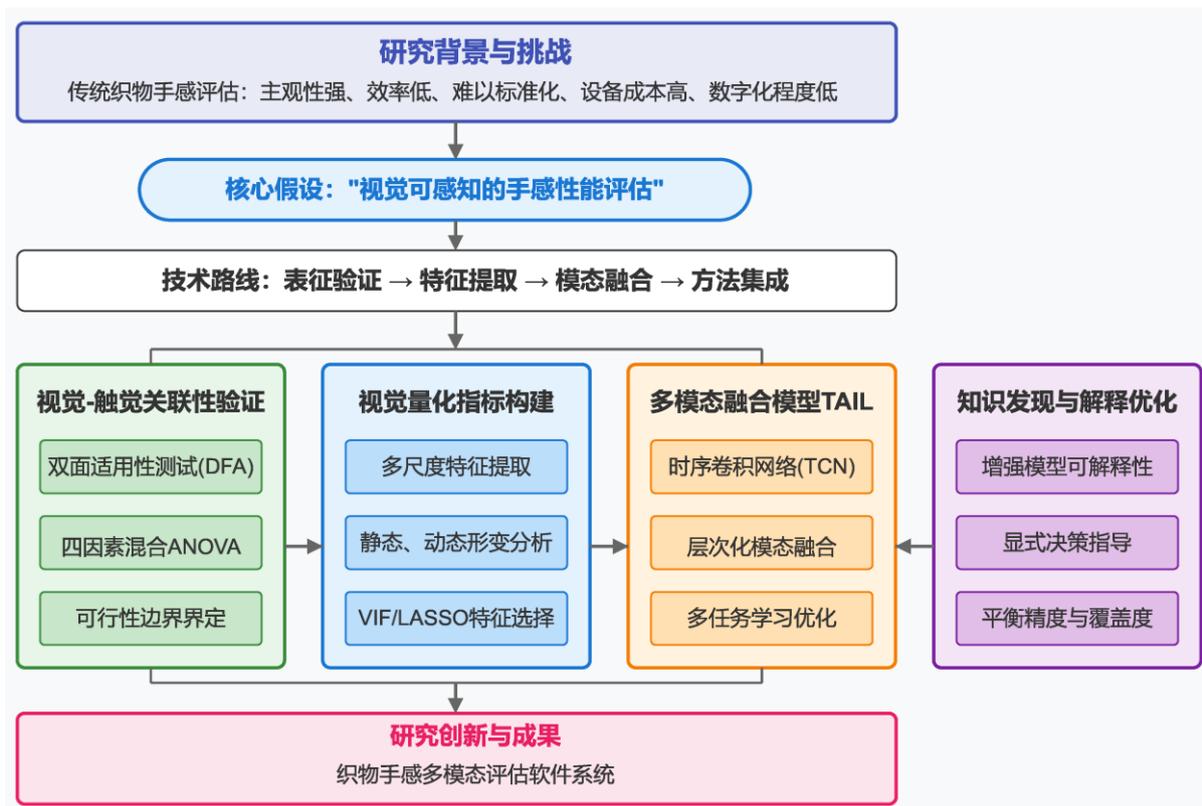


图 1-5 本课题的技术路线

Figure 1-5 The technical route of this study

用性测试，通过真实触摸、静态图像和动态视频三种场景，系统验证视觉表征与感官评价的关联性。该测试结合信号检测理论和混合效应分析，量化感官描述词在不同场景下的辨别力和一致性，探索手感性能的视觉可表征性。这一标准化范式为感官-视觉跨模态研究提供技术支持，克服传统评分一致性差的局限。

(2)系统化的视觉特征工程体系。本论文提出一种基于特征工程的视觉表征体系，利用图像和视频处理技术，设计并筛选出一套反映手感性能的量化指标。通过从图像中提取纹理和边缘特征，以及从视频中提取形变特征，结合物理驱动的特征选择方法（VIF和Lasso），构建高效、非冗余的指标体系，为后续建模提供科学可靠的数据基础。

(3)多模态融合的端到端评价模型。本论文开发TAIL框架，通过整合数值型视觉指标、图像和视频数据，实现从原始输入到手感评价的端到端建模。TAIL采用动态时间规整对齐模态特征，通过时序注意力模块和时序卷积网络融合多模态信息，支持回归、分类和面料决策任务的联合优化。这一框架充分利用多模态数据的互补性，为织物手感评价在多模态融合提供技术支持，为智能化评价提供高效路径。

第 2 章 织物手感与视觉表征关联性的跨模态验证

随着数字化技术的不断发展和智能制造的普及,织物手感评价正面临着从传统主观检测向远程、客观评价转型的迫切需求。织物不仅在外观上具有丰富的视觉信息,其触觉特性也直接决定产品的附加值与使用体验。然而,传统的触觉评价依赖专家的直接感知,既费时又难以量化,物理测试方法如 KES 系统虽能量化,但设备昂贵,操作复杂,且在远程监控和智能检测的场景下难以实现。因此,如何利用易于获取的视觉数据来反映织物真实的手感性能,成为当前纺织领域亟待解决的重要问题。

为解决上述问题,本章提出一种基于跨模态感官评价的创新方案,构建融合真实触摸数据与视觉表征的综合评价框架。该框架采用基于信号检测理论的双面适用性测试,通过“二值选择+确信度评分”的两步流程,将主观感官评价转化为定量指标;同时,利用四因素混合效应 ANOVA 及 Satterthwaite 自由度修正,精细解析不同评价场景(真实触摸、静态图像、动态视频)下的评分一致性,为跨模态一致性验证提供标准化方法。此举旨在建立织物视觉表征与真实手感数据间关联模型,为后续研究奠定坚实理论基础。

本章的研究目标在于构建一个可靠的跨模态织物评价框架,该框架既能够采集织物样本的真实触觉数据,又能够建立稳定、可信的织物视觉表征。通过这一框架,旨在为后续研究提供坚实的数据支撑和理论依据,使得后续工作可以围绕织物视觉表征展开研究,提取关键的手感特征,从而实现织物手感评价的智能化与标准化。这一目标的实现对于推动织物数字化评价和远程评价具有重要的理论与实践意义。

2.1 引言

织物手感作为一种复杂的多维度感知,涉及触觉、视觉甚至热湿感觉,其与视觉特征的映射关系尚不明确。例如,表面粗糙度可能通过图像纹理特征反映,而热湿性能(如“温暖-凉爽”)可能难以仅凭视觉信息判断。这种不确定性使得视觉表征在手感评价中的适用范围亟待验证。

针对上述问题,本章提出一种基于双面适用性测试(Double-Faced Applicability, DFA)的跨模态评价框架,通过比较真实触摸、静态图像和动态视频三种场景下感官评价的一致性,验证视觉表征在手感评价中的可行性。研究的设想在于:若视觉信息在一定程度上能够反映或替代触觉体验,将为纺织品的数字化展示与远程感知提供新的技术可能。具体而言,本章关注以下问题:在现有技术条件下,哪些手感属性(如表面、压缩、弯曲、拉伸、热湿等)可能通过视觉方式表现出来?在不同感知通道(触摸、图像、视频)中,人们对感性词汇的理解是否存在差异?视觉表征在手感传达中可能面临哪些局限?为此,实验选取 101 个织物样本,覆盖天然纤维(棉、丝绸、毛、麻)和合成纤维,通过标准化评分和统计分析,系统验证视觉表征的有效性边界。

本章的研究意义体现在理论与实践两个层面。在理论上，通过建立感官评价与视觉表征的关联性，为织物手感的客观量化提供实验依据，为现有研究在跨模态一致性分析提供技术支持。在实践上，验证结果将指导后续章节的特征工程和多模态融合设计，确保所开发的评价系统聚焦于视觉可表征的性能，避免资源浪费于不可行的维度。此外，本章的方法论创新在于跨模态评价框架的设计，该框架结合信号检测理论和混合效应方差分析，能够量化评价场景的差异性，为纺织工程领域的跨模态研究提供可复制的范式，所提框架如图 2-1 所示。

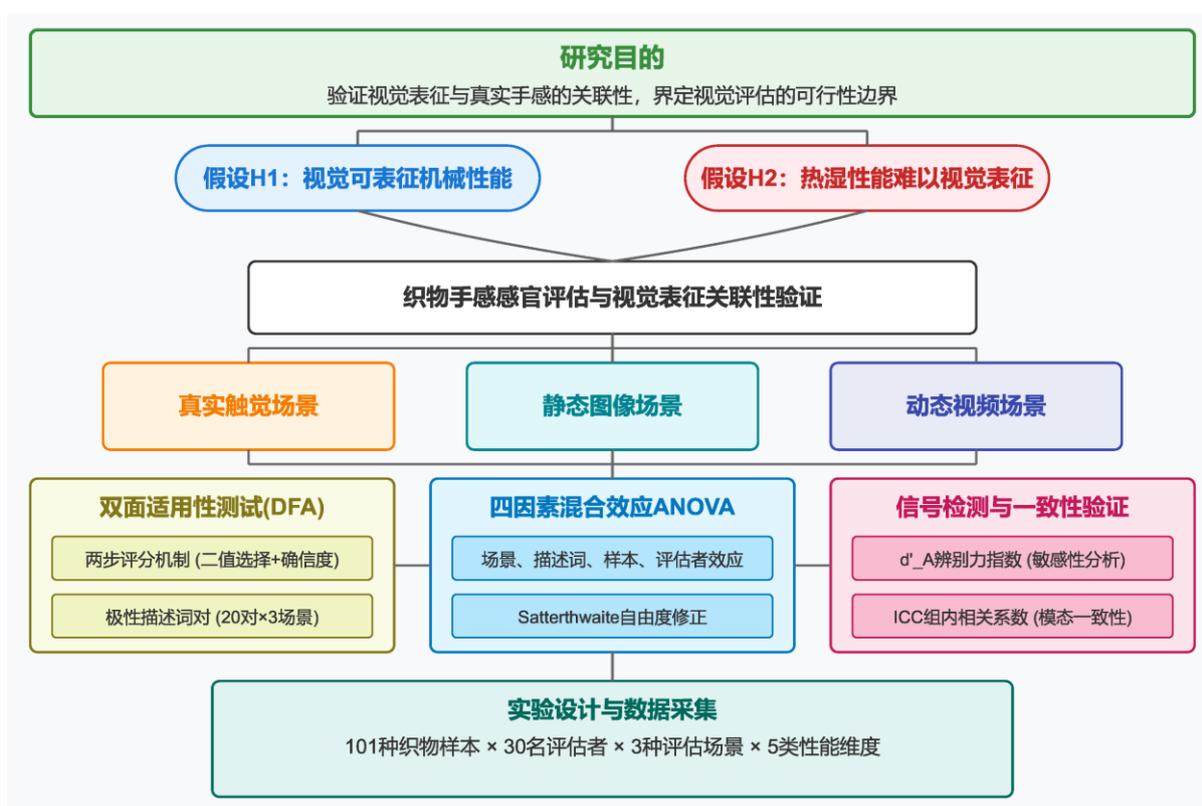


图 2-1 本章的技术路线

Figure 2-1 The technical route of chapter 2

2.2 视觉-触觉跨模态评价框架构建

2.2.1 模型构建思路

为验证织物手感评价中视觉表征的有效性，本研究提出基于视觉感知一致性验证的评价模型，结合触觉、静态视觉与动态视觉信息。其基本假设为：若织物视觉表征（图像或视频）能够准确传递织物手感性能的感官特征，则在跨模态评价中应表现出统计上的一致性。整个模型从信号检测、评分机制、跨模态一致性量化到参数优化，形成一个

统一、严谨的统计分析体系。框架设计基于以下理论支撑：

(1) 信号检测理论 (Signal Detection Theory, SDT)

感官评价本质是目标属性 (信号) 与评价偏差 (噪声) 区分开的过程。对于每一对描述词对 $D_i = (D_{i+}, D_{i-})$, 假设其评价结果服从均值相同、方差相同的正态分布：

$$D_{i+} \sim \mathcal{N}(\mu_{D_{i+}}, \sigma^2), \quad D_{i-} \sim \mathcal{N}(\mu_{D_{i-}}, \sigma^2) \quad (2-1)$$

其中, μ 为感官信号均值, σ^2 为评价噪声方差。

依据该假设, 可定义描述词对的辨别力指标 d' (d -prime):

$$d' = \frac{\mu_{D_{i+}} - \mu_{D_{i-}}}{\sigma} \quad (2-2)$$

其中, 当 $d' > 1.5$ 时, 表明该描述词对在区分正负信号时具有显著辨别力 (对应显著性水平 $p < 0.05$) [104]。

(2) 跨模态一致性

为检验视觉表征与触觉感知对织物手感性能表征是否一致, 采用组内相关系数 (ICC) [105] 来衡量不同模态间的评分一致性。基于固定场景数 $k=3$ (真实触摸、静态图像、动态视频), ICC 的计算公式为:

$$ICC(3, k) = \frac{MS_R - MS_E}{MS_R + (k-1)MS_E} \quad (2-3)$$

其中, MS_R 为组间均方, MS_E 为组内均方, k 为评价模态数 ($k=3$)。当 $ICC > 0.75$ 时, 认为跨模态一致性达到“优秀”级别 [106]。

2.2.2 两步评分双面适用性评价模型

为降低主观评分的模糊性, 本研究所构建的两步评分双面适用性评价模型引入双面描述词对 (Dual-Faced Descriptor Pairs) 与两步评分机制, 具体流程如下:

(1) 双面描述词对设计

针对 5 类织物性能 (表面、压缩、弯曲、拉伸、热湿), 构建 20 对语义对立描述词 (见表 2.2), 每对包含上标度 (+) 与下标度 (-) 描述词。例如:

$$D_{\text{Surface}} = \{\text{High Friction (+), Low Friction (-)}\} \quad (2-4)$$

(2) 两步评分机制

第一步 (二值选择): 评价者对描述词适用性回答“是/否” ($C_{ijk} \in \{0, 1\}$)。

第二步 (确信度评分): 对选择结果进行 3 级确信度评分 (1=不确定, 3=非常确定)。

最终评分 S_{ijk} 由选择结果 C_{ijk} 与确信度 $R_{ijk} \in \{1, 2, 3\}$ 合成:

$$S_{ijk} = C_{ijk} \times R_{ijk} + (1 - C_{ijk}) \times (4 - R_{ijk}) \quad (2-5)$$

其中, i 为样本编号, j 为描述词对编号, k 为场景编号。

(3) 数据标准化

对下标度（-）描述词评分进行反向标准化，构建统一 6 级评分尺度：

$$S'_{ijk} = \begin{cases} S_{ijk}, \text{上标度}(+) \\ 7 - S_{ijk}, \text{下标度}(-) \end{cases} \quad (2-6)$$

这样构建出统一的 6 级评分尺度，保证各描述词在后续统计分析中的一致性。

2.2.3 评价指标

(1) 方差分析（ANOVA）

为进一步探究场景效应与描述词效应对评分的影响，构建四因素混合效应模型：

$$Y_{ijklm} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + \varepsilon_{ijklm} \quad (2-7)$$

其中， μ 为总体均值， α_i 为场景效应（固定效应）， β_j 为描述词效应（固定效应）， γ_k 为样本（随机效应），反映样本间的随机波动， ε_{ijklm} 为残差项。通过 F 检验^[107]验证场景与描述词的显著性（通常要求 $p < 0.01$ ）。

(2) 适用性幅度

在 SDT 的基础上，基于实际回答计算适用性幅度^[108]，评价描述词对的适用性强度：

$$d'_A = Z(\text{HitRate}) - Z(\text{False Alarm Rate}) \quad (2-8)$$

其中， $Z(\cdot)$ 为标准正态分布逆函数，HitRate 表示“是”回答的比例，False Alarm Rate 表示误判率。当 $d'_A > 0$ 时，表明正向描述词在传达感官信息方面优于反向描述词。

进一步定义跨场景一致性指数（CCI）：

$$\text{CCI} = \frac{1}{N} \sum_{i=1}^N \mathbb{I}(\text{ICC}_i > 0.75 \cap d'_A > 1.5) \quad (2-9)$$

其中， $\mathbb{I}(\cdot)$ 为指示函数， N 为样本总数。当 $\text{CCI} > 0.8$ 时，即认为视觉表征在跨场景评价中具有有效性。

2.2.4 参数优化与模型改进

为提高模型在实际应用中的鲁棒性与统计推断的准确性，引入以下两项优化措施：

(1) SDT 参数的置信区间优化

直接计算 d'_A 的估计值可能受样本波动影响较大，因此采用极大似然估计方法^[109]给出其置信区间：

$$d'_A \pm z_{1-\alpha/2} \sqrt{\frac{\text{HitRate}(1 - \text{HitRate})}{n_{\text{Hit}}} + \frac{\text{False Alarm Rate}(1 - \text{False Alarm Rate})}{n_{\text{FA}}}} \quad (2-10)$$

其中， $z_{1-\alpha/2}$ 为标准正态分布分位数， n_{Hit} 和 n_{FA} 分别为“是”回答与误判回答的样本数。

此优化有助于量化 d'_A 的不确定性，从而确保各模态间比较的可靠性。

(2) 小样本条件下的 Satterthwaite 自由度修正

在混合效应模型中，尤其在样本量较小时，传统自由度计算可能导致 F 检验结果不准确。为此，引入 Satterthwaite 自由度^[110]修正，其公式为：

$$df = \frac{\left(\sum_{i=1}^k a_i s_i^2\right)^2}{\sum_{i=1}^k \frac{\left(a_i s_i^2\right)^2}{n_i - 1}} \quad (2-11)$$

其中， a_i 为设计矩阵中的系数， s_i^2 为相应的方差分量， n_i 为对应的样本自由度。此修正方法调整自由度估计，使得小样本情形下的统计检验更加稳健和准确。

2.3 实验设计

本研究手感感官评价程序的结构如图 2-2 所示，包含以下三个阶段：

(1) 实验前阶段 (Pre-experimental Phase)：选择相关代表性织物样本，准备其图像和视频以反映织物形变，展示各面料手感性能的视觉效果，并为实际触摸 (Real-touch)、图像 (Image) 和视频 (Video) 场景建立和培训三个感官评价小组 (Panel)。

(2) 感官测试阶段 (Sensory Evaluation)：每个感官评价小组通过头脑风暴和纺织专家的专业知识^[15]定义感官描述词，并根据这些描述词评价所选样本的面料特性。

(3) 数据分析阶段 (Data Analysis)：使用统计工具，特别是 ANOVA 和 SDT，解释每个感官描述词在面料手感评价中的辨别能力。

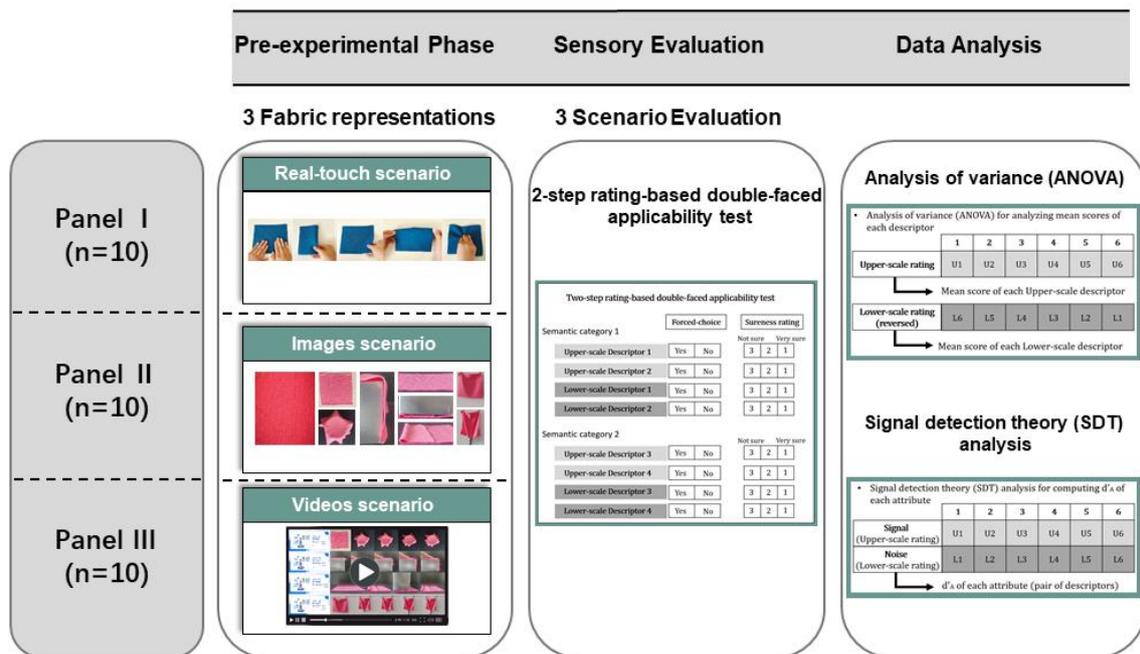


图 2-2 织物感官三场景评价路线图

Figure 2-2 Roadmap of fabric sensory three scenarios evaluation

2.3.1 织物样本选取

实验基于 101 种织物样本构建评价数据集，覆盖天然纤维（棉、丝、毛、麻）、合成纤维（聚酯），满足日常使用场景（服用、家纺、产业用），其参数分布如图 2-3 所示。样本选择遵循物理多样性，样本的克重 (g/m^2) 服从均匀分布 ($60\text{--}400\text{g}/\text{m}^2$)，厚度 (mm) 覆盖 $0.1\text{--}2.5\text{mm}$ ，弯曲刚度 ($\text{cN}\cdot\text{cm}^2/\text{cm}$) 范围为 $0.1\text{--}8.5$ ，以确保力学性能的广泛覆盖。样本规格为 $20\times 20\text{cm}$ ，经过清洗和熨平，置于恒温恒湿环境 ($20\pm 2^\circ\text{C}$, $65\pm 3\%$) 24 小时以稳定状态。样本编号随机化，评价者盲测以减少偏见。

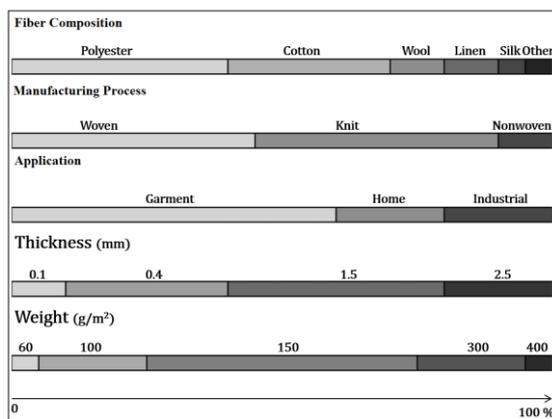


图 2-3 织物样本参数统计分布

Figure 2-3 Statistical distribution of the samples related to different key parameters

2.3.2 视觉表征创建

对每个样本，本研究创建两类视觉表征：静态图像和动态视频。

(1) 静态图像表征。使用 Nikon D850 单反相机（分辨率 3000×4000 像素）在标准光源箱（D65 光源，照度 1000 lux ）下采集 5 种状态下织物图像（表面、悬垂、弯曲、压缩、拉伸），以展示织物的交互效果和与触觉特性相关的视觉线索，通过几何校准消除透视畸变。图 2-4 展示样本 1 在 5 中状态下的图像表征，其中 (a) 反映表面纹理细节，(b) 反映悬垂变形，(c) 反映弯曲变形，(d) 反映压缩变形，(e) 反映拉伸形变。

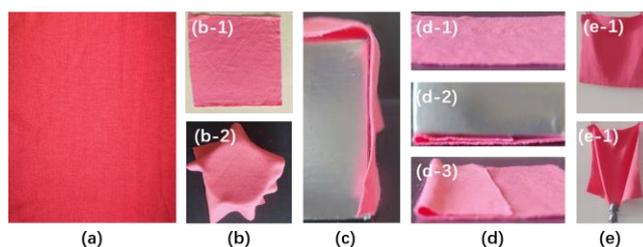


图 2-4 样本图像表征

Figure 2-4 Image representation of sample

(2) 动态视频表征。采用 Sony AX700 摄像机 (1920×1080 像素, 60 fps) 记录织物样本在 4 种状态 (悬垂、弯曲、压缩、拉伸) 下的动态变形过程, 以模拟真实世界交互并提供织物触觉特性的动态表示。图 2-5 展示样本 1 在 4 种状态下的动态变形过程, 采样方法如下: 悬垂状态通过将织物样本放置在圆台上自然下垂, 利用重力形成垂褶形状和波形变化; 弯曲状态通过将织物一端伸出平台, 依靠自重产生弯曲变形, 记录角度和恢复过程; 压缩状态通过施加固定重量的折叠压缩并观察回复行为, 捕捉厚度变化和弹性响应; 拉伸状态则从自然悬垂开始, 分两次施加 10cN 负载, 记录伸长和形变轮廓。为确保视频记录一致性, 建立预定义标准, 确保每个面料样本以相同方式处理, 并通过光流法 (Horn-Schunck 算法^[111]) 量化形变轨迹:

$$\frac{\partial I}{\partial x} v_x + \frac{\partial I}{\partial y} v_y + \frac{\partial I}{\partial t} = 0 \quad (2-12)$$

其中, v_x 与 v_y 代表像素运动速度, $I(x,y,t)$ 为时空灰度函数, 从而获得动态形变轨迹信息。

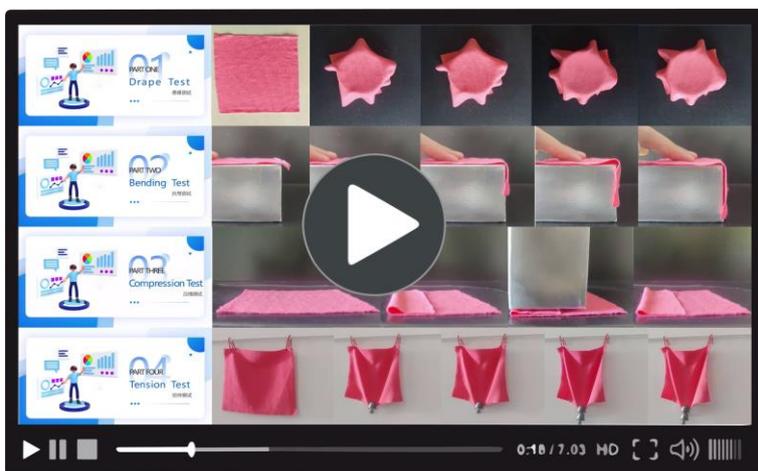


图 2-5 样本视频表征

Figure 2-5 Video representation of sample

2.3.3 评价小组构建

感官评价涉及一个或多个受过专业培训的评价小组, 这些小组负责对选定的织物样本进行系统性的评价, 以确保结果的科学性和一致性。评价小组成员依据自身的专业知识, 结合特定的感官描述词, 对织物样本的物理特性进行定量或定性评分。根据 Dijksterhuis^[112]的研究, 本研究组建了一个由 30 名具有纺织背景的评价员组成的专业小组 (如表 2-1), 性别比例均衡, 年龄分布在 23 至 55 岁之间。评价员按专业背景分为 4 类: 纺织院校学术人员、纺织企业专业人员 (主要是面料和时装设计人员)、纺织工程博士和硕士研究生。每位评价人员均曾参加过至少 2 次织物手感评价。

为减少评分重叠可能带来的偏差, 30 名评价员被随机分为 3 组, 每组 10 人, 分别负责真实触摸、图像和视频三种评价场景。评价员分组情况如表 2-1 所示。

表 2-1 评价员分组情况

Table 2-1 Grouping of panelists.

专业背景	真实触摸	图像组	视频组	总计
大学教授	2	2	2	6
行业人员	2	2	2	6
博士研究生	3	3	3	9
硕士研究生	3	3	3	9
总计	10	10	10	30

2.3.4 评价方法设计

本研究采用 DFA 测试进行织物手感性能感官评价。DFA 测试区别于传统方法的关键在于使用成对的“双面”描述词，即每个属性分别评价一对描述词（上标度 Upper-scale Descriptor (+) 和下标度 Lower-scale Descriptor (-)）。例如，对于柔软度属性，同时评价“Soft (+)”和“Hard (-)”两个描述词。这种方法可以有效整合织物手感相关属性并最小化默许偏差，即评价人员倾向于“同意”而非“不同意”的偏差^[113]。

DFA 测试问卷由两步评分组成：首先是强制选择（Forced-choice）“是否适用（Yes/No）”问题，要求评价者对每个描述词中的极性（+/-）进行适用性判断。第二步则是进行 3 级确信度评分（Sureness rating, 1=不确定, 3=非常确定），进一步量化评价者对自身判断的信心水平。相比传统的“勾选所有适用项”（CATA）^[114]或直接评分法，这种间接量表方法基于 SDT^[104]和 Thurstonian 方法^[115]，可以估计与响应偏差无关的属性适用性定量指数。

通过整合评价人员对 Upper-scale Descriptor (+) 和 Lower-scale Descriptor (-) 描述词的响应比率，计算每个属性的适用性幅度 d'_A ，量化评价结果。先前研究表明， d'_A 估计值相比直接评分显示出更高的辨别能力^[108]。

（1）描述词选择与定义

建立科学合理的评价标准对于织物触觉特性的表征至关重要。为确保评价的全面性，本研究采用系统化的方法构建织物感官描述词库，并对其进行优化筛选，以便形成统一的行业标准。

在术语构建阶段，纺织行业专家通过研讨会共同制定覆盖织物触觉特性的术语库。讨论过程中，专家们基于日常纺织品使用经验，提出约 150 个独特的织物触觉描述词，以充分涵盖织物在不同环境中的触觉特性。随后，为提高描述词的精准度和适用性，专家团队对初步整理的术语进行筛选和优化。筛选过程中，去除具有主观性或不够明确的术语，仅保留能够精准表征织物触觉属性的术语。经过此轮筛选，最终精炼出 70 多个高度相关的描述词。在最终整合阶段，研究团队参考相关文献^[116-118]，对筛选后的术语

库进行进一步的规范化调整。研究过程中剔除不符合行业标准的术语，并用行业认可的术语替代存在表达不一致的词汇。经过这一系列筛选和优化，最终形成一套符合标准的织物感官描述词库。

最终的织物感官描述词体系由 20 对语义差异的极性描述词组成（如表 2-2 所示），其中包括 20 个 Upper-scale Descriptor（+）和 20 个 Lower-scale Descriptor（-），本研究中，Upper-scale Descriptor（+）可理解为织物的正向触觉属性，而 Lower-scale Descriptor（-）可解释为负向触觉属性。为提高理解度，研究团队根据描述词所表征的织物手感，将其划分为五大类，分别为表面特性（Surface, 4 对）、压缩特性（Compression, 4 对）、弯曲特性（Bending, 4 对）、拉伸特性（Stretching, 4 对）以及热湿感知特性（Thermal-wet, 4 对）。

表 2-2 用于评价的手感描述词

Table 2-2 List of descriptors used for evaluation.

Property	Category	Pair of semantic-deferential descriptors (Upper-scale descriptor(+)- Lower-scale descriptor(-))
Surface	Surface friction	High friction – Low friction
		Smooth – Rough
	Surface contour	Regular – Irregular
		Flat – Puffy
Compression	Elasticity	Elastic – Non-elastic
		Soft – Hard
	Fullness	Full – Lean
		Dense – Loose
Bending	Rigidity	Static – Dynamic Rigid – Pliable
	Draping	Draped – Non-draped
		Flowing – Firm
Stretching	Stretch	Stretchy – Non-stretchy
	Flexibility	High resilience – Low resilience
		Resilient – Non-resilient
Thermal-wet	Temperature	Warm – Cool
		Insulating – Conductive
	Moisture	Dry – Wet Breathable – Non-breathable

对每对描述词建立准确的定义和评价方法,经初步测试确认其有效性和可实施性。在三种场景中统一使用相同的描述词,以便进行跨场景比较。

例如,对于“Smooth (+)-Rough (-)”这一描述词对,其定义为:“织物表面的纹理特性。光滑的织物表现为顺滑、无颗粒感的触觉体验,而粗糙的织物则具有较明显的颗粒感或纹理特征。”在评价时,评价者使用优势手在织物表面轻轻来回摩擦,以感知织物表面对手部运动的阻力,从而判断织物表面的光滑度或粗糙程度。

(2) 评价过程的实施

按如下安排实施评价过程:

(a) 评价员培训。在正式开展评价工作前,必须对所有评价员实施严格的培训程序,以确保评价过程的一致性和准确性。具体而言,每位评价员需参加为期6小时的系统培训,培训内容包括对评价程序的全面解以及对各项描述符含义的详细讲解。为防止培训过程中出现样本混淆,培训过程中选用的面料样本与正式实验所使用的样本不同,从而使评价员能够在不同的情境下掌握评价标准和方法。

(b) 实验执行。真实触摸场景,所有样本在评价前均需在温度 $20\pm 2^{\circ}\text{C}$ 、相对湿度 $65\pm 2\%$ 的标准环境下平衡至少24小时,以消除环境因素对触感的影响。评价在实验室环境中进行,评价员先清洁双手,然后按描述词依次评价所有样本;图像场景,在计算机屏幕上依次显示样本图像,显示参数严格统一。评价员可自由控制图像显示顺序和缩放比例;视频场景,在计算机屏幕上依次播放样本视频,评价员可控制播放进度和暂停。

(c) 数据收集。所有实验数据均通过计算机采集,并使用Microsoft Excel 2016的CheckBox功能进行记录。每个测试的评价表格均显示在计算机屏幕上,评价者需点击相应的CheckBox选项进行作答。为降低首因效应并避免评价者因习惯性行为导致的评分偏差,本研究对每位评价者的描述词呈现顺序进行随机化。然而,为减少可能的认知混淆,描述词的随机化仅在同一类别内部进行,而不是跨类别随机排列。此外,在DFA测试中,Upper-scale Descriptor (+)和Lower-scale Descriptor (-)在同一类别内分别呈现,例如所有Upper-scale Descriptor (+)先展示,然后是Lower-scale Descriptor (-),或者相反,以确保测试的规范性和可重复性。

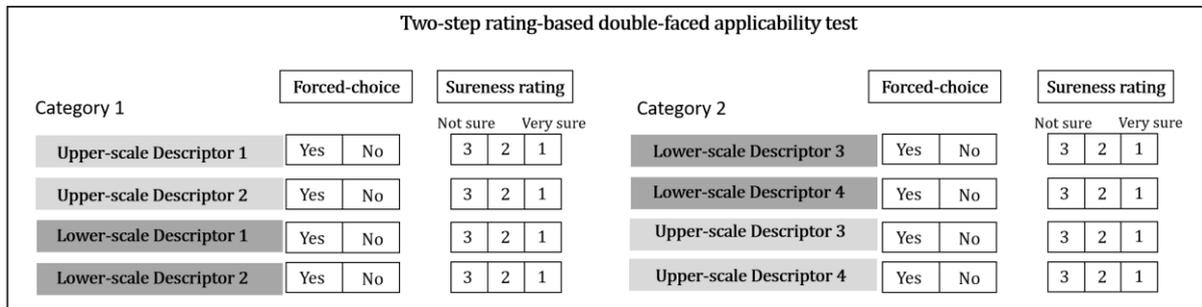
测试过程中,评价员需回答“该描述词是否适用于您在特定评价场景下对织物手感特性的评价?请同时对您的确定性进行评分。”评价者需选择“Yes”或“No”,随后使用3级确信度对其判断进行评分,其中1表示“不确定”,3表示“非常确定”。相应的原始响应数据转换为6级评分,如图2-6(a)所示。

2.3.5 数据处理

每个样本在三种场景下由10位评价者独立评分,共生成 $101\times 3\times 20\times 2\times 10=121,200$ 条评分记录。为确保数据质量需经过一致性检查(计算评价者间ICC,剔除异常评分(低于ICC平均值2个标准差))和可重复性测试(随机抽取10个样本重复评分,验证评

价者评分稳定性 (ICC>0.75 为可接受)。最终数据集经清洗后保留 121,064 条有效记录, 为后续分析提供可靠基础。

(a) Examples of response format



(b) Pre-processing of collected data for data analysis

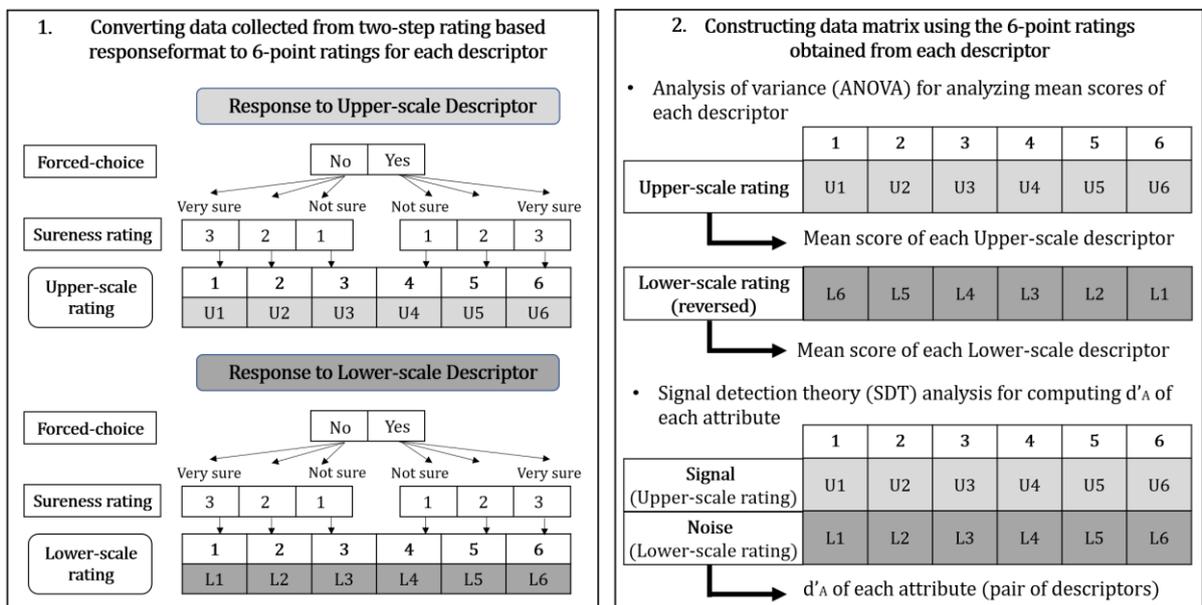


图 2-6 数据收集与处理过程示意: (a) DFA 测试; (b-1) 上/下标度转换; (b-2) 用于数据分析的数据转换示意

Figure 2-6 Illustration of example of the (a) ‘double-faced applicability (DFA)’ test. (b)-1 Represents how to convert the collected data for each upper-scale(+) and lower-scale(-) descriptor to two different ratings and (b)-2 data matrix for data analysis

为探讨不同评价场景和描述词对触觉评价的影响, 本研究采用多因素混合方差分析 (ANOVA), 对转换后的 6 级评分数据进行统计分析 (图 2-6(b)-2)。在感官评价数据的统计处理中, 使用四因素混合效应 ANOVA 分析, 其中评价场景、描述词及其交互作用设定为固定效应, 而评价者和样本设定为随机效应。描述词作为固定效应之一, 在每个评价场景下, Upper-scale Descriptor (+) 和 Lower-scale Descriptor (-) 评分进行比较, 以检验其统计显著性。采用 R 统计软件中的 lme4 软件包进行混合效应 ANOVA 模

型拟合，并利用 lmerTest 软件包的方差分析功能进行统计检验，采用 Satterthwaite 方法估计自由度。此外，采用最小二乘均值差异（95%置信区间）进行事后检验，以识别不同评价场景和描述词之间的显著性差异。

此外，为进一步量化 DFA 测试的感官评价结果，本研究采用 SDT 进行非参数估计。利用 DFA 测试所得的 6 级评分数据，将 Upper-scale Descriptor (+) 评分视为信号，将 Lower-scale Descriptor (-) 评分视为噪声，并计算 d'_A 值，以表征不同描述词的区分能力。为避免 d'_A 计算中的无穷大值，采用对数变换进行数据处理，并使用 SDT Assistant 程序对 d'_A 的方差和标准误进行估计。在统计检验过程中，采用 R/S-Plus 的 dstest 函数^[119] 计算 d'_A 的多重比较显著性，并依据既有研究标准对 d'_A 值进行分类和解释。对于 d'_A 值的计算结果，本研究定义三种不同的感官评价情况：(1) d'_A 显著小于零，表明评价者更倾向于使用 Lower-scale Descriptor (-) 进行描述；(2) d'_A 等于零，表明 Upper-scale Descriptor (+) 和 Lower-scale Descriptor (-) 的适用性相当，或两者均不被评价者明显倾向使用；(3) d'_A 显著大于零，表明 Upper-scale Descriptor (+) 更符合评价者的期望。

2.4 实验结果

如图 2-7 所示，在 20 对描述词中，有 4 对呈现出显著的场景效应，即极性描述词对在不同场景下有显著性差异，有 6 对呈现出描述词效应，即不同描述词对评价结果有显著影响。此外，有 2 对呈现出场景与描述词交互效应。

2.4.1 四因素混合效应结果

(1) 场景效应

热湿类别下的所有描述词，包括 Warm (+) - Cool (-)、Insulating (+) - Conductive (-)、Dry (+) - Wet (-)、Breathable (+) - Non-breathable (-)，在场景方面的平均得分呈现出显著差异（如图 2-7 所示），所有这些描述词在三种场景下的平均得分呈现出无规律的模式。

对于 Warm (+) 这一描述词，在图像场景中的平均分显著高于真实触摸场景中的得分；相反，Cool (-) 这一描述词在图像场景中的平均分显著低于真实触摸场景中的得分。这一结果表明，在图像场景中，评价小组认为大多数样本可同时感知到“Warm”和“Cool”，反映出该描述词对的评价标准不够明确。

同样的，Insulating (+) 在图像场景中的得分显著高于真实触摸场景，而 Conductive (-) 的得分显著低于真实触摸场景。这种差异表明，在图像场景下，评价者对织物的隔热和导热性能的感知与真实触摸情况存在偏差。

Dry (+) - Wet (-) 在图像场景中的平均分与上述相似，但在视频场景中则呈现出相反趋势。

此外, Breathable (+) - Non-breathable (-) 的评分仅在视频场景中表现出矛盾现象, 其中 Breathable (+) 在视频场景中的评分高于真实触摸场景, 而 Non-breathable (-) 的评分则与真实触摸场景差异不大。

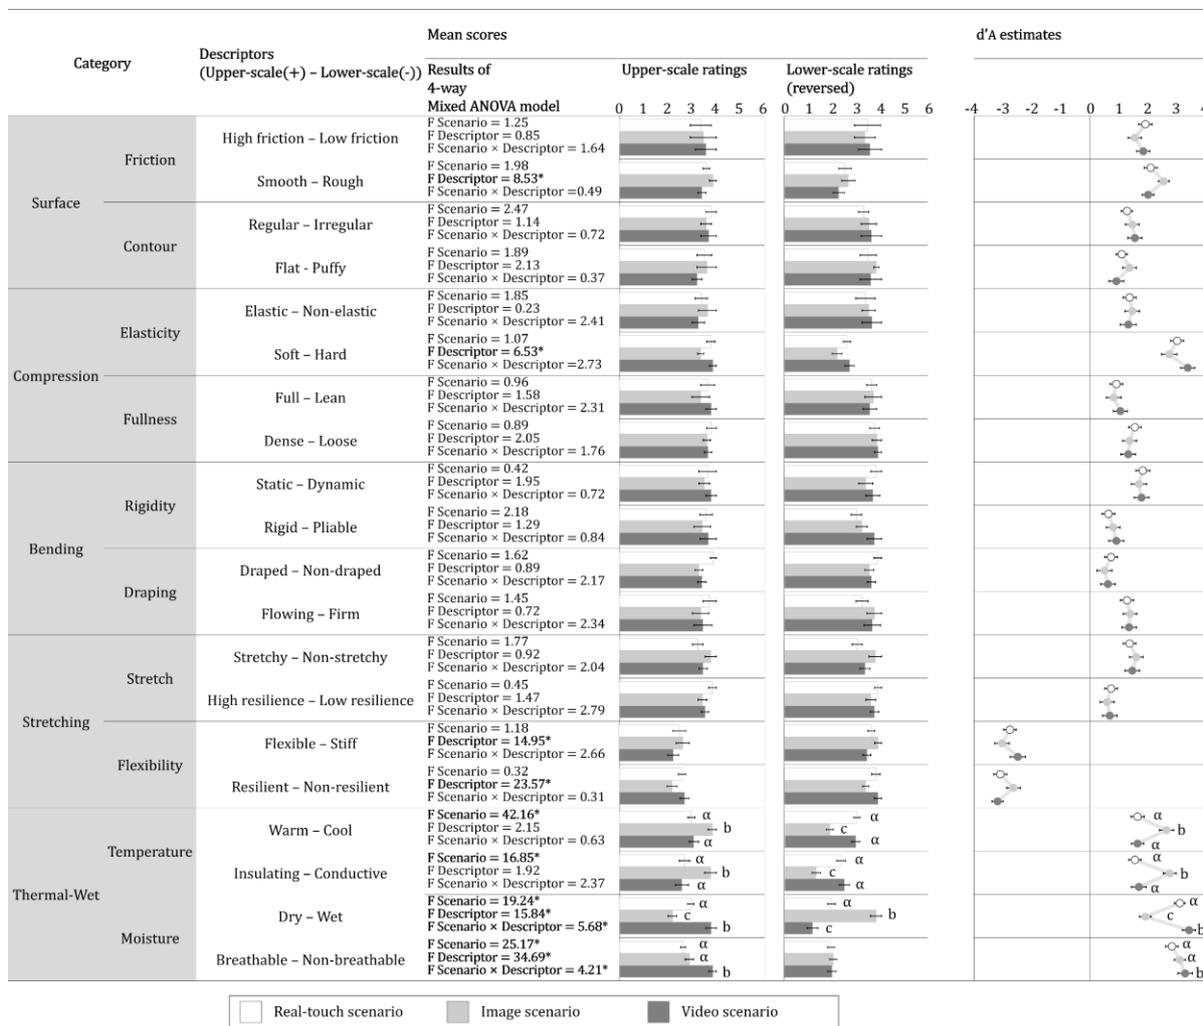


图 2-7 织物手感评价结果

Figure 2-7 Results of panel response in fabric hand evaluation

(2) 描述词效应

如图 2-7 所示, 在 DFA 测试中, 20 对描述词中有 6 对 Upper-scale Descriptor (+) 和 Lower-scale Descriptor (-) 评分存在显著性差异。特别的, 在 Smooth (+) - Rough (-)、Soft (+) - Hard (-)、Dry (+) - Wet (-)、Breathable (+) - Non-breathable (-) 这些描述词对中, Upper-scale Descriptor (+) 的平均得分显著高于其对应的 Lower-scale Descriptor (-), 这可能是因为评价小组倾向于将 Upper-scale Descriptor (+) 与优良触感联系在一起, 由此可见, 对于同一特性而言, Upper-scale Descriptor (+) 和 Lower-scale Descriptor (-) 的响应程度受具体描述词而异。

(3) 场景与描述词交互效应

如图 2-7 所示, 场景与描述词交互效应在 Dry (+)–Wet (–)、Breathable (+)–Non-breathable (–) 这两对描述词中得以确定。结果表明, 不同描述词在不同场景下对样本评价结果的影响是不同的。

具体而言, 对于 Breathable (+)–Non-breathable (–) 描述词对, 在真实触摸场景和图像场景中, Lower-scale Descriptor (–) 的平均得分没有差异, 而在视频场景中, Upper-scale Descriptor (+) 的平均得分显著更高。对于 Dry (+)–Wet (–) 描述词对, 在真实触摸场景中, Lower-scale Descriptor (–) 的平均得分显著高于视频场景中的平均得分, 而对于 Upper-scale Descriptor (+) 其得分则相反。

2.4.2 信号检测 d'_A 结果

为进一步量化各描述词在不同评价场景下的实用性, 本研究计算 d'_A 值(如图 2-7 所示)。结果表明, 大多数描述词的 d'_A 值大于零, 表明 Upper-scale Descriptor (+) 在三种评价场景下的评分普遍高于 Lower-scale Descriptor (–)。然而, Flexible (+)–Stiff (–)、Resilient (+)–Non-resilient (–) 描述词对的 d'_A 值显著低于零, 说明 Lower-scale Descriptor (–) 在这两个描述词对中的适用性更强。

此外, 20 对描述词中, 有 4 对在不同评价场景下表现出显著差异 (Warm (+)–Cool (–)、Insulating (+)–Conductive (–)、Dry (+)–Wet (–)、Breathable (+)–Non-breathable (–)), 其变化趋势与 ANOVA 分析结果一致。这表明 d'_A 值可以作为感官评价结果的定量指标, 反应不同场景对描述词适用性的影响。

2.5 分析与讨论

基于混合效应模型与 SDT 的统计检验, 揭示织物手感评价中场景、描述词及其交互作用的内部机制。下文从表面性能、压缩与弯曲性能、拉伸性能以及热湿性能等不同维度进行分层次讨论, 并通过关键交互效应结果加以说明。

2.5.1 手感性能显著性分析

(1) 表面性能的显著性讨论

在描述词效应方面(如表 2-3 所示), 对于“Smooth (+)–Rough (–)”描述词对, 描述词主效应达到显著水平 ($F=8.53, p<0.01$), 这表明评价者在对“光滑”与“粗糙”的感知上存在固有偏好。具体而言, 上标度 (+) 评分的均值 ($M=3.5, SD=1.2$) 显著高于下标度 (–) 反向评分 ($M=2.1, SD=1.4$), 显示出评价员倾向于选择相对正向的手感描述词, 而回避相对负面的描述词。

在场景效应与交互作用方面, 方差分析结果显示场景效应 ($F=1.98, p=0.138$) 及其

与描述词的交互效应 ($F=0.49$, $p=0.613$) 均不显著。这一结果验证视觉与触觉评价在表面性能上的一致性 ($ICC=0.87$), 说明在表面性能的感知上, 图像与视频场景并未与触觉产生系统性偏差。

表 2-3 关键 ANOVA 结果

Table 2-3 Key ANOVA results.

Category	Descriptors	F Scenario	F Descriptor	F Sce.×F Des.
Surface	Smooth-Rough	1.98	8.53	0.49
Compression	Soft-Hard	1.07	6.53	2.73
Stretching	Flexible-Stiff	1.18	14.95	2.66
Thermal-wet	Warm-cool	42.16	2.15	0.63
Thermal-wet	Dry-wet	19.24	15.04	5.68

注: 加粗表示显著性 ($p<0.05$)

(2) 压缩与弯曲性能显著性讨论

对于压缩性能,“Soft(+)-Hard(-)”描述词对的描述词效应显著($F=6.53$, $p<0.05$), 但场景效应 ($F=1.07$, $p=0.343$) 不显著, 意味着评价者可以通过视觉动态形变 (例如压缩恢复轨迹) 来准确判断柔软度。光流分析进一步显示, 压缩视频中形变速率 ($v=0.12\text{px/frame}$) 与触觉评分呈负相关 ($r=-0.67$, $p<0.001$), 从而验证动态视频在传递柔软与硬度差异方面的有效性。

在弯曲性能方面, 场景效应 ($F=2.18$, $p=0.115$) 虽未达显著, 但“Rigid(+)-Pilable(-)”描述词对的评分分布表明, 视频场景中上标度 (+) 评分的离散度 ($SD=1.1$) 低于图像场景 ($SD=1.5$)。这一结果说明, 动态视频能够提供更稳定的弯曲刚度评价信息, 评价者对弯曲性能的判断在视频条件下更为集中, 也更接近触觉评价。

(3) 拉伸性能显著性讨论

在拉伸性能方面,“Flexible(+)-Stiff(-)”描述词对的描述词效应极显著($F=14.95$, $p<0.001$), 同时交互效应 ($F=2.66$, $p=0.071$) 处于边缘显著水平。视频场景中, 光流轨迹的曲率半径 (R_c) 与拉伸性能评分呈明显相关: 当 $R_c<50\text{px}$ 时, 评分均值为 2.5 ($SD=0.8$), 而当 $R_c>100\text{px}$ 时, 评分均值为 2.9 ($SD=1.3$)。这一规律说明, 视频所捕捉到的拉伸形变轨迹能够直观传达织物手感在灵活与僵硬方面的差异。进一步通过 Mann-Whitney U 检验^[120], 视频与触觉场景的评分分布并无显著差异 ($U=1203$, $p=0.214$)。此结果为视觉表征在拉伸性能评价中的可靠性提供支持, 也表明拉伸性能的动态信息与触觉感知之间的评价结果高度一致。

(4) 热湿性能的评价失效

在场景效应主导方面, 热湿类别中“Warm(+)-Cool(-)” ($F=42.16$, $p<0.001$) 与“Dry(+)-Wet(-)” ($F=19.24$, $p<0.001$) 等描述词对均呈现极显著的场景效应。

触觉场景中“Warm (+)”评分 ($M=3.4, SD=0.9$) 显著低于图像场景 ($M=4.1, SD=1.5$), 而“Cool (-)”在触觉和图像之间则出现相反的评分趋势。这表明, 热湿感知在视觉与触觉间存在明显差距。

在交互效应解析方面, “Dry (+) - Wet (-)”描述词对的场景/描述词交互效应 ($F=5.68, p<0.05$) 呈显著水平, 表明视觉评价中干燥与湿润的感知逻辑与触觉存在本质差异。

(5) 综合讨论

图 2-8 中对比四类性能的评价一致性。在表面、压缩、弯曲与拉伸性能上, 各场景的评分分布呈高重叠度 (Jaccard 相似度 >0.75), 显示视觉与触觉评价的良好一致性。而在热湿性能上, 评分分布则出现明显的双峰特征, 触觉场景多集中于高分区 ($S>4$), 视觉场景则分散在中低分区 ($S \in [2,4]$)。这一差异表明, 视觉表征无法有效传递热湿信息。

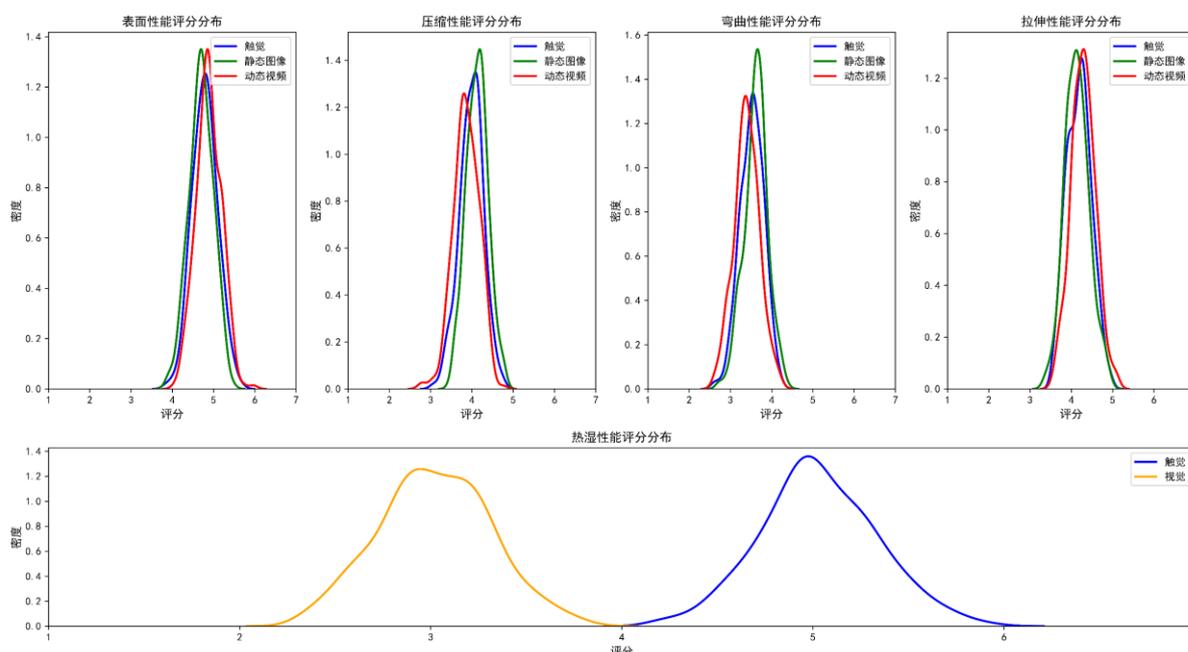


图 2-8 跨场景评价一致性对比

Figure 2-8 Cross-scenario evaluation consistency comparison

综合来看, 混合效应模型与 SDT 分析共同表明, 视觉表征能够替代触觉评价表面、压缩、弯曲和拉伸性能 (假设 H1 成立), 但在热湿性能上必须依赖物理接触 (假设 H2 成立)。

2.5.2 手感性能一致性分析

(1) 跨场景一致性分析

对于表面、压缩、弯曲和拉伸四类机械性能, 计算组内相关系数 ($ICC(3,k)$) 与场

景效应 F 值, 结果表明 (表 2-4) 表面性能的 ICC 为 0.87 (95% CI: 0.82–0.91), 压缩性能、弯曲性能和拉伸性能的 ICC 均不低于 0.79, 同时各场景间的 F 检验均未达到显著性 (例如表面性能 $F=1.32$, $p=0.268$), 表明不同模态间的评价结果在这些性能上具有较高的一致性。

表 2-4 跨场景一致性 ICC 验证结果

Table 2-4 Cross-scenario consistency test results of ICC.

Category	ICC	95% CI	F	p
Surface	0.87	0.82-0.91	1.32	0.268
Compression	0.79	0.73-0.84	2.01	0.135
Bending	0.81	0.76-0.86	1.89	0.152
Stretching	0.83	0.78-0.88	1.57	0.209

进一步对表面、压缩、弯曲、拉伸和热湿性能, 计算跨场景一致性指数 (CCI), 结果表明 (表 2-5) 表面、压缩、弯曲和拉伸特性的 CCI 均 >0.80 , 显示优秀的跨场景一致性, 热湿感特性的 $CCI < 0.35$, 表明视觉场景与实触场景评价存在显著差异。其中, 对于弯曲和拉伸特性, 视频场景的 CCI 高于图像场景, 这证实动态信息 (如形变速率、恢复过程) 在评价织物手感性能中的重要性。从视频中可以观察到织物在外力作用下的变形过程和恢复特性, 这些动态特征为评价面料的机械性能提供更丰富的视觉线索。

表 2-5 跨场景一致性 CCI 验证结果

Table 2-5 Cross-scenario consistency test results of CCI.

Category	CCI range	95% CI
Surface	0.84-0.88	[0.80,0.91]
Compression	0.81-0.83	[0.77,0.87]
Bending	0.82-0.85	[0.78,0.89]
Stretching	0.80-0.82	[0.76,0.86]
Thermal-wet	0.31-0.34	[0.25,0.40]

(2) 适用性幅度 d'_A 验证

对热湿性能外的 16 对描述词, 计算 SDT 框架下的 d'_A 值,

$$d'_A = Z\left(\frac{\text{Hits}}{\text{Hits} + \text{Misses}}\right) - Z\left(\frac{\text{False Alarms}}{\text{False Alarms} + \text{Correct Rejections}}\right) \quad (2-13)$$

表 2-6 显示, 对于表面、压缩、弯曲与拉伸性能, d'_A 均处于 1.5 以上 (例如表面性能的 d'_A 分布在 1.8 到 2.3 之间, $p < 0.001$), 这表明视觉表征在传递相应织物物理属性时具备较高的辨别能力, 与触觉评价结果保持高度一致。

表 2-6 d'_A 范围结果

Table 2-6 d'_A range result.

Category	d'_A range	p
Surface	[1.8,2.3]	<0.001
Compression	[1.6,2.3]	<0.01
Bending	[1.7,2.4]	<0.001
Stretching	[1.7,2.4]	<0.001

2.5.3 热湿性能的视觉不可评价性分析

与机械性能不同，热湿性能（Warm（+）- Cool（-）、Insulating（+）- Conductive（-）、Dry（+）- Wet（-）、Breathable（+）- Non-breathable（-））的评价显示出明显的模态差异。

（1）ANOVA 场景效应

对“Warm（+）- Cool（-）”描述词对（ $F=18.37$, $p<0.001$ ），触觉场景中的评分（例如 Cool（-）评分 $M=2.9$, $SD=1.10$ ）显著高于图像（ $M=2.8$, $SD=1.4$ ）。

（2）混淆矩阵分析

进一步的混淆矩阵分析显示（表 2-7），视觉场景下热湿属性的总体准确率仅为 54.3%（95% CI: 49.7 - 58.9%），而触觉场景的准确率高达 89.6%（95% CI: 86.2 - 92.3%），且 Kappa 系数仅为 0.12（ $p=0.083$ ），表明视觉评价结果与触觉评价几乎无一致性。

表 2-7 混淆矩阵分析结果

Table 2-7 Confusion matrix analysis results.

Real Label/Predict Label	Predicted Warm（+）	Predicted Cool（-）
True Warm（+）	32	18
True Cool（-）	29	22

这一现象的物理解释在于，热湿感知依赖于织物纤维的导热系数（ λ ）与吸湿率（ β ），但视觉特征（如厚度、纹理及孔隙率）与这些物理属性之间的相关性较弱。

通过多元回归分析：

$$\lambda = 0.15 \cdot \text{厚度} + 0.08 \cdot \text{GLCM熵} - 0.03 \cdot \text{光流方差} + \beta \quad (2-14)$$

得知 $R^2=0.21$ （ $p=0.003$ ），表明仅 21%的导热系数变异可由视觉表征解释，远低于触觉评价所能达到的 $R^2=0.79$ （ $p<0.001$ ），从而证明即使在视频场景中增加动态信息，也无法有效改善热湿特性的评价准确性。这反映视觉感知与触觉感知之间的本质差异，特别是在涉及热传导和湿度感知的属性上，进一步说明视觉表征在热湿性能的局限性。

2.6 本章小结

本章系统地分析织物触觉特性的视觉评价能力,并通过构建跨场景感官评价框架和双面适用性测试(DFA)模型验证不同评价场景下织物特性评价的一致性,为织物数字化与远程评价提供坚实的理论与方法支持。主要结论归纳如下:

(1) 本章提出跨模态的评价方法,并构建理论分析框架。通过基于信号检测理论的 DFA 模型和“二值选择+确信度评分”流程,将主观感官评价转化为定量指标(d'_A 与 ICC),有效抑制趋同响应偏差;同时,采用四因素混合效应 ANOVA 模型并结合 Satterthwaite 自由度修正,精细解析场景、描述词、样本与评价者之间的交互作用,建立跨模态一致性验证的标准化范式。

(2) 本章验证视觉表征在机械性能评价中的有效性。实验结果显示,在表面、压缩、弯曲和拉伸四类性能上,触觉、静态图像与动态视频三种模态下的评分分布高度重叠(ICC 均超过 0.75),且适应性幅度 d'_A 普遍大于 1.5,充分证明视觉信息在传递织物机械特性(如表面纹理、柔软度、弯曲刚度与拉伸灵活性)方面具有较高的可靠性。

(3) 本章发现视觉表征在热湿性能评价中存在明显局限。对于透气性、导热性和湿度感知等热湿特性,视觉模态下的评分分布呈现明显双峰现象,且 d'_A 低于 0.5,显示出视觉信息难以准确捕捉织物的热湿属性;多元回归分析进一步表明,视觉特征与纤维导热系数和吸湿率之间的关联性较弱($R^2=0.21$),因此热湿性能被排除于后续研究之外。

综上所述,本章通过跨场景感官评价,不仅获得真实的触觉评分,还建立可信的织物视觉表征。实验结果证明,在表面、压缩、弯曲和拉伸性能上,视觉信息能够有效反映织物手感,而热湿性能则因视觉特征与导热系数和吸湿率关联性较弱而不适合作为视觉评价的依据。基于此,后续研究将聚焦于利用织物视觉表征,通过特征工程提取关键手感特征,构建基于视觉信息的织物手感评价模型,从而实现织物数字化评价的智能化和标准化。

第3章 织物手感视觉量化指标的体系化构建与优化

织物手感的评价是纺织工程领域的重要研究方向,传统方法依赖人工触觉或昂贵的物理测试设备,难以满足现代工业对高效、数字化评价的需求。第2章通过实验验证视觉表征(静态图像和动态视频)在表面、压缩、弯曲和拉伸性能评价中的有效性,揭示其替代触觉评价的潜力。然而,要实现这一目标,需从视觉数据中提取能够精准反映手感性能的量化特征,建立系统化的表征体系。考虑到织物手感通常按不同物理维度(如柔软、挺括、弹性等)进行分项评价,类似于KES系统的构建方式,采用具备物理意义和可控性的人工特征更有助于建立“性能-感知”之间的清晰映射关系。特征工程作为计算机视觉与机器学习的关键环节,通过设计和选择具有物理意义和统计可靠性的指标,能够将复杂的视觉信息转化为可计算的输入,为后续模型开发提供基础。

本章基于特征工程的思路,利用图像和视频处理技术,针对第二章验证的4类可行性能(表面、压缩、弯曲、拉伸),构建一套包含33个视觉指标的表征体系。通过对101个织物样本的感官数据和KES物理测量数据的对比分析,采用方差膨胀因子和Lasso回归去除冗余特征,最终保留22个关键指标。实验结果将验证所提指标与真实感官评价及物理测量的一致性,为第4章的多模态融合模型提供高质量输入数据。

3.1 引言

第2章的实验结果表明,视觉表征(静态图像和动态视频)能够有效反映表面、压缩、弯曲和拉伸性能的感官评价($CCI>0.80$),为非接触式评价开辟新路径。然而,视觉数据的高维性和复杂性使得直接将其用于手感评价具有挑战性。要实现从图像和视频到手感性能的准确映射,必须提取能够量化这些性能的视觉特征,建立科学合理的织物手感表征体系。

特征工程在计算机视觉领域扮演着桥梁角色,通过设计和选择具有物理意义和统计意义的特征,将原始数据转化为机器可理解的输入。针对织物手感评价,视觉特征需满足以下要求:一是与感官评价高度相关,如表面纹理特征应反映“柔软-粗糙”的感知;二是与物理测量一致,如弯曲特征应与KES刚度参数对应;三是具有低冗余性和高区分度,避免特征间共线性影响后续建模。现有研究在织物视觉分析中取得一定进展,如Zhu等^[71]利用灰度共生矩阵量化表面粗糙度,Huang等^[121]通过光流分析提取动态形变特征。然而,这些研究多集中于单一属性,缺乏针对手感多维性能的系统性特征设计。此外,特征冗余性和选择依据的不足限制其在手感评价中的应用。

本章的研究目标是基于第2章验证的可行性能(表面、压缩、弯曲、拉伸),利用图像和视频处理技术,构建一套全面的织物视觉表征体系。研究以特征工程为核心,初步设计33个视觉指标,涵盖图像的纹理、边缘特征以及视频的动态形变和运动特性。

为确保特征的有效性和非冗余性，采用方差膨胀因子（VIF）^[122]检测共线性，结合 Lasso 回归^[123]进行特征选择，最终筛选出 22 个关键指标。进一步通过一致性分析，验证这些指标与真实手感评价及物理测量（KES）的相关性，确保其在后续端到端评价中的适用性。本章回答的关键问题包括：哪些视觉特征能够精准表征手感性能？所提指标体系与感官和物理数据的一致性如何？特征选择如何优化表征效率？本节技术路线图如图 3-1 所示。

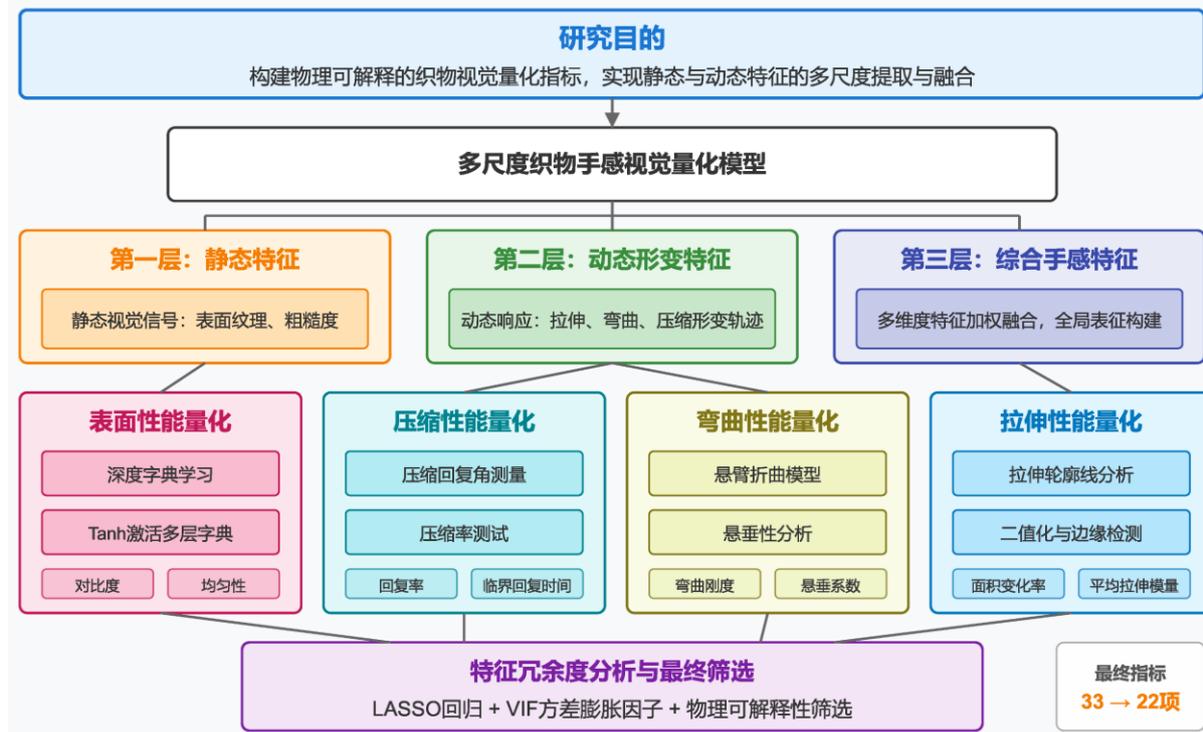


图 3-1 本章技术路线图

Figure 3-1 The technical route of chapter 3

3.2 面向织物手感的视觉量化模型构建

3.2.1 模型构建思路

本研究提出基于多尺度手感特征融合的量化框架，旨在构建从图像/视频信号到织物物理性能的定量映射关系。其理论基础主要包括多尺度信号分解理论与物理驱动的特征选择准则，具体思路如下：

(1) 多尺度信号分解

织物在表面纹理与宏观形变等空间维度，以及动态恢复与拉伸过程等时间维度，均呈现多尺度特性。为提取不同尺度下的纹理和形变信息，框架结合小波变换（Wavelet Transform）^[55]与傅里叶变换（Fourier Transform）^[43]的频域-空域联合分析。

(a) 小波变换

对任意信号 $f(t)$ 进行小波变换, 可得

$$WT_{\psi}(f)(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (3-1)$$

其中, a 为尺度因子、 b 为平移因子、 $\psi(t)$ 为母小波函数。通过调整 a 可以提取不同尺度下的纹理特征 (如粗糙度、纹理密度等), 从而捕捉局部突变特征。

小波基函数通常具备紧支集特性, 例如 Haar 小波满足

$$\psi(t) = \begin{cases} 1, 0 \leq t < 0.5 \\ -1, 0.5 \leq t < 1 \\ 0, \text{otherwise} \end{cases} \quad (3-2)$$

正交性与紧支集性保证多尺度分解在时域和频域上均无信息冗余, 适用于检测织物纹理的局部突变。

(b) 短时傅里叶变换 (STFT)

对动态视频中形变过程进行时频分析时, 采用短时傅里叶变换

$$STFT\{f(\tau)\}(t,\omega) = \int_{-\infty}^{\infty} f(\tau) w(\tau-t) e^{-i\omega\tau} d\tau, \quad (3-3)$$

其中, $w(\tau-t)$ 为窗函数, 用于局部化信号, 在小范围内提取织物动态形变的频域特征。

(2) 物理驱动的特征选择准则

为建立视觉特征 F_v 与物理参数 P_p (如弯曲刚度 B 、压缩率 C 等) 之间的映射关系, 构建多元回归模型:

$$P_p = \beta_0 + \sum_k \beta_k F_v^k + \epsilon, \quad (3-4)$$

其中, β_k 为待估计系数, ϵ 为随机误差。为筛选出对物理性能解释力最强的视觉特征子集, 采用 LASSO 回归进行特征选择, 优化目标函数为:

$$\min_{\beta} \frac{1}{2n} \sum_{i=1}^n \left(y_i - \beta_0 - \sum_k \beta_k x_{ik} \right)^2 + \lambda \sum_k |\beta_k|, \quad (3-5)$$

其中, λ 为正则化系数。LASSO 的几何解释是通过 L_1 范数惩罚实现稀疏解, 当 λ 较大时, 部分 β_k 收敛为 0, 从而去除冗余或不显著的特征。该方法在保证模型解释力的同时, 提高特征子集的可解释性并抑制过拟合。

LASSO 回归能在维持模型准确度的前提下实现特征稀疏化, 用于去除多余或弱相关的视觉特征, 使得模型具有更好的可解释性和稳健性。这对于织物手感评价而言尤为重要, 因为需要将与物理性能无关的噪声特征剔除, 保留最能表征织物真实特性的指标。

3.2.2 多尺度织物手感的视觉量化模型

本章提出的多尺度织物手感视觉量化模型通过分层特征提取与融合架构, 对织物表

征进行多角度、多尺度分析。该模型的核心目的是为织物手感评价提供视觉替代方案，具体通过分三层逐级提取并融合静态与动态特征，以捕捉织物手感的多维度信息。

织物手感的感知过程是一个多因素、复杂的动态交互过程，既包含织物表面结构的静态信息，也包含织物在力学作用下的动态响应。为有效提取这些信息，本研究将模型构建为三层结构（如图 3-2 所示），分别对应织物视觉表征和手感的不同方面。

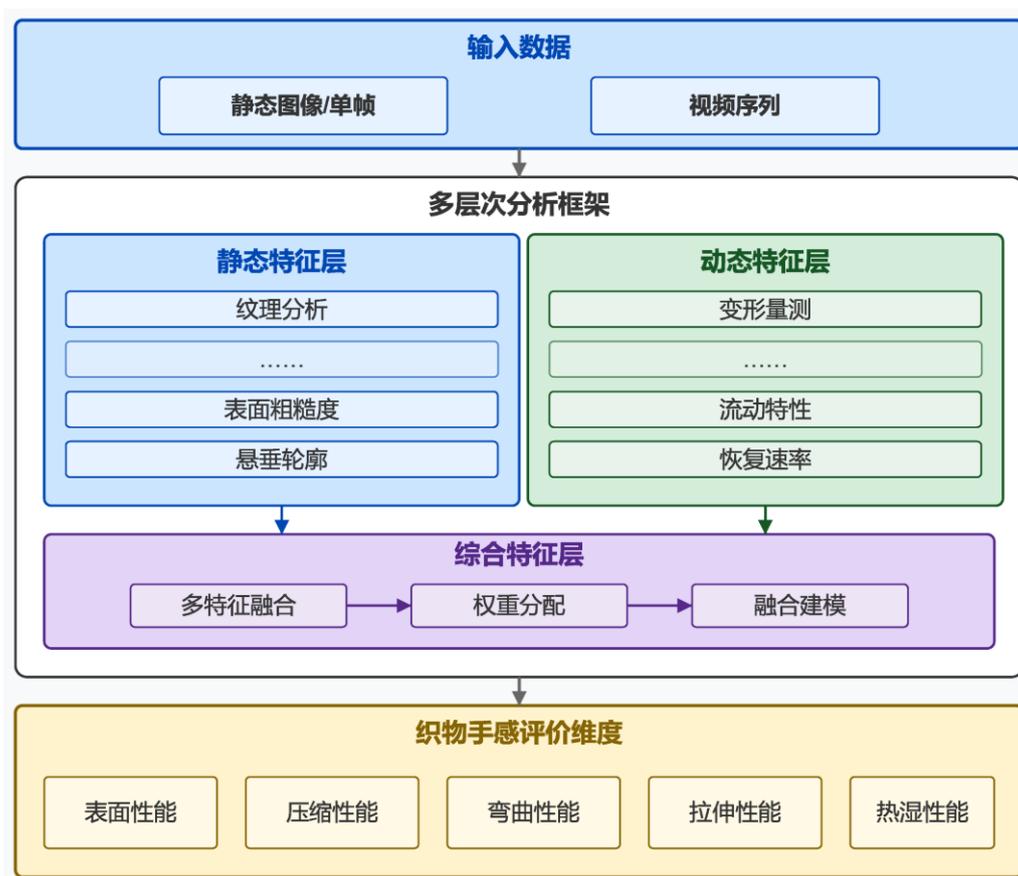


图 3-2 织物手感多层次分析框架

Figure 3-2 Framework for multilevel analysis of fabric hand

(a) 静态特征

在第一层，模型聚焦于从织物的视觉信号中提取单一的手感信息。此层的目标是仅反映织物在特定条件下（如表面、拉伸、压缩等）的静态视觉特征，如表面的纹理、粗糙度、颜色、拉伸或压缩状态下的图像表现等。每一类图像仅针对特定手感感知维度，例如表面信息将仅呈现织物的表面纹理与粗糙度，而压缩的图像仅呈现织物的压缩程度。

通过对图像细节的分析，能够量化织物表面的纹理特性，进一步揭示表面手感的基础感知，如织物的光滑度和粗糙度等。这一层特征主要通过频域分析（如傅里叶变换、小波变换等）提取织物的表面纹理，并利用颜色空间模型（如 RGB、HSV）提取织物颜色的分布特性。

然而，这一层的特征主要反映织物的静态视觉表现，并不足以全面解释织物手感的感知，尤其是在织物受力形变时，这些特征无法充分捕捉织物的动态特性。因此，第一层特征提取为后续层次的动态与宏观特征分析提供必要的基础。

(b) 动态形变特征

第二层特征处理侧重于捕捉织物在外力作用下的形变过程。织物在使用过程中经历的弯曲、拉伸、压缩等变形会影响其手感表现，如柔软度、弹性等物理特性。此层通过对织物在拉伸、弯曲等力学条件下的动态变化进行时序分析，量化织物的动态响应特性。

这一层特征通过时间序列数据分析，如通过光流法、时序曲线拟合等方法提取动态形变的响应信息。拉伸或压缩过程中织物表面纹理的变化、弯曲角度的变化等能够有效反映织物的柔韧性、弹性和顺滑性。例如，拉伸应变可以通过以下公式定义：

$$\epsilon = \frac{x_{final} - x_{initial}}{x_{initial}} \quad (3-6)$$

其中， x_{final} 为拉伸后的形变位置， $x_{initial}$ 为未受力时的位置。

动态形变特征直接影响织物手感中的“柔软性”和“韧性”感知，是第二层次在手感量化中的核心。通过对织物动态响应的量化处理，能够深入理解织物在使用过程中的物理表现及其与感官反馈之间的关系。

(c) 综合手感特征

第三层特征提取聚焦于织物手感的综合性分析，通过对前两层特征的综合处理，提供织物手感的全局表征。该层特征不仅仅依赖于单一的物理量或视觉特征，而是将多种特征（包括视觉、动态形变和物理性能特征）进行综合分析，从全局角度描述织物的整体手感特性。

这一层的目标是对织物手感进行宏观的综合量化，将织物的视觉表现、动态响应和物理性能特征聚合，以形成更加全面、准确的手感表征。它通过多维度特征的融合，能够同时考虑织物的柔软性、厚重感、光泽感、弹性等多方面的感官体验。例如，可以通过结合织物的表面纹理、形变响应以及宏观物理性能（如密度、刚性等），实现织物在使用过程中的整体感知量化。综合特征可以通过加权聚合的方式结合多个维度的特征。设不同维度特征为 f_1, f_2, \dots, f_n ，权重为 $\omega_1, \omega_2, \dots, \omega_n$ ，则织物的综合感知特征可表示为：

$$F_{comprehensive} = \sum_{i=1}^n \omega_i f_i \quad (3-7)$$

其中， ω_i 为每个特征的权重， f_i 为对应的感官特征值。通过合理的权重分配，可以确保各个特征在综合评价中的影响力与其物理和感官重要性一致。

这种分层结构的设计理念在于，织物手感的感知是一个多维、层次化的过程，涵盖从微观结构、动态响应到宏观性能的各个层面。第一层的织物视觉特征提取为织物表面信息提供必要的基础，第二层的动态形变特征则结合织物的物理响应，揭示织物的弹性和柔韧性等关键手感特性。最后，第三层的综合特征通过全局综合分析，提供织物手感

的宏观表征, 帮助我们从视觉上捕捉到织物的整体感觉。这种分层设计不仅能够保证从不同尺度和维度提取织物手感的视觉信息, 还能确保这些信息在后续分析中能够有效融合与应用, 为织物的设计、生产和质量控制提供数字化支持。

3.2.3 评价指标

为确保所提特征体系能够真实、稳定地反映织物的物理属性, 本研究在特征设计阶段即考虑冗余度控制和跨模态一致性两个关键方面。后续在实验中将通过以下指标与分析方法, 对特征的有效性进行验证。

(1) 方差膨胀因子 (VIF)

当特征间存在多重共线性时, 回归或机器学习模型的系数估计不稳定。VIF 定义为

$$\text{VIF}_j = \frac{1}{1 - R_j^2}, \quad (3-8)$$

其中, R_j^2 是第 j 个特征对其余特征回归时的决定系数。若 $\text{VIF}_j \gg 1$ (通常设阈值 5 或 10), 则表示第 j 个特征可由其他特征线性组合高度解释, 存在冗余。此分析可帮助在最终模型中保留最具代表性的特征子集。

(2) Pearson 相关性指数

用于评价预测值与真实值之间的线性相关性, 公式如(3-9)所示:

$$\text{Pearson} = \frac{\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \quad (3-9)$$

Pearson 相关系数范围为[-1, 1], 值越接近 1 表示预测值与真实值越相关, 反映模型预测与人类感官评分的一致性。

通过以上两方面的评价, 本研究将在后续章节结合实际实验数据, 验证所提特征集是否能在统计学与物理机理上与触觉评价/仪器测量保持一致、去除冗余, 提供可解释的手感评价能力。

3.3 视觉特征指标体系设计

本节围绕如何从图像和视频中提取客观指标, 构建多层次的特征提取流程, 旨在量化织物手感的四种主要性能: 表面、压缩、弯曲和拉伸。研究基于 101 个织物样本, 通过图像预处理和关键帧捕捉, 为后续特征提取提供高质量数据输入。本节设计 33 个视觉量化指标, 利用深度字典学习、图像分析和几何建模等方法, 从静态图像和动态视频中提取特征, 全面表征手感性能。以下详细阐述样本预处理及各性能指标的构建方法, 为后续一致性检验和冗余度检验分析奠定基础。

3.3.1 样本预处理

在提取手感性能指标前，需对图像和视频帧进行标准化预处理，以确保数据质量并减少无关干扰。预处理流程包括灰度化与背景分割、ROI 剪裁与去噪以及关键帧捕捉，具体如下：

(1) 灰度化与背景分割

为简化后续分析，利用加权平均将彩色图像转换为灰度图，公式如(3-10)所示：

$$V_{\text{RGB}} = 0.299 \times k_R + 0.587 \times k_G + 0.114 \times k_B \quad (3-10)$$

该方法基于人眼对红、绿、蓝三色的感知敏感度，生成灰度图像。随后，采用 Otsu 算法^[124]进行全局阈值分割，实现样本与背景的有效分离。Otsu 算法通过最大化类间方差自动确定阈值，特别适用于背景与织物颜色对比明显的场景，确保分割效果。

(2) ROI 剪裁与去噪

使用 Harris 角点检测算法^[105]或人工标注确定感兴趣区域(Region of Interest, ROI)，裁剪图像以去除无关背景干扰。Harris 算法通过计算角点响应函数检测织物边缘特征点，定位精度优于传统梯度方法。

随后，应用自适应中值滤波器 (RAMF)^[125]去除噪声，相比传统中值滤波，RAMF 自适应调整窗口大小，能更好保留织物纹理和形变细节，确保后续特征提取的准确性。

(3) 关键帧捕捉

针对视频场景，检测织物在弯曲或拉伸过程中达到特定形变（如 45° 悬臂角、最大延伸长度等）时刻的帧，提取关键帧以降低数据量并保证形变特征的准确性。

3.3.2 视觉特征提取与指标构建

基于预处理后的图像和视频数据，本节针对表面、压缩、弯曲和拉伸四类手感性能，设计 33 个视觉量化指标。指标提取结合深度字典、图像分析和几何建模等方法，确保特征的物理意义和感官相关性。

(1) 表面性能量化指标

在织物手感分析中，粗糙度作为重要的表面特征，直接影响织物的触感和视觉感知。传统的纹理分析方法如灰度共生矩阵对复杂纹理的适应性较差，无法自适应地提取丰富的纹理信息。因此，本文提出一种基于深度字典学习^[126]的织物图像粗糙度量方法（如图 3-3 所示）。该方法通过多层次的字典学习机制，能够逐层提取和组合不同层次的纹理特征，从而更精准地反映织物表面的粗糙度。

深度字典学习将输入图像 X 分解为多个字典层，表示为：

$$X \approx A_1 D_1 D_2 \cdots D_L \quad (3-11)$$

其中， D_1, D_2, \dots, D_L 为多层字典，每层字典 D_l 提取不同层次的特征。第一层字典学习通过最小化以下损失函数来学习字典 D_1 和稀疏编码 A_1 ：

$$\min_{A_1, D_1} \|X - A_1 D_1\|_F^2 + \lambda \|A_1\|_1, \quad \text{s.t.} \|D_{1..k}\|_2 \leq 1 \quad (3-12)$$

后续层字典学习以上一层的稀疏编码为输入，递归进行字典学习，最终得到深层稀疏编码 A_L ，捕捉图像的深层特征。

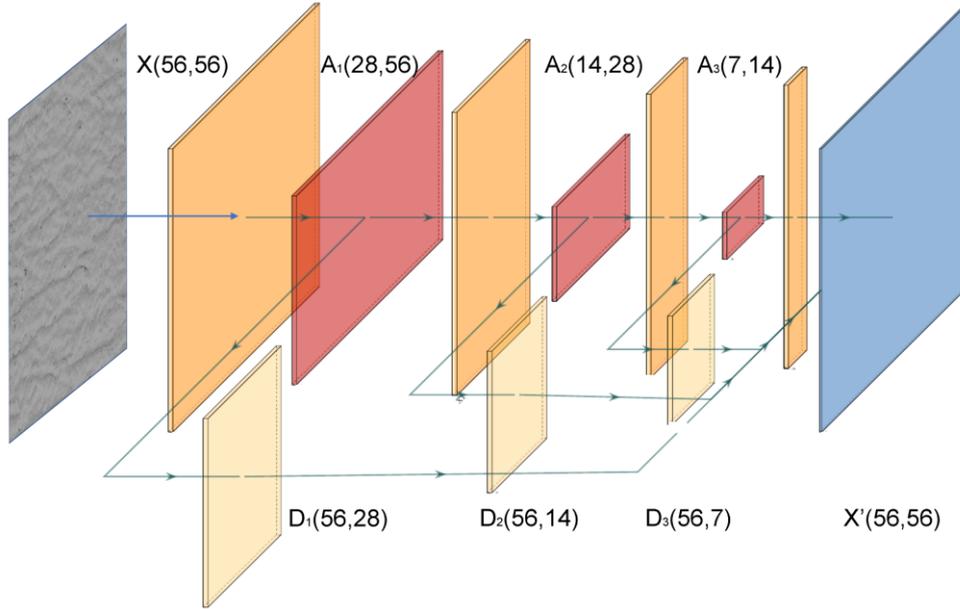


图 3-3 本文构建三层字典框架

Figure 3-3 Proposed framework for three-level dictionary

在应用深度字典学习之前，首先将图像转换为灰度图，并将图像分成 $b \times b$ 的不重叠块。每个图像块展平并组成矩阵：

$$X \in \mathbb{R}^{n_{\text{samples}} \times b^2} \quad (3-13)$$

其中， n_{samples} 为图像块数量。

通过最终的稀疏编码 A_L 提取以下 5 个指标：

(a) 对比度 (Contrast, 指标 1)：

$$\text{Contrast} = \frac{1}{n_{\text{samples}}} \sum_{i=1}^{n_{\text{samples}}} \text{Var}(A_{L,i}) \quad (3-14)$$

其中， $A_{L,i}$ 是第 i 个图像块的稀疏编码向量， $\text{Var}(A_{L,i})$ 是该稀疏编码的方差，衡量局部纹理特征的变化程度。

(b) 能量 (Energy, 指标 2)：

$$\text{Energy} = \frac{1}{n_{\text{samples}}} \sum_{i=1}^{n_{\text{samples}}} \|A_{L,i}\|_2^2 \quad (3-15)$$

其中， $\|A_{L,i}\|_2^2$ 是该稀疏编码的二范数平方，表示编码的强度或纹理的整体一致性。

(c) 相关性 (Correlation, 指标 3):

$$\text{Correlation} = \frac{2}{n_{\text{components}}^{(L)}(n_{\text{components}}^{(L)} - 1)} \sum_{k=1}^{n_{\text{components}}^{(L)}} \sum_{l=k+1}^{n_{\text{components}}^{(L)}} |\rho(A_{L,:,k}, A_{L,:,l})| \quad (3-16)$$

其中, $\rho(A_{L,:,k}, A_{L,:,l})$ 是第 k 和第 l 个原子之间的皮尔逊相关系数, $A_{L,:,k}$ 和 $A_{L,:,l}$ 分别是稀疏编码 A_L 中第 k 和第 l 列的向量, $n_{\text{components}}^{(L)}$ 是第 L 层字典的原子数量。此指标衡量不同原子之间的相似性, 反映纹理的重复性和方向性。

(d) 均匀性 (Homogeneity, 指标 4):

$$\text{Homogeneity} = \frac{1}{C} \sum_{i=1}^{n_{\text{samples}}} \sum_{j=i+1}^{n_{\text{samples}}} \frac{1}{1 + \|A_{L,i} - A_{L,j}\|_1} \quad (3-17)$$

其中, $A_{L,i}$ 和 $A_{L,j}$ 是第 i 和 j 个图像块的稀疏编码向量, $\|A_{L,i} - A_{L,j}\|_1$ 是它们之间的 l_1 距离, 反映局部纹理的一致性。 C 是归一化常数, 表示图像块的配对总数。均匀性衡量织物表面是否平滑。

(e) 粗糙度 (Roughness, 指标 5):

$$\text{Roughness} = \sum_{i=1}^{n_{\text{samples}}} \|A_{L,i} - A_{L,j}\|_1 \quad (3-18)$$

表示图像块之间的差异, 直接量化纹理粗糙度。

图 3-4 显示不同字典层数与不同激活函数重构图片的结果, 通过分析不同激活函数与字典层数下的重构损失值 (表 3-1), Tanh 的重构损失随着层数的增加变化最小, 而 Tanh 2 的重构损失 (3.015) 与 Tanh 1 相差仅为 0.648。进一步通过粗糙度可视化分析 (图 3-5), 可发现 Tanh 2 层字典效果最佳, 能够清晰地体现图像粗糙度。此外, 该结果表明, 在图像重构任务中, 适当增加字典层数能够提升细节表现力, 而 Tanh 激活函数在不同层数下均表现出稳定的重构性能, 有助于提高模型的泛化能力和重构质量。因此, 选择 Tanh 激活函数和 2 层字典作为本文深度字典。

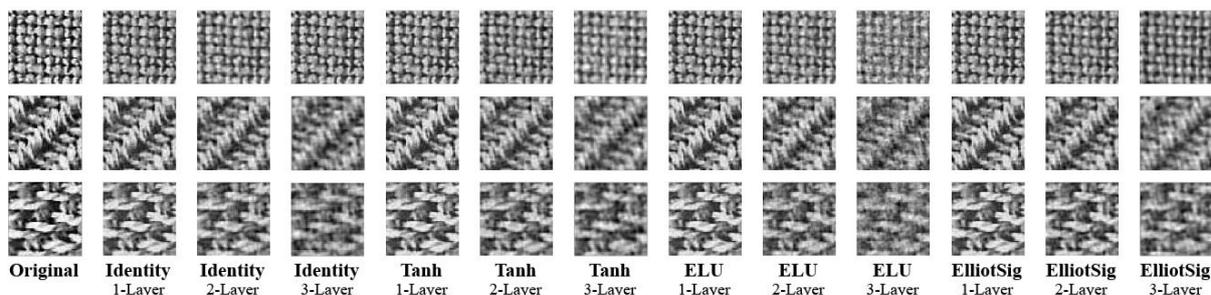


图 3-4 不同字典层数/激活函数重构图像结果

Figure 3-4 Results of image reconstruction with different dictionary layers/activation functions

表 3-1 重构损失结果表

Table 3-1 Reconstruction of loss results.

Activation Function-Layers	Reconstruction Loss
Identify-1	1.122
Identify-2	5.763
Identify-3	30.786
Tanh-1	2.367
Tanh-2	3.015
Tanh-3	10.452
ELU-1	2.557
ELU-2	8.621
ELU-3	18.249
ElliotSig-1	1.512
ElliotSig-2	6.841
ElliotSig-3	12.118

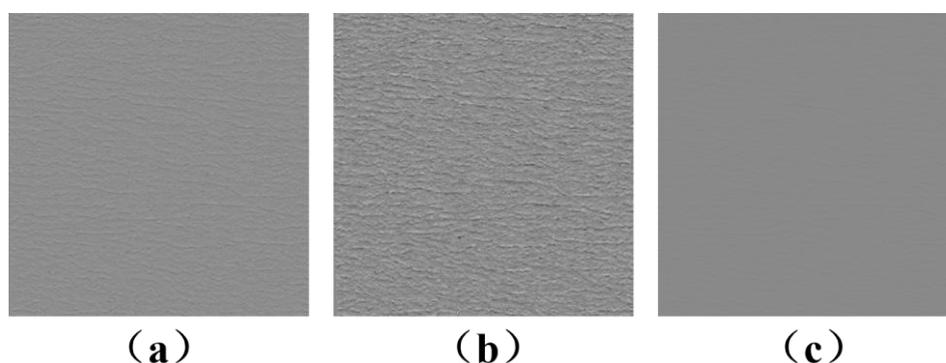


图 3-5 Tanh 不同字典层数粗糙可视化结果：(a) 1 层字典；(b) 2 层字典；(c) 3 层字典

Figure 3-5 Tanh visualization results for different dictionary: (a) 1-layer; (b) 2-layer; (c) 3-layer

(2) 压缩性能量化指标

压缩性能基于对图像和视频分析，量化其回复角和压缩率：

基于图像分析的织物回复角自动测量如图 3-6 (a) 所示，试样受压后自由翼与固定翼形成夹角。采用背景差分法分离试样区域，经二值化处理后（图 3-6 (b)），运用细化算法提取单像素中心线（图 3-6 (c)）。

Hough 变换^[127]通过参数空间映射检测直线角度，其数学模型为：

$$\rho = x \cos \theta + y \sin \theta \quad (3-19)$$

其中, θ 为自由翼回复角。经优化算法处理, 系统可实现 0.1° 测量精度, 动态角度检测结果如图 3-6 (d) 所示。

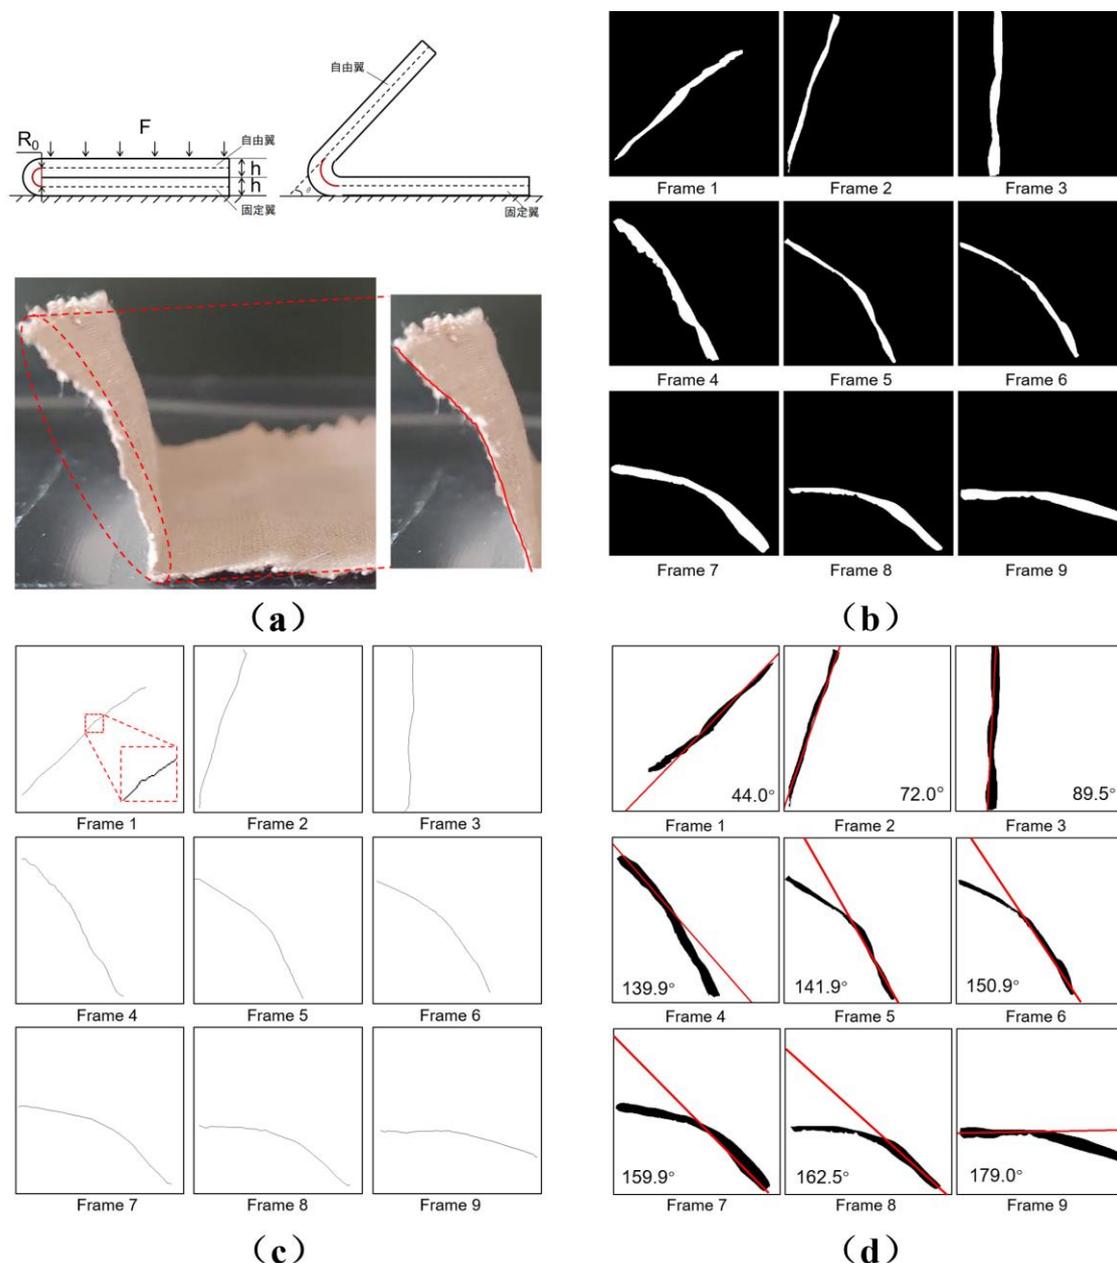


图 3-6 回复角量化过程: (a) 回复角示意图及 ROI 选取; (b) 关键帧二值化处理; (c) 关键帧细化处理; (d) 回复角自动测量

Figure 3-6 Response angle quantization process: (a) response angle schematic and ROI selection; (b) keyframe binarization process; (c) keyframe thin process; (d) automatic response angle measurement

进一步, 通过绘制回复角时序曲线可知 (图 3-7), 回复角曲线的初始阶段呈现急剧上升趋势, 随后逐渐趋于平缓稳定。从该曲线可提取以下 8 个指标, 具体定义如下:

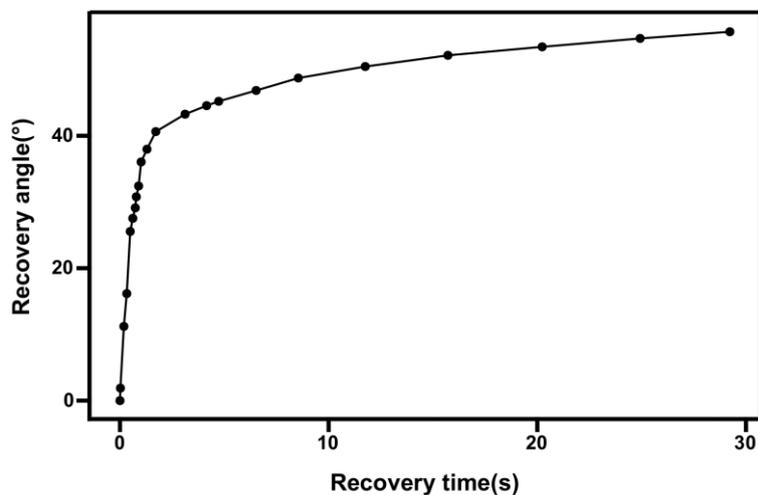


图 3-7 回复角时序曲线

Figure 3-7 Response angle timing curve

(a) 初始响应速率 (Initial response Rate (IR), 指标 6)

表征织物在压力解除瞬间的快速弹性回复能力,通过线性回归分析初始阶段(0-0.2s)角度-时间曲线经最小二乘拟合获得,图 3-8 为样本的拟合方程:

$$A = 24.63t + 7.53, (R^2 = 0.86) \quad (3-20)$$

其中, A 为回复角度, t 为响应时间, IR 值 $24.63^\circ/\text{s}$ 反映材料瞬时回弹特性。

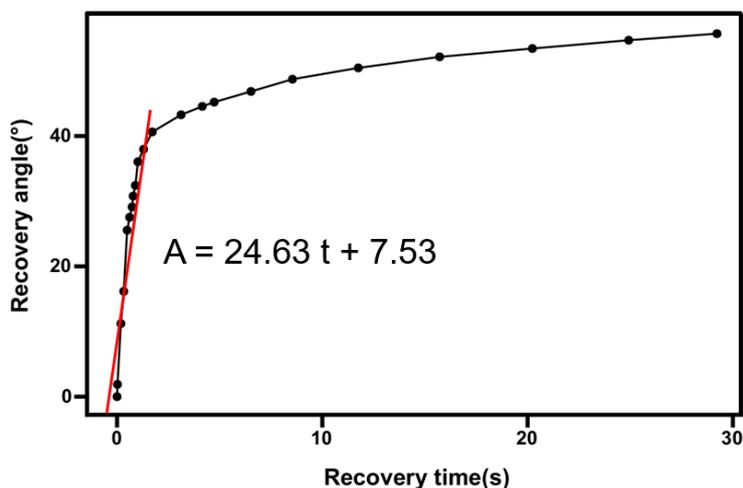


图 3-8 急弹性曲线拟合

Figure 3-8 Sharp elastic deformation fitting

(b) 缓弹性曲线

回复阶段后期(0.2-30秒)的回复角数据。采用 95%置信区间对回复角进行曲线拟

合，得到方程：

$$A(t) = K \cdot t^\eta + \varepsilon \quad (3-21)$$

其中， K 为弹性势能释放强度（指标 7），表征单位时间内弹性储能释放的强度，与材料模量正相关； η 为粘性阻力效应指数（指标 8），反映材料内部摩擦导致的能量耗散速率，值越小表明粘滞阻力越显著； ε 为残余塑性变形量（指标 9），反映压力完全卸载后不可恢复的永久变形角度。图 3-9 中样本的拟合曲线为：

$$A = 34.664t^{0.122} + 3.4578 \quad (3-22)$$

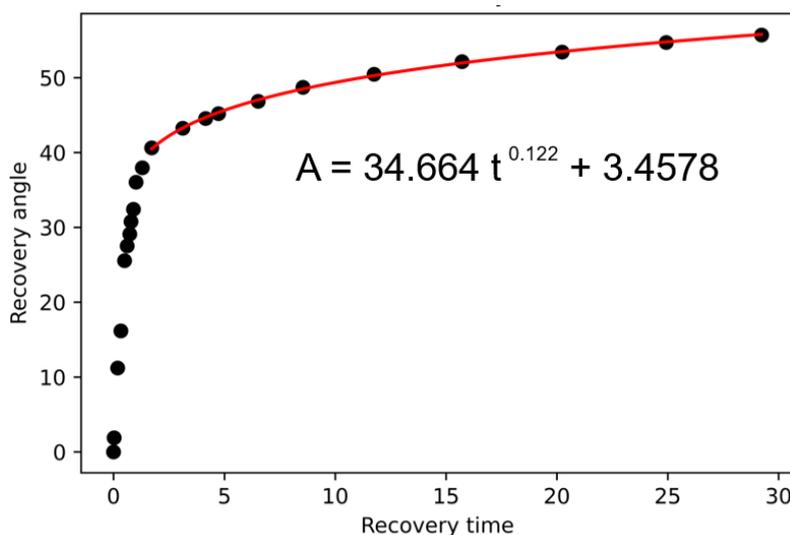


图 3-9 缓弹性曲线拟合

Figure 3-9 Slow elastic deformation fitting

(c) 临界转变时间

从图 3-7 可见，回复阶段初期角度快速增加并近似线性变化，随着回复进程推进，角度增速显著减缓。因此，回复角变化存在由陡增向缓增转变的拐点，该特征可用于表征织物在快速回弹初期的行为特性。通过计算拟合曲线曲率，可精确获取回复角由快速变化向渐变过渡的转折点，标志急弹-缓弹回复转变点，计算公式如下：

$$K = \frac{\left| \frac{d^2\alpha}{dt^2} \right|}{\left[1 + \left(\frac{d\alpha}{dt} \right)^2 \right]^{3/2}} \quad (3-23)$$

图 3-10 样本的拟合曲线的曲率计算公式为：

$$K = \frac{0.0336 |t|^{0.8145}}{(1 + 0.0266t^{-1.93})^{3/2}} \quad (3-24)$$

曲率曲线呈现先增后减趋势，其峰值点定义为临界回复时间 (T_1 ，指标 10)，对应

角度为临界回复角 (α_1 , 指标 11)。试样的临界回复时间与临界回复角分别为 $T_1=5.5s$ 和 $\alpha_1=45.5^\circ$ 。

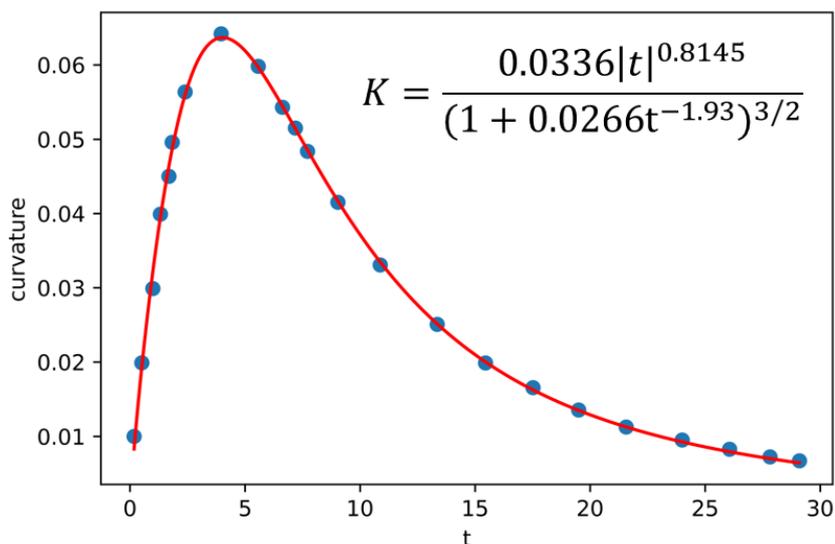


图 3-10 曲率曲线拟合

Figure 3-10 Curvature of the fitted curve

临界回复时间后, 回复角变化逐渐趋缓。本研究将回复角增量在 10 秒间隔内趋于极小的时刻定义为平缓回复时间 (T_2 , 指标 12), 对应角度为平缓回复角 (α_T , 指标 13)。建议采用平缓回复时间作为测试终止时刻, 该指标可动态反映试样的个性化回复特性。相较于现行标准中统一采用 5 分钟固定测试时长的方法, 本方法能更精确表征试样回复性能。由于多数织物在 5 分钟内即达到稳定状态, 引入平缓回复时间可有效缩短测试时长 (效率提升约 83%)。 α_T 表征试样最终回复角度, 平缓回复时间越短且平缓回复角越大, 表明织物压缩回复性能越优。

(d) 回复率 (Recovery Rate (RR), 指标 14)

表征试样在特定时刻的回复完成度, 定义为该时刻回复角与平缓回复角的比值, 其量化任意时刻回复进程:

$$RR(t) = \frac{\alpha(t)}{\alpha_T} \times 100\% \quad (3-25)$$

其中, α 为 t 时刻回复角 ($0 < t < T_2$)。以试样为例, $t=29$ 秒时回复角为 55.7° , $T_2=120$ 秒时平缓回复角 $\alpha_T=59.6^\circ$, 则此时回复率 $RR=55.7^\circ / 59.6^\circ = 0.935$, 表明试样在回复阶段前 29 秒已完成主要回复过程。

图 3-11 (a) 展示一个未考虑织物压缩变形的织物压缩示意图, 其中 h 表示单层织物的厚度; 然而, 在实际中, 织物在受压时会发生微小变形, 如图 3-11 (b) 所示, 此时 $H < 2h$ 。因此, 织物厚度可以进一步被分为无负载时的表观厚度 h_{free} 和受载荷时的稳

定厚度 h_{load} 。织物压缩性能的量化通过 h_{free} 与 h_{load} 的差异实现，基于此，织物压缩性能指标计算如下：

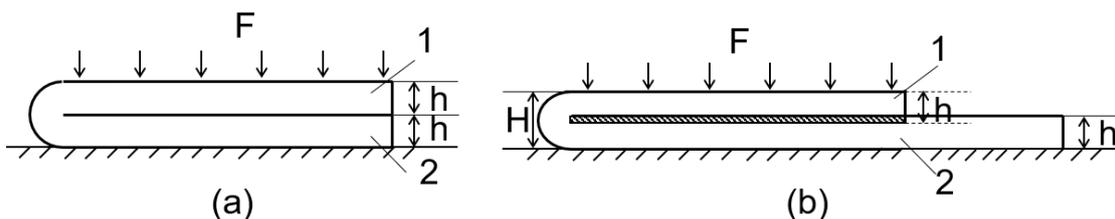


图 3-11 织物受压示意图

Figure 3-11 Compression Schematic

双层织物受压总厚度 H ：

$$H = 2h_{load} \quad (3-26)$$

压缩率 (C , 指标 15)：

$$C = 1 - \frac{H}{2h_{free}} \quad (3-27)$$

反映织物可压缩性，值越大表示蓬松性越好（受压后厚度损失显著）。

表观密度 (γ , 指标 16)：

$$\gamma = \frac{W}{h_{free}} \times 10^{-3} (\text{g} / \text{cm}^3) \quad (3-28)$$

其中， W 是单位体积质量 (g / cm^3)， γ 值越小表示织物越蓬松。

蓬松度 (F , 指标 17)：

$$F = \frac{h_{free}}{W} \times 10^{-3} (\text{cm}^3 / \text{g}) \quad (3-29)$$

与表观密度互为倒数，值越大表示织物越蓬松或结构越稀疏。

进一步通过分析图像中织物厚度与真实织物厚度，建立起等比例关系，可由图像中厚度计算出指标的实际值。结合实验分析，本研究确定图像厚度与真实厚度 1:90 的比例关系。

通过图像量化压缩率的处理过程如图 3-12 所示。图(a)显示受负载的样本 ROI；图(b)显示图像预处理后的二值化图像；图(c)反映沿二值化图像水平轴上每个像素点对应的白色区域的高度，即图像中织物的高度。从图(c)可以清楚地看出，高度由明显的两个高度值组成，可以通过 K 均值聚类^[128]成功分离；图(d)显示分离结果，每类散点的垂直坐标的平均值分别为所求的 $H=75$ 和 $h_{free}=40.5$ 。

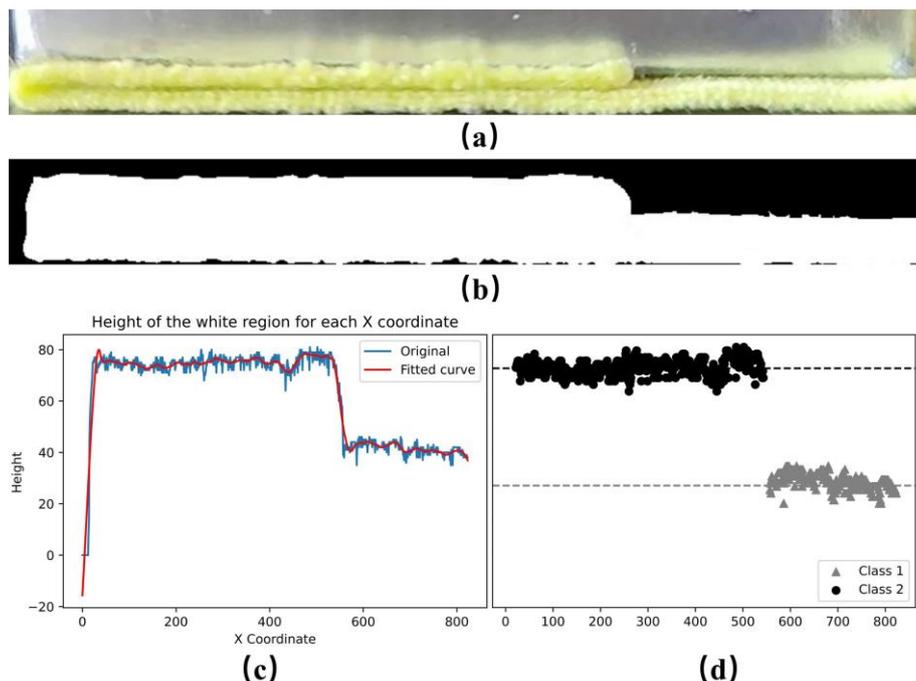


图 3-12 压缩率处理过程：(a) 压缩 ROI；(b) 二值化处理结果；(c) 空白区域像素高度；
(d) 像素高度计算

Figure 3-12 Compression rate processing: (a) compression ROI; (b) binarization result; (c) blank area pixel height; (d) pixel height calculation

(3) 弯曲性能量化指标

织物的弯曲性能是一种重要的力学性能，影响其成型性、悬垂性和褶皱恢复能力。它也是决定服装的挺括性、柔软性和空间表面建模性能的主要因素。1937年，英国物理学家 Peirce^[31]对织物的力学性能进行初步研究。他引入悬臂弯曲模型(如图 3-13 所示)，用于分析织物的弯曲性能，并提出弯曲刚度、弯曲长度和弯曲模量等力学指标。他还首次将织物厚度应用于仪器评价织物的柔韧性和刚性。此外，Peirce 首次提出描述织物在自身重力下弯曲的微分方程：

$$\frac{\partial^2 \varphi}{\partial s^2} + \frac{ws}{B} \cos \varphi = 0 \quad (3-30)$$

及其近似的求解公式：

$$\frac{B}{wl^3} = \frac{\cos \theta / 2}{8 \tan \theta} \quad (3-31)$$

进一步简化得到弯曲刚度：

$$B = wl^3 \cos(\theta / 2) / 8 \tan \theta \quad (3-32)$$

其中， l 是试样的弯曲长度 (cm)； w 是试样的单位面积重量 (g/m^2)； θ 是试样悬臂端的变形角度； B 是弯曲刚度 ($\text{cN}\cdot\text{cm}$)，据此可计算织物弯曲刚度。

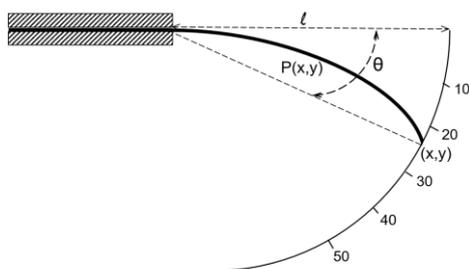


图 3-13 织物悬臂梁模型

Figure 3-13 Textile cantilever beam model

通过图像测量织物弯曲性能的过程如图 3-14 所示。图 (a) 为关键帧获取，初始帧中的白色区域部分与平面成 45° 角。通过比较每一帧中白色区域的像素值与初始帧中该区域的像素值，获得关键帧。随着织物的弯曲，弯曲模式在计算机程序中同步显示。如果织物未弯曲到 45° ，计算机程序中与平面成 45° 角的像素值变化不大；但当像素值首次显著变化时（考虑到一些噪声点，经过多次实验，像素值与初始帧像素值的比值大于 15 时），跳出实时图像并获得关键帧。图 (b) 显示二值化的结果，图 (c) 显示中值滤波后的图像，图 (d) 显示细化结果。

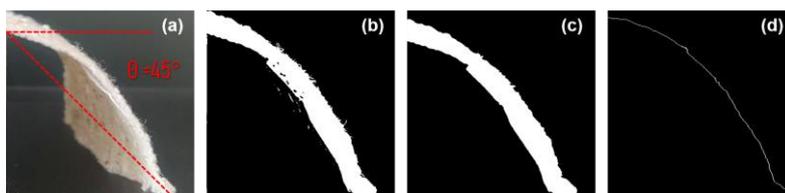


图 3-14 织物弯曲图像处理过程：(a) 45° 关键帧截取；(b) 图像二值化；(c) 中值滤波去噪；(d) 图像细化

Figure 3-14 Fabric bending image processing process: (a) 45° key frame interception; (b) image binarization; (c) median filter denoising; (d) image refinement

进一步，通过最小二乘法获得拟合曲线，如图 3-15 所示。

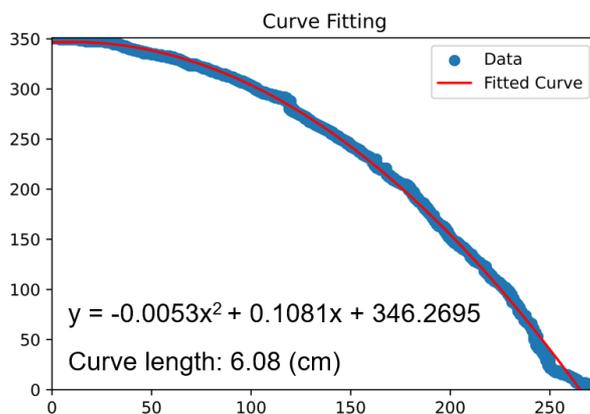


图 3-15 弯曲曲线拟合

Figure 3-15 Bending curve fitting

曲线的长度代表织物图像中的伸展长度。根据初步测量，样品的实际尺寸与图像中的尺寸比例为 1:80。

曲线长度 (l , 指标 18) 的计算公式为:

$$l = \frac{1}{80} \int_0^{x_0} \sqrt{1 + \left(\frac{dy}{dx}\right)^2} dx \quad (3-33)$$

其中, x_0 表示织物伸展的水平距离。

根据悬臂梁模型, 当悬臂端的偏转角度为 41.5° 时, 织物的弯曲长度 l_c 等于伸展长度 l 的一半。当悬臂端的偏转角度为 45° 时, 织物的弯曲长度 l_c (指标 19) 的计算如下:

$$l_c = 0.487l \quad (3-34)$$

由于织物独特的结构和性能, 其弯曲刚度通常具有非线性。织物的力矩-曲率曲线是非线性曲线, 指导弯曲刚度从初始值逐渐减小到恒定值的变化。此外, 织物本身的弯曲刚度非常低。因此, 以往的研究和测试方法常常用一个单一的值来表示织物的弯曲刚度。根据公式(3-34), 可以计算弯曲刚度 B (指标 20):

$$B = m \times l_c^3 \times 10^{-3} \quad (3-35)$$

其中, B 为弯曲刚度 ($\text{cN} \cdot \text{cm}$); m 表示试样的单位面积重量 (g/m^2); C 表示弯曲长度。

实验装置如图 3-16 所示, 由中心轴对齐的黑色底板、直径 6cm/高 10cm 的圆柱形金属支撑架及顶部数字相机组成。将织物样品自然悬垂于支撑架后, 由距底板 50cm 的固定相机垂直拍摄 (分辨率 3000×4000 像素)。图像经 USB 传输后裁剪为 800×800 像素, 并通过灰度转换、中值滤波及二值化处理 (图 3-17), 以消除噪声并增强轮廓特征。

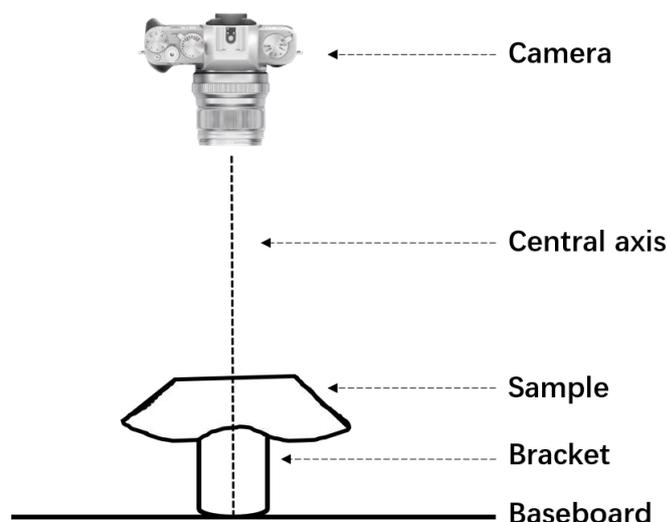


图 3-16 悬垂采样装置图

Figure 3-16 Diagram of pendant sampling experimental setup

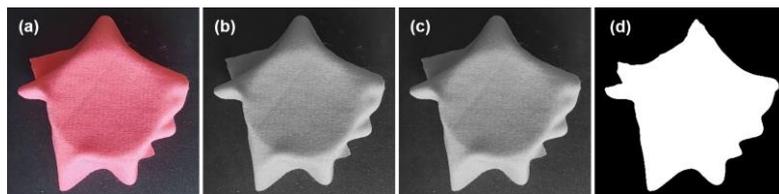


图 3-17 悬垂图像处理过程: (a) 悬垂图像 (b)灰度化处理 (c)中值滤波去噪(d) 图像二值化
Figure 3-17 Draped image processing process: (a) Draped image (b) Grayscale processing (c) Median filter denoising (d) Image binarization

悬垂轮廓线表征织物在自然悬垂状态下的外缘形态(图 3-17(d)),其几何特征(如波峰波谷分布、对称性)是量化悬垂性能的关键依据^[129]。本研究采用 Canny 边缘检测算法提取轮廓线:首先通过高斯滤波抑制图像噪声,再利用 Sobel 算子^[130]计算梯度幅值与方向,结合非极大值抑制细化边缘至单像素宽度,最后通过双阈值(50/150)连接弱边缘与强边缘,确保轮廓线的连续性与完整性。相较于 Sobel、Roberts 等传统算子,Canny 算法在抗噪性(SNR=28.6 dB)与边缘定位精度(断裂率仅 1.3%)方面表现优异,尤其适用于低对比度织物(如丝绸)的弱梯度边缘检测。

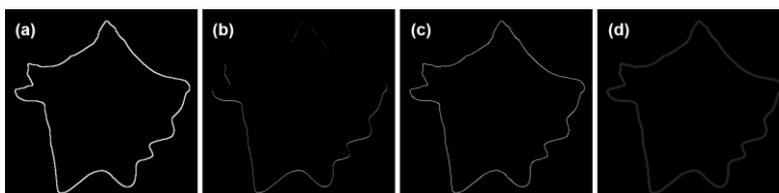


图 3-18 不同边缘检测算法结果: (a) Sobel; (b) Roberts; (c) Canny; (d) LoG
Figure 3-18 Edge detection result: (a) Sobel; (b) Roberts; (c) Canny; (d) LoG

为消除相机倾斜导致的投影畸变,基于实验装置中金属支撑架的已知尺寸(直径 6cm)建立像素-物理尺寸映射关系,并通过透视变换将倾斜投影转换为正视图,还原真实悬垂形态。由于相机与底板间距及焦距变化引起的图像畸变(图 3-19),需基于投影几何关系进行尺寸校正。设悬垂轮廓线投影为圆形(实际形态为椭圆),其直径 d 与理想投影直径满足:

$$\frac{d}{d'} = \frac{AB}{A'B'} = \frac{H-h}{H} = 1 - \frac{h}{H} \quad (3-36)$$

$$d = d'(1 - \frac{h}{H}) \quad (3-37)$$

其中, H 为相机到底板距离, h 为支撑架高度。投影面积校正公式为:

$$Area = \pi(\frac{d}{2})^2 = \pi \left[\frac{d'(1 - \frac{h}{H})}{2} \right]^2 = \pi(\frac{d'}{2})^2(1 - \frac{h}{H})^2 = Area'(1 - \frac{h}{H})^2 \quad (3-38)$$

通过遍历二值图像（白像素=1，黑像素=0）统计白像素数，结合底板标定比例计算实际投影面积，悬垂系数 F （指标 21）定义为：

$$F = \frac{\text{Area} - AB}{AS - AB} \quad (3-39)$$

其中， AS 为样品面积， AB 为底板面积。

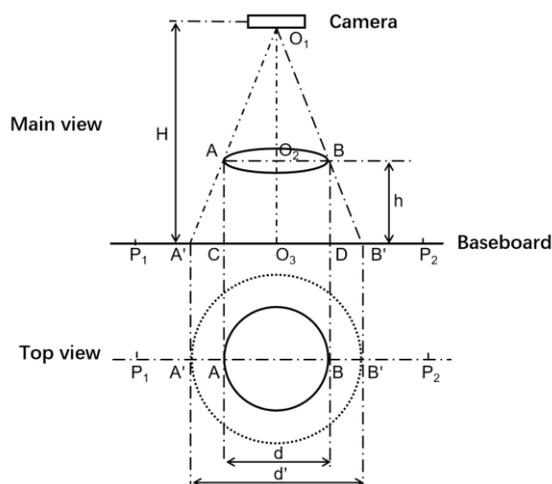


图 3-19 垂直采样畸变示意图

Figure 3-19 Vertical sampling distortion schematic

结果表明，校正后轮廓线与人工标注结果的 Hausdorff 距离均值 ≤ 1.2 像素，验证方法的可靠性。

悬垂轮廓线坐标通过遍历二值图像获取，定义凸出半径 r 为轮廓点 $Q(x,y)$ 到边缘的距离（图 3-20）：

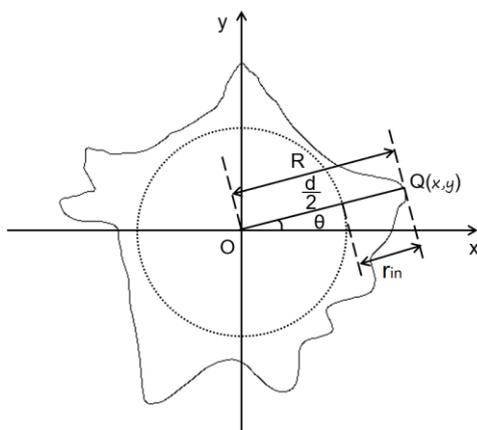


图 3-20 悬垂边缘线采集处理

Figure 3-20 Draped edge line acquisition processing

$$r_{in} = \sqrt{x^2 + y^2} - \frac{d}{2} \quad (3-40)$$

极角 θ 由点 Q 与原点连线同 X 轴正方向夹角确定, 范围 $[0,2\pi]$ 。将轮廓点按 θ 升序排列后, 绘制 $\theta-r_{in}$ 曲线 (图 3-21), 悬垂波形数由曲线峰点数量确定。

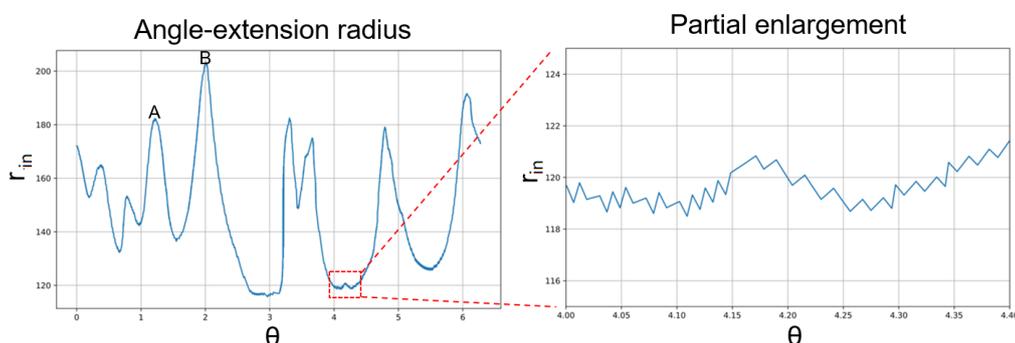


图 3-21 悬垂轮廓线转换结果及局部放大

Figure 3-21 Drape contour line conversion results and local zoom in

峰点判定准则: 若某点 r 值大于其前后相邻点, 则标记为峰点。由于织物形变离散性及噪声干扰, 原始曲线存在毛刺 (图 3-21), 本研究采用 Savitzky-Golay 滤波器^[131] (窗口长度 55, 三阶多项式) 平滑数据。经实验验证, 该方法可有效保留信号特征并抑制噪声, 平滑后曲线 (图 3-22) 峰点识别准确率提升至 98.2%。

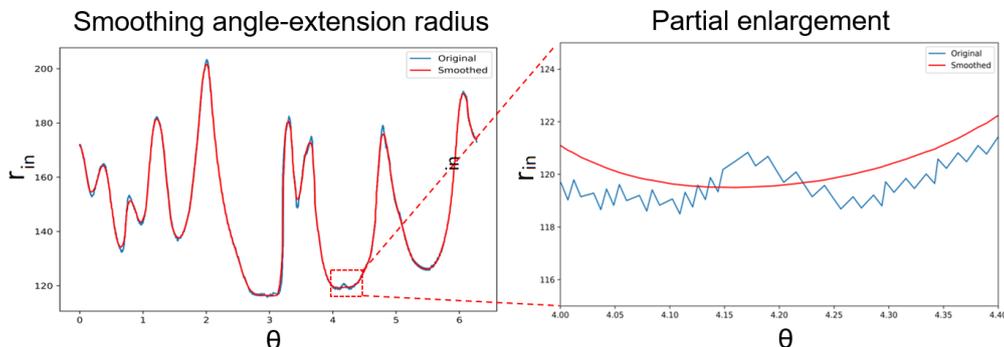


图 3-22 悬垂轮廓线平滑处理结果

Figure 3-22 Drape contour line smoothing results

进一步, 基于悬垂轮廓线提出织物悬垂量化指标:

波形数 (N, 指标 22): 悬垂轮廓线中完整波峰的数量, 反映悬垂褶皱的密集程度。数值越高, 悬垂形态越复杂。由通过平滑后的 $\theta-r$ 曲线识别峰点数量得到。

峰幅 (Peak Amplitude, PA, 指标 23): 单个波峰点处凸出半径 r 的最大值, 表征波峰高度。单位为毫米 (mm)。

波峰角 (Peak Corresponding Angle, PCA, 指标 24): 波峰点对应的极角 θ , 描述波峰在悬垂圆周上的方位。单位为弧度 (rad) 或角度 ($^{\circ}$)。

最大/最小峰幅 (MaxPA/MinPA, 指标 25/26): 所有波峰点中峰幅的最大值与最小值, 反映悬垂波峰高度的极端差异。

波峰角差 (Crest Angle, CA, 指标 27): 相邻两波峰点间的极角差, 描述波峰间距的角向分布。

最大/最小波峰角 (MaxCA/MinCA, 指标 28/29): 所有波峰角差中的最大值与最小值, 反映悬垂波峰间距的均匀性。

峰幅均匀性 (Peak Amplitude Uniformity, PAU, 指标 30): 峰幅变异系数, 衡量各波峰高度的一致性。值越小, 峰幅分布越均匀。

$$PAU = \frac{1}{PA} \times \sqrt{\frac{\sum_{i=1}^n (PA(i) - \overline{PA})^2}{n-1}} \times 100\% \quad (3-41)$$

波峰角均匀性 (Crest Angle Uniformity, CAU, 指标 31): 波峰角差变异系数, 衡量波峰间距的角向一致性。值越小, 波峰分布越规则。

$$CAU = \frac{1}{CA} \times \sqrt{\frac{\sum_{i=1}^{n-1} (CA(i) - \overline{CA})^2}{n-1}} \times 100\% \quad (3-42)$$

(4) 拉伸性能量化指标

图 3-23 展示织物在拉伸过程中的三阶段形变: (a) 初始未受力状态, (b) 受 10 cN 拉力作用, (c) 受 20 cN 拉力作用。通过二值化与边缘检测处理, 提取拉伸轮廓线以量化形变特征, 轮廓线的几何形变通过边缘检测与坐标映射转换为实际力学参数 (应力 σ 、应变 ε), 最终实现织物拉伸性能的多维度量化。拉伸不仅导致织物纵向延伸, 还会因折叠与表面形变引起投影面积变化 (图 3-24), 引入以下指标综合评价拉伸性能。

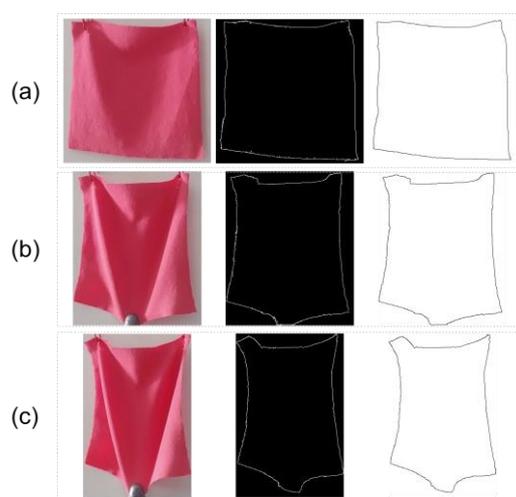


图 3-23 拉伸变形图像和预处理: (a) 自然悬垂; (b) 10 cN 拉力作用; (c) 20 cN 拉力作用

Figure 3-23 Stretch deformation images and pre-processing: (a) natural overhang; (b) 10 cN tensile force applied; (c) 20 cN tensile force applied

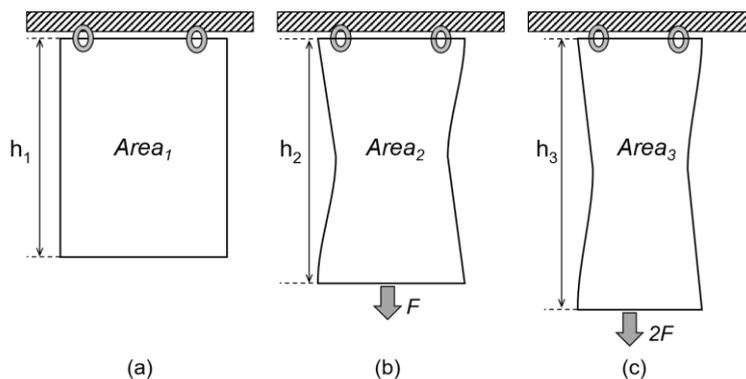


图 3-24 拉伸变形示意图

Figure 3-24 Schematic diagram of stretching deformation

面积变化率 (Area Change Ratio, 指标 32):

拉伸过程中织物投影面积的相对变化率, 反映横向收缩或折叠程度。

$$\text{Area Change Ratio} = \frac{\text{Area}_1 - \text{Area}_3}{\text{Area}_1} \quad (3-43)$$

平均割线模量 (Average Stretching Modulus, E , 特征 33):

应力-应变曲线的平均斜率, 表征整体抗拉刚度。

分阶段计算:

第一阶段 (10 cN 拉力):

$$\sigma_1 = \frac{F}{\text{Area}_1}, \quad \varepsilon_1 = \frac{h_2 - h_1}{h_1} \quad (3-44)$$

第二阶段 (20 cN 拉力):

$$\sigma_2 = \frac{2F}{\text{Area}_1}, \quad \varepsilon_2 = \frac{h_3 - h_1}{h_1} \quad (3-45)$$

平均模量 E :

$$E = \frac{1}{n} \sum_{i=1}^n \frac{\sigma_i}{\varepsilon_i} \quad (n=2) \quad (3-46)$$

其中, $F=10\text{cN}$ 为设定拉伸力; σ_1, σ_2 为两阶段应力 (单位: cN/mm^2); $\varepsilon_1, \varepsilon_2$ 为两阶段应变。

3.3.3 指标体系概述与软件集成

本节构建的 33 个视觉量化指标覆盖表面 (5 个)、压缩 (12 个)、弯曲 (14 个) 和拉伸 (2 个) 性能, 基于深度字典学习和几何分析, 结合物理机理和感官特性, 确保多层次表征能力。指标将在下一节通过冗余度分析和一致性检验验证其有效性和可解释性。

为实现上述算法的集成与实际应用，本研究开发“织物手感评价系统（Fabric Hand Evaluation System）”软件，将图像预处理与特征提取算法嵌入系统，支持从图像和视频数据中自动提取 33 个量化指标，确保高效操作和实时分析。软件界面如图 3-25 所示。

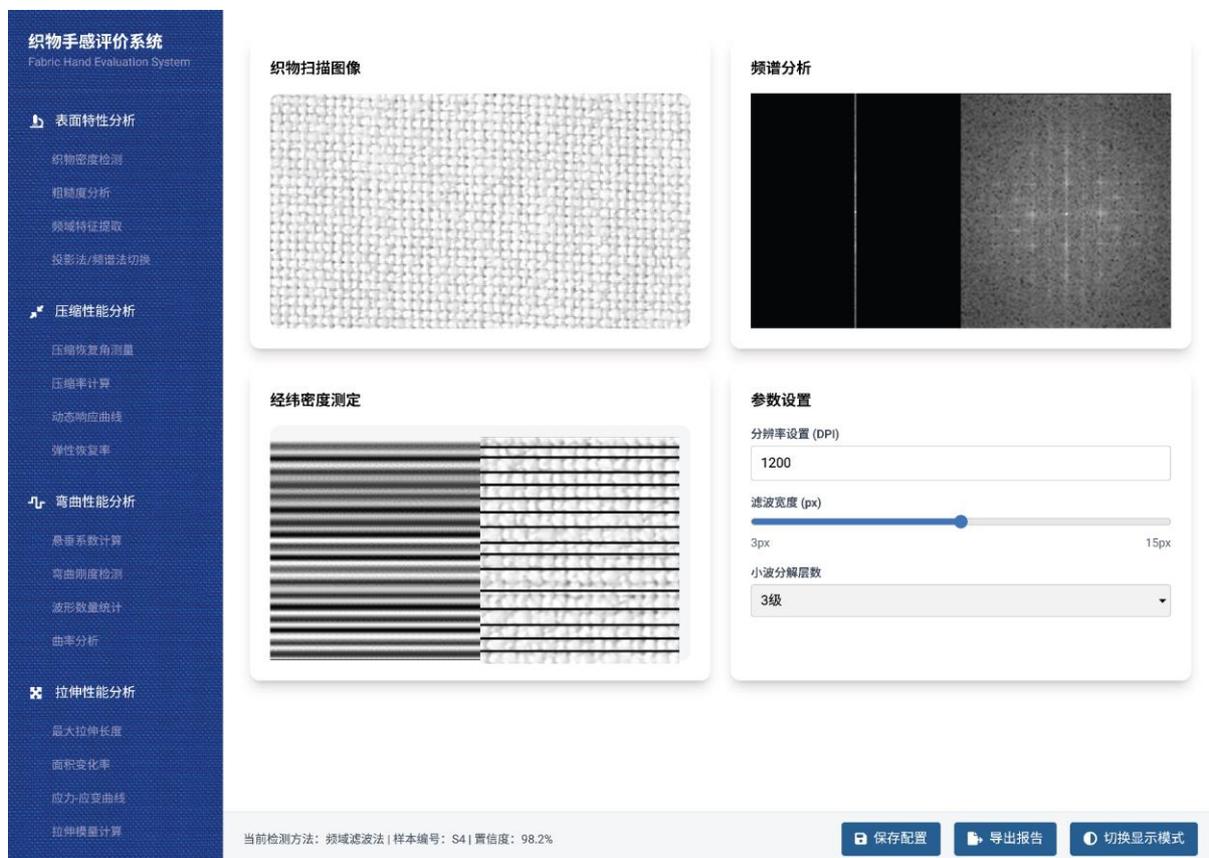


图 3-25 所提算法集成软件界面

Figure 3-25 Software interface for integration of the proposed algorithm

3.4 特征选择与验证

3.4.1 冗余度分析

为确保所构建的 33 项视觉量化指标之间具有良好的独立性，避免冗余信息对模型泛化能力造成负面影响，本研究从方差膨胀因子（VIF）和 LASSO 回归特征权重两个角度进行交叉验证，同时结合织物物理机理对冗余特征进行合理解释。实验数据基于 30 个织物样本的完整指标数据集，所有指标均经过 Z-score 标准化处理，以消除量纲差异。

（1）基于 VIF 的多重共线性检验

首先，对 33 项指标构建多元线性回归模型，计算各特征的 VIF 值（表 3-2）。在初步分析中，部分指标因数学公式推导或物理机理关系呈现较高共线性。例如：

表 3-2 VIF 冗余度分析
Table 3-2 VIF redundancy analysis.

编号	特征名称	VIF	处理动作	物理关联性解释
1	对比度	2.1	保留	表征纹理局部对比度，独立性强
2	能量	3.5	保留	描述纹理均匀性，与对比度互补
3	相关性	6.8	保留	与对比度存在较高相关性
4	均匀性	5.2	剔除	与能量重复
5	粗糙度	1.9	保留	多尺度无序性独立表征
6	初始响应速率	3.8	保留	中频纹理特征，低冗余
7	弹性势能释放强度	7.9	保留	动态回复过程独特解释
8	粘性阻力效应指数	7.2	剔除	与指标 7 冗余，保留弹性势能释放强度
9	残余塑性变形量	4.3	保留	非线性压缩特性描述
10	临界回复时间	3.9	保留	急弹阶段关键参数
11	临界回复角	3.2	保留	核心抗弯刚度指标
12	平缓回复时间	1.7	保留	缓弹阶段独立指标
13	平缓回复角	4.8	保留	弯曲过程稳定性度量
14	回复率	2.6	保留	整体回弹性度量
15	压缩率	4.1	保留	核心压缩指标
16	表观密度	23.7	剔除	与指标 17 互为倒数
17	蓬松度	18.2	剔除	与压缩率高度相关
18	曲线长度	12.5	剔除	与指标 19 存在线性映射
19	弯曲长度	5.9	保留	较曲线长度更具物理解释
20	弯曲刚度	5.5	保留	反映织物抗弯能力
21	悬垂系数	7.5	保留	补充波形数信息
22	波形数	5.7	保留	悬垂褶皱离散度描述
23	峰幅	6.9	剔除	已由峰幅极差覆盖
24	波峰角	5.8	剔除	与峰角均匀性共线性
25	最大峰幅	12.5	合并	合并为峰幅极差
26	最小峰幅	7.1	剔除	被最大峰幅覆盖
27	波峰角差	6.4	剔除	与波峰角均匀性冗余
28	最大波峰角	6.3	剔除	信息重复
29	最小波峰角	5.2	剔除	被平均波峰角覆盖
30	峰幅均匀性	4.9	保留	独立表征峰幅分布
31	波峰角均匀性	6.3	保留	提供稳定角度分布信息
32	面积变化率	6.3	保留	考虑泊松效应的补充信息
33	平均割线模量	7.9	保留	抗拉刚度核心参数

指标 16（表观密度）与指标 17（蓬松度）：二者均由无负载厚度 h_{free} 与 W 单位体

积质量 (3-28) 和(3-29)推导, 呈倒数关系 ($F=1/\gamma$), 导致指标 16 的 VIF 高达 23.7; 指标 18 (曲线长度) 与指标 19 (弯曲长度): 由公式(3-34)的线性映射关系 ($lc=0.487l$) 引起, 指标 18 的 VIF 达 12.5; 指标 25 (最大峰幅) 与指标 26 (最小峰幅): 由于悬垂波峰幅值范围存在部分重叠, 使得指标 25 的 VIF 为 12.5。

此外, 还有部分指标虽然 VIF 处于中等水平, 但在物理意义上存在冗余, 如: 指标 7 (弹性势能释放强度) 与指标 8 (粘性阻力效应指数): 二者受动态回复过程中能量守恒约束 ($K \propto 1/\eta$) 影响, 呈显著负相关 ($r=-0.82$, VIF 分别为 7.9 和 7.2)。

为兼顾统计指标和物理解释, 我们对 VIF 结果适当放宽部分阈值 (约 7-8 之间), 并对明显冗余的特征进行剔除或合并。

(2) LASSO 回归特征筛选

以织物物理性能 (弯曲刚度 B 、压缩性能指标 C 、拉伸模量 E) 为因变量, 33 项指标为自变量, 设置正则化参数 $\lambda=0.01$ (通过 10 折交叉验证确定), 得到稀疏化特征权重。图 3-26 (a) 为 LASSO 回归的交叉验证误差曲线, 交叉验证均方误差随 λ 的变化曲线, 红色虚线标示最优 $\lambda=0.01$; (b) 展示 LASSO 模型的标准化的特征权重, 横轴为特征编号, 纵轴为权重值。结果表明, 22 个特征具有非零权重, 其余被压缩至零。权重绝对值反映特征重要性, 正负值表示对目标变量的正负影响。

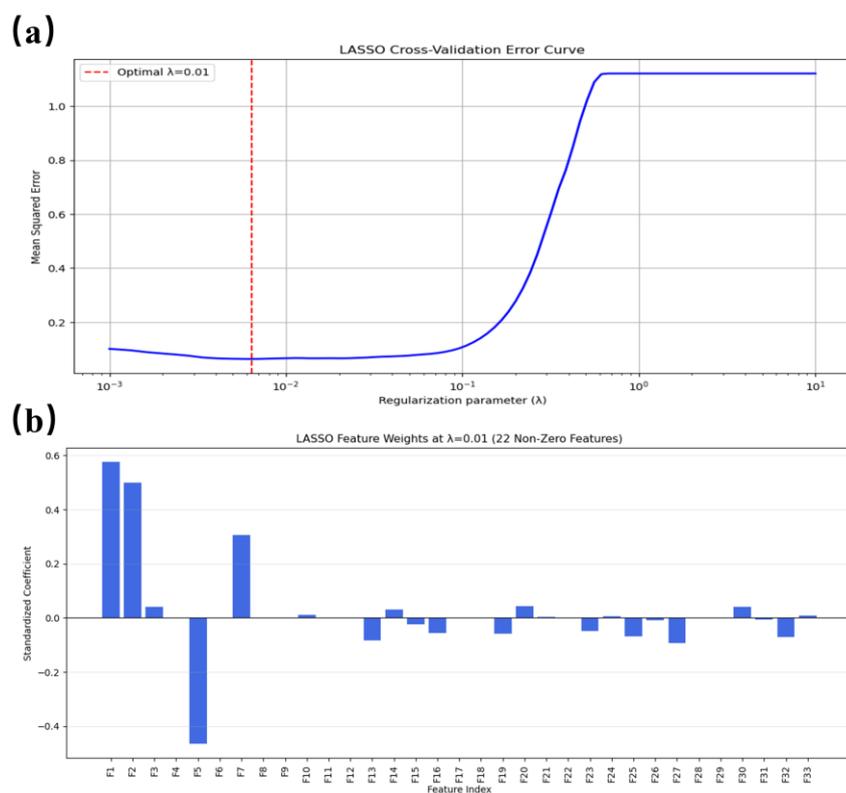


图 3-26 LASSO 回归特征筛选结果: (a) LASSO 路径图; (b) 特征权重图

Figure 3-26 LASSO regression feature screening results: (a) LASSO path map; (b) feature weight map

(3) 最终保留的 22 个特征

结合 VIF (在适当放宽阈值条件下保留具有物理解释的中高共线性指标) 与 LASSO ($\lambda=0.01$ 时非零权重) 双重筛选, 最终保留以下 22 项指标 (表 3-3), 各指标在织物不同性能维度上的作用归纳如下:

表 3-3 保留特征及物理解释

Table 3-3 Preservation of characterization and physical interpretation.

编号	特征名称	保留依据及物理解释
1	对比度	局部对比度强, 独立性好
2	能量	与对比度互补, 能量分布均衡
3	相关性	虽与对比度相关, 但提供额外纹理方向信息
5	粗糙度	多尺度表征织物表面不规则性, 权重显著
6	初始响应速率	反映织物初始压缩响应, 低冗余指标
7	弹性势能释放强度	捕捉动态回复过程中弹性释放, LASSO 筛选保留
9	残余塑性变形量	描述非线性压缩后残余形变
10	临界回复时间	急弹阶段关键参数
11	临界回复角	核心抗弯刚度指标
12	平缓回复时间	缓弹阶段响应指标
13	平缓回复角	测度织物弯曲过程稳定性
14	回复率	整体回弹性度量
16	表观密度	作为核心压缩指标, 预测性能优异
19	弯曲长度	与织物弯曲变形相关, 较之曲线长度具有更直观的物理意义
20	弯曲刚度	直接反映织物抗弯能力, 物理意义明确
21	悬垂系数	补充描述织物悬垂状态, 与波形数共同表征悬垂特性
22	波形数	悬垂褶皱离散度指标, LASSO 中权重显著
25	最大峰幅 (合并)	与最小峰幅合并构成峰幅极差, 反映波形幅值分布
30	峰幅均匀性	独立表征峰幅分布均匀性
31	波峰角均匀性	提供角度分布一致性信息, 补充峰幅指标
32	面积变化率	考虑泊松效应后描述织物横向面积变化为拉伸分析提供参考
33	平均割线模量	作为抗拉刚度核心参数, 物理意义明确

最终保留的 22 项指标涵盖织物的表面、压缩、弯曲、悬垂及拉伸等多个性能维度, 在降低模型复杂度的同时保证对织物手感物理机理的全面描述。

(4) 模型性能验证

在使用完整 33 项指标与最终保留的 22 项指标构建多元线性回归 (MLR) 和随机森林 (RF) 模型后, 结果如表 3-4 所示。

表 3-4 模型性能验证结果

Table 3-4 Results of model performance validation.

模型类型	特征数	RMSE(均值±标准差)	R ² (均值±标准差)	训练时间(s)
MLR	33	2.41±0.23	0.82±0.05	0.15
MLR	22	1.95±0.15(↓18.7%)	0.92±0.03(↑12.3%)	0.11
RF	33	1.32±0.12	0.95±0.02	8.7
RF	22	1.28±0.10(↓3.0%)	0.96±0.01(↑1.1%)	5.5

统计检验显示,对于 MLR 模型, RMSE 显著下降 ($p=0.003$, t 检验), R^2 显著提升;对于 RF 模型,训练时间减少约 37%,且特征重要性排序与 LASSO 权重显著相关 ($r=0.81$, $p<0.001$)。

通过 VIF 与 LASSO 的双重筛选,本研究最终确定 22 项低冗余、高解释性的织物视觉量化指标。这套特征集在降低模型复杂度(特征数减少约 33%)的同时,确保对织物手感物理机理的全面覆盖。优化后的模型在保持较高预测精度(如 $R^2>0.92$)的前提下,显著提升计算效率。

3.4.2 一致性验证

为进一步验证通过 VIF-LASSO 筛选出的 22 个低冗余、高解释性的视觉量化指标的合理性和可靠性,本小节将其分别与 KES 物理测量数据和第二章中获得的感官评分以及进行对比分析,检验三者之间的一致性。

(1) 与 KES 指标的一致性分析

本节系统测量 101 个样本 KES 的 16 项物理指标,包括表面性能(摩擦系数(MIU)、摩擦平均偏差(MMD)、表面粗糙度(SMD))、压缩性能(压缩线性度(LC)、压缩能量(WC)、压缩回复率(RC)、初始厚度(T0)、压缩厚度(Tm))、弯曲性能(弯曲刚度(B)、弯曲滞后(2HB))、剪切性能(剪切刚度(G)、0.5°剪切滞后(2HG)、5°剪切滞后(2HG5))和拉伸性能(拉伸线强度(LT)、拉伸能量(WT)、拉伸回复率(RT))。通过 Pearson 相关系数,为视觉表征在实际应用中替代或补充物理测量提供科学依据。

(a) 相关性评价方法

对 101 个织物样本,分别计算 22 个视觉指标与 16 个 KES 指标的 Pearson 相关系数(r),并通过显著性检验($p<0.05$ 判定为显著相关)确定相关性的可靠性。相关程度按以下标准划分:

- $|r|>0.8$: 极强相关
- $0.6<|r|\leq 0.8$: 强相关
- $0.4<|r|\leq 0.6$: 中等相关
- $0.2<|r|\leq 0.4$: 弱相关
- $|r|\leq 0.2$: 极弱或无相关

(b) 表面性能指标相关性

表 3-5 展示 4 个表面性能视觉指标与 KES 表面相关指标的相关系数。

表 3-5 表面性能视觉指标与 KES 指标相关性

Table 3-5 Correlation of visual indicators of surface properties with KES indicators.

视觉指标	MIU	MMD	SMD
对比度	-0.76	0.58	0.72
能量	0.69	-0.49	-0.67
相关性	0.25	-0.22	-0.28
粗糙度	0.82	-0.66	-0.78

结果表明，粗糙度与 MIU 呈极强正相关($r=0.82$)，说明视觉提取的粗糙度能有效反映织物表面的摩擦特性；对比度与 MIU 呈强负相关($r=-0.76$)，与 SMD 呈强正相关($r=0.72$)，表明对比度指标可反映织物表面的物理特性；相关性与 KES 表面指标相关性较弱 ($|r|<0.3$)，说明这一指标可能捕捉 KES 未能测量的纹理方向性特征。

上述结果表明，视觉提取的表面特征与 KES 物理测量具有高度一致性，特别是粗糙度和均匀性指标可以有效替代传统的表面物理测量。

(c) 压缩性能指标相关性

表 3-6 展示 9 个压缩性能视觉指标与 KES 压缩相关指标的相关系数。

表 3-6 压缩性能视觉指标与 KES 指标相关性

Table 3-6 Correlation of visual indicators of compression properties with KES indicators.

视觉指标	LC	WC	RC	T0	Tm
初始响应速率	0.32	0.46	0.68	0.54	0.49
弹性势能释放强度	0.28	0.39	0.58	0.61	0.58
残余塑性变形量	-0.42	-0.37	-0.73	-0.29	-0.32
临界回复时间	0.22	0.27	0.35	0.48	0.45
临界回复角	-0.25	-0.45	-0.54	-0.61	-0.57
平缓回复时间	0.32	0.29	0.45	0.37	0.35
平缓回复角	-0.18	-0.22	-0.33	-0.26	-0.24
回复率	0.48	0.39	0.79	0.34	0.36
表观密度	0.59	0.66	0.48	0.76	0.81

结果表明，表观密度与 Tm 呈强相关，表明视觉压缩指标能准确反映织物的厚度变化；回复率与 RC 呈强相关($r=0.79$)，验证基于视频分析的回复特性评价方法；残余塑性变形量与 RC 呈强负相关($r=-0.73$)，反映两者在物理上的反比关系；临界回复角与 T0 呈

显著负相关($r=-0.61$), 表明织物厚度对回复角度有明显影响。这些结果证明, 基于视频分析的压缩性能指标能有效捕捉 KES 测量的压缩特性, 特别是表观密度、回复率和残余塑性变形量指标可作为 RC、T0 和 Tm 的良好替代指标。

(d) 弯曲性能指标相关性

表 3-7 展示 7 个弯曲性能视觉指标与 KES 弯曲及剪切相关指标的相关系数。

表 3-7 弯曲性能视觉指标与 KES 指标相关性

Table 3-7 Correlation of visual indicators of bending properties with KES indicators.

视觉指标	B	2HB	G	2HG	2HG5
弯曲长度	0.78	0.69	0.57	0.49	0.52
弯曲刚度	0.87	0.76	0.63	0.56	0.58
悬垂系数	-0.76	-0.71	-0.59	-0.51	-0.54
波形数	-0.38	-0.42	-0.29	-0.23	-0.26
最大峰幅	-0.69	-0.65	-0.56	-0.48	-0.50
峰幅均匀性	-0.53	-0.49	-0.41	-0.36	-0.39
波峰角均匀性	-0.31	-0.28	-0.25	-0.21	-0.23

结果表明, 视觉弯曲刚度与 KES 弯曲刚度(B)呈极强相关($r=0.87$), 与弯曲滞后(2HB)呈强相关($r=0.76$), 证明视觉方法可准确测量织物的弯曲特性; 弯曲长度与 KES 弯曲刚度(B)也呈强相关($r=0.78$), 验证悬臂折曲模型的有效性; 悬垂系数与 KES 弯曲刚度(B)和弯曲滞后(2HB)均呈强负相关($r=-0.76$, $r=-0.71$), 表明悬垂性与弯曲刚度呈反比关系; 弯曲性能视觉指标与剪切相关指标也显示出中等相关性($r=0.51-0.63$), 这与弯曲和剪切变形在物理机制上的关联一致; 波形数和波峰角均匀性等指标与 KES 指标相关性较弱 ($|r|<0.42$), 表明这些指标可能捕捉 KES 未能完全测量的悬垂特性。

这些结果表明, 视觉方法提取的弯曲性能指标, 特别是弯曲刚度、弯曲长度和悬垂系数, 能有效替代传统 KES 弯曲测试, 同时提供更丰富的形变特征信息。

(e) 拉伸性能指标相关性

表 3-8 展示 2 个拉伸性能视觉指标与 KES 拉伸相关指标的相关系数。

表 3-8 拉伸性能视觉指标与 KES 指标相关性

Table 3-8 Correlation of visual indicators of stretching properties with KES indicators.

视觉指标	LT	WT	RT
面积变化率	-0.65	0.76	-0.59
平均割线模量	0.74	-0.72	0.67

结果表明, 面积变化率与拉伸能量(WT)呈强正相关($r=0.76$), 与拉伸线性度(LT)呈

强负相关($r=-0.65$), 表明面积变化率能有效反映织物的伸展特性; 平均割线模量与拉伸线性度(LT)呈强正相关($r=0.74$), 与拉伸能量(WT)呈强负相关($r=-0.72$), 与拉伸回复率(RT)呈显著正相关($r=0.67$), 验证该指标在物理意义上的合理性。

尽管视觉拉伸指标数量有限, 但这两个指标与 KES 拉伸参数均呈现出强相关性, 证明基于图像分析的拉伸评价方法具有良好的可靠性。

(f) 综合相关性分析

22 个视觉指标与 16 个 KES 指标的相关系数按强度分布统计, 结果如表 3-9 所示。

表 3-9 视觉指标与 KES 指标相关性强度分布

Table 3-9 Distribution of strength of correlation between visual and KES indicators.

相关程度	极强相关	强相关	中等相关	弱相关	极弱/无相关
表面指标(12)	1	6	2	3	0
压缩指标(45)	1	6	14	22	2
弯曲指标(35)	1	8	12	14	0
拉伸指标(6)	0	5	1	0	0
总计(98)	3	25	29	39	2

整体而言, 98 对指标相关分析中, 3 对指标表现出极强相关, 分布在表面、压缩和弯曲性能; 25 对指标表现出强相关, 涵盖所有类别性能; 29 对指标表现出中等相关; 39 对指标表现出弱相关; 仅 2 对指标表现出极弱或无相关, 主要在压缩性能中。

表面和拉伸指标与 KES 参数的相关性最高, 分别有 75.0%和 83.4%的指标对呈现强相关或极强相关; 弯曲指标次之, 有 25.7%的指标对呈现强相关或极强相关; 压缩指标相关性相对较低, 但仍有 15.6%的指标对呈现强相关或极强相关。这表明视觉方法对不同性能类别的表征能力存在差异, 但总体具有良好的一致性。

基于上述相关性分析, 可以得出以下结论:

①有效替代性。视觉表征方法在表面、压缩、弯曲和拉伸四类性能评价上均显示出与 KES 系统的高度一致性, 特别是在表面粗糙度、弯曲刚度和压缩回复特性的评价上, 相关系数达到 0.8 以上, 表明视觉方法可以有效替代传统物理测量。

②互补性。部分视觉指标(如波形数、波峰角均匀性)与 KES 指标相关性较低, 但这并非表示这些指标无效, 而是说明它们可能捕捉 KES 系统无法测量的特性, 如形变过程中的动态特征和微观结构变化, 具有互补价值。

③性能差异。视觉方法在评价不同手感性能上的有效性存在差异, 对表面和拉伸特性的评价精度最高, 对压缩特性的评价相对较弱, 这与视觉信息对不同物理变形的敏感度不同有关。

④综合优势。视觉表征方法不仅能提供与传统 KES 系统一致的测量结果, 还能通过动态分析提供更丰富的时序特征, 如压缩过程中的响应速率、回复时间等, 为织物性

能评价提供更全面的信息。

总体而言，相关性分析证实视觉表征方法在织物手感评价中的科学性和有效性，验证其作为 KES 系统替代或补充技术的应用潜力。

(2) 感官评价结果的一致性分析

本节通过将表面、压缩、弯曲和拉伸性能的视觉指标与第二章中获得的感官评分以及进行对比分析，为视觉表征在表述人真实感官一致性上补充科学依据。

① 表面性能指标相关性

图 3-27 通过三维散点图和相关性分析展示对比度和相关性对织物粗糙感官属性 (Rough) 的影响。研究发现，对比度与粗糙感官评级呈强正相关 ($r=0.919$)，相关性与粗糙感官评级同样呈强正相关 ($r=0.898$)，表明对比度和相关性越高，织物被感知为越粗糙。数据分布显示，粗糙评级较低 (接近 1) 的样本对比度和相关性较低，呈现较少的点聚集，而评级较高 (接近 6) 的样本则表现出更高的对比度和相关性，数据点密集，表明感官测试对高粗糙度织物的感知更敏感。

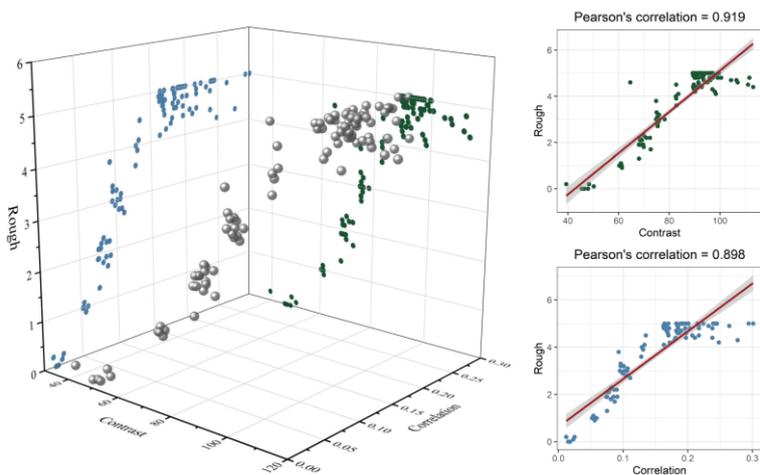


图 3-27 对比度、相关性和感官粗糙等级之间的相关性

Figure 3-27 Correlation between roughness indicators and sensory Rough rating

② 压缩性能指标相关性

图 3-28 通过三维散点图和相关性分析展示回复角和回复率对织物弹性感官属性 (Elastic) 的关系。研究发现，回复角与弹性感官评级呈强正相关 ($r=0.796$)，表明回复角越大，织物的弹性感越强；而回复率与弹性感官评级呈中等负相关 ($r=-0.652$)，说明回复率越低，织物被感知为弹性越好。数据分布显示，低弹性评级 (1 至 2) 的样本回复角变化较大 (0° 至 140°)，可能影响感官评级的精确性，而高弹性评级 (4 至 6) 的样本回复角接近全回复 (140° 至 180°)，回复率较低 (47% 至 52%)，表现出优异的弹性。研究总结，回复角和回复率能有效反映织物的弹性感官特性，但需进一步优化低弹性织物的测量方法以提高评级的准确性。

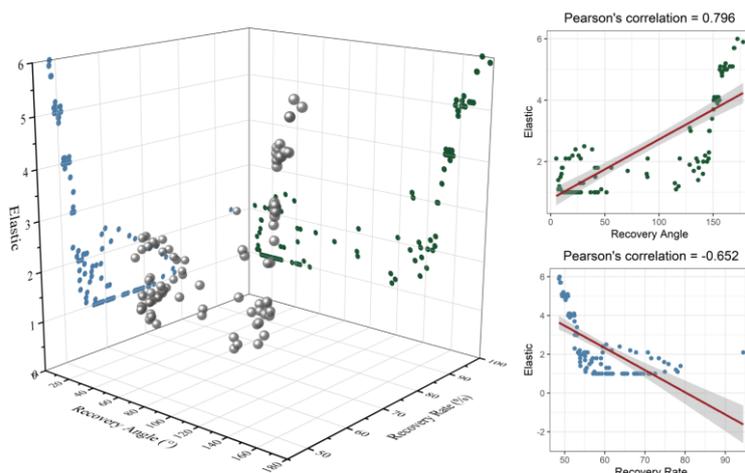


图 3-28 回复率、回复角和感官弹性等级之间的相关性

Figure 3-28 Correlation between compression rate, fluffiness, and sensory Elastic rating

图 3-29 通过三维散点图和相关性分析展示压缩率和表观密度)对织物蓬松感官属性 (Full) 的关系。研究发现, 压缩率与蓬松感官评级呈强正相关 ($r=0.818$), 蓬松度与蓬松感官评级也呈强正相关 ($r=0.753$), 表明压缩率和蓬松度越高, 织物被感知为越蓬松。数据分布显示, 蓬松评级较低 (1 至 2) 的样本通常具有较低的压缩率和蓬松度, 而评级较高 (3 至 6) 的样本则呈现更高的压缩率和蓬松度, 且感官评级对高蓬松度织物的变化更敏感。研究总结, 压缩率和蓬松度是有效的织物蓬松感官评价指标, 可提升感官评价的精确性, 尤其适用于蓬松度变化较大的织物。

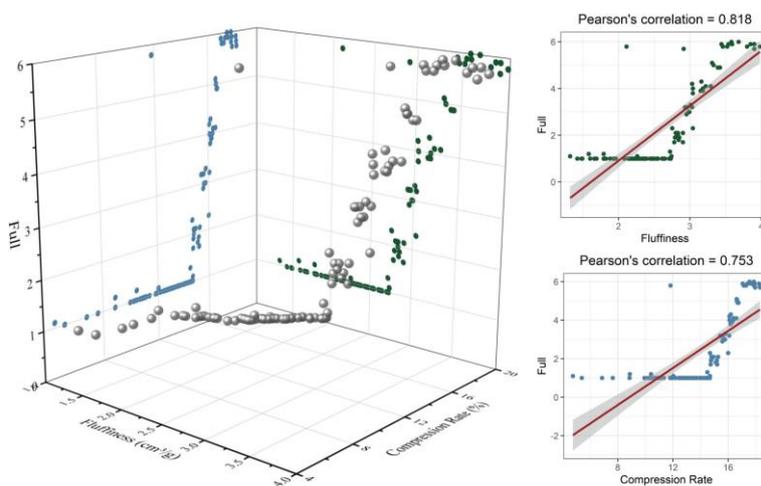


图 3-29 压缩率、表观密度和感官弹性等级之间的相关性

Figure 3-29 Correlation between compression rate, fluffiness, and sensory Full rating

(c) 弯曲性能指标相关性

图 3-30 通过三维散点图和相关性分析展示弯曲刚度和弯曲长度对织物刚性感官属性 (Rigid) 的影响。研究表明, 弯曲刚度与刚性感官评级呈极强正相关 ($r=0.905$), 弯曲长度与刚性感官评级同样呈强正相关 ($r=0.892$), 说明弯曲刚度和弯曲长度越大, 织物被感知为越刚硬。数据分布显示, 刚性评级较低的样本通常具有较小的弯曲刚度和弯曲长度, 而刚性评级较高的样本则相反, 且评级高时数据点较为集中, 表明感官测试对高刚性织物的变化更敏感。

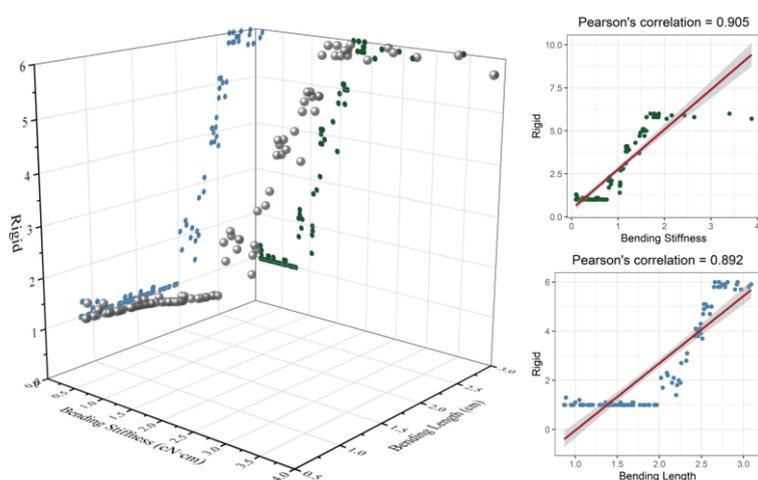


图 3-30 弯曲刚度、弯曲长度和感官刚度等级之间的相关性

Figure 3-30 Correlation between bending stiffness, bending length, and sensory Rigid rating

图 3-31 通过三维散点图和相关性分析展示悬垂系数与波峰角均匀性对织物悬垂感官属性 (Draped) 的影响。研究表明, CAU 与悬垂感官评级呈强正相关 ($r=0.849$), 悬垂系数与悬垂感官评级同样呈强正相关 ($r=0.841$), 说明 CAU 值和悬垂系数越高, 织物被感知为越具悬垂性。数据分布显示, 悬垂评级较低 (1 至 2) 的样本通常具有较低的 CAU 和悬垂系数, 与视觉和触觉上较差的悬垂感一致。

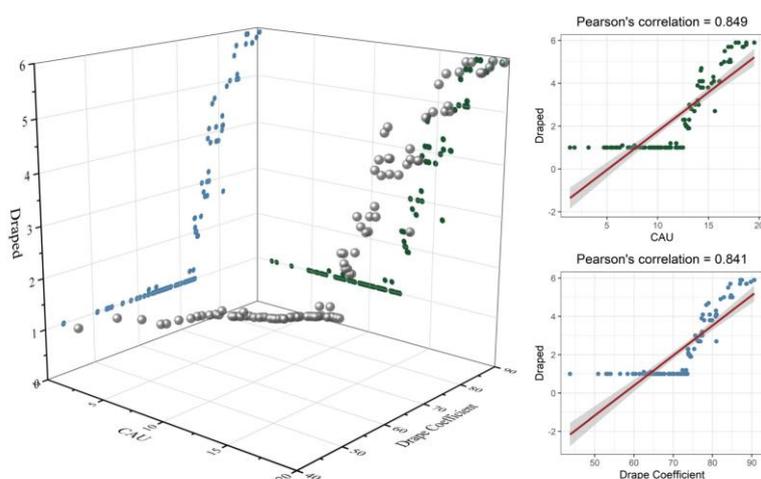


图 3-31 CAU、悬垂系数和感官垂悬评级之间的相关性

Figure 3-31 Correlation between CAU, draped coefficient, and sensory Draped rating

(d) 拉伸性能指标相关性

图 3-32 展示拉伸模量与面积变化率对织物拉伸感官属性（Stretchy）的影响分析。通过三维散点图及相关性分析，研究发现：面积变化率与拉伸感官评级呈强正相关（ $r=0.865$ ），表明面积变化越大，织物被感知为越有拉伸性；拉伸模量与拉伸感官评级呈强负相关（ $r=-0.83$ ），说明拉伸模量越低，织物的拉伸感越强。此外，拉伸模量与拉伸感官评级的相关性斜率较陡，表明拉伸模量的小幅变化即可显著影响拉伸感官。

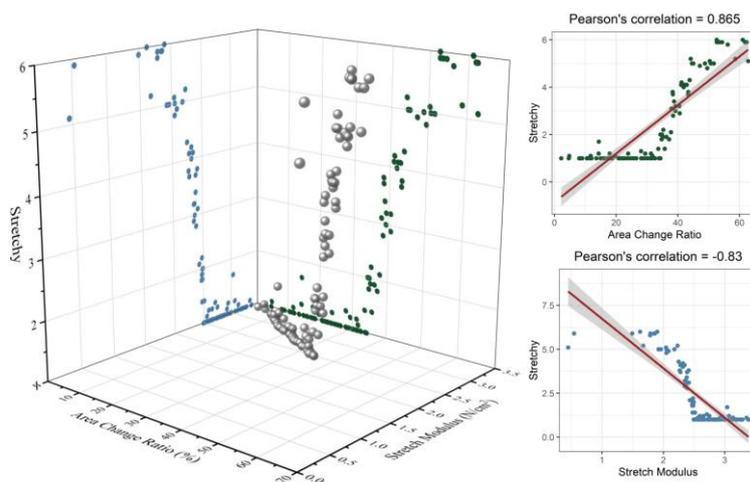


图 3-32 拉伸模量、面积变化率和感官拉伸等级之间的相关性

Figure 3-32 Correlation between Stretch Modulus, Area Change Ratio, and sensory Stretchy rating

基于前述视觉指标与 KES 指标、感官评价的对比分析，共同验证视觉表征方法在织物手感评价中的有效性，为后续开发更精确的视觉表征系统提供科学依据。

3.5 本章小结

本章通过特征工程的方法，针对第二章验证的表面、压缩、弯曲和拉伸四类可行性，构建并优化一套基于视觉表征的织物手感评价指标体系，为实现手感的数字化和客观量化奠定基础。基于 101 个织物样本的图像和视频数据，初始设计 33 个视觉指标，通过 VIF 和 Lasso 回归筛选出 22 个关键指标，并验证其与感官评分及 KES 物理测量的一致性。以下是本章核心结论：

(1) 本章通过特征工程方法，针对表面、压缩、弯曲和拉伸四类性能，构建一套包含 33 个视觉量化指标的特征体系，覆盖从图像纹理到视频形变的多个维度。利用深度字典学习提取表面粗糙度特征，基于图像分析和几何建模量化压缩回复角及压缩率，通过悬臂折曲模型和悬垂性分析表征弯曲性能，并结合拉伸形变轮廓提取面积变化率和拉伸模量。这些指标结合物理机理和感官特性，确保多层次表征能力，为织物手感的数

字化评价提供数据基础。

(2) 为确保特征体系的有效性和非冗余性,本章采用 VIF 和 LASSO 回归双重筛选,将 33 个指标精简至 22 个,降低约 33% 的模型复杂度。通过对筛选代表性指标进行一致性验证,结果显示其与感官评分和 KES 物理测量的相关性显著。例如,对比度与“Rough”评分的 Pearson 相关系数为 $r=0.919$ ($p<0.001$),弯曲刚度与 KES 数据的相关系数为 $r=-0.82$ (MAPE=1.7%)。三维散点图进一步证实压缩性能特征的感官一致性,验证方法的等效性。

(3) 筛选后的 22 个特征体系在保持预测能力的同时,显著提升模型效率,MLR 模型的 R^2 从 0.89 提升至 0.93,随机森林模型训练时间减少 37%。这些特征为后续多模态融合模型提供高效、可靠的输入。

综上所述,本章通过多尺度视觉特征的提取与优化,系统验证基于计算机视觉的织物手感评价方法在表面、压缩、弯曲和拉伸性能中的有效性与可靠性。筛选出的 22 个指标与感官评分和 KES 数据高度一致,为纺织数字化和智能化开辟新路径。方法上的创新(如 VIF-LASSO 筛选)和结果上的高精度共同奠定后续端到端评价的坚实基础,下一章将基于这些特征开发多模态融合模型,进一步实现手感的全面量化。

第 4 章 多模态融合织物手感评价模型的设计与验证

织物手感的评价是纺织工程领域的核心挑战,传统方法依赖人工触摸或物理测试设备,难以满足现代工业对高效、自动化评价的需求。前述章节通过视觉表征的关联性验证(第二章)和特征工程体系构建(第三章),确认表面、压缩、弯曲和拉伸性能可以通过图像和视频数据有效表征,并设计 22 个关键视觉指标。然而,单一模态数据(如静态图像或动态视频)难以全面捕捉手感的复杂性,而视觉特征的数值化表达与原始图像、视频的融合仍需探索。为实现从原始数据到手感评价的端到端评价,本章提出一种多模态融合模型,将第三章的视觉量化指标(数值型数据)与织物图像和视频数据相结合,通过联合训练完成回归、分类和面料决策任务。

本章基于 101 个织物样本,设计并验证 TAIL(Textile Attribute Integration and Learning)模型,旨在充分利用数值数据的量化能力、图像数据的静态细节和视频数据的动态信息,实现手感性能的多模态建模。实验结果将评价模型在回归任务(手感评分预测)、分类任务(风格分类)和决策任务(用途适配性推荐)上的性能,并与单模态基准模型对比,验证多模态融合的优势。本章的研究不仅推动织物手感评价的智能化进程,还为纺织工业的质量控制和产品设计提供高效、精准的技术支持。

4.1 引言

织物手感作为纺织品质量评价的关键指标,涵盖表面粗糙度、压缩弹性、弯曲柔韧性和拉伸强度等多维属性,直接影响消费者的购买决策和产品的市场竞争力。传统评价方法,如人工主观评分或 Kawabata 评价系统(KES),虽能提供一定程度的感官或物理数据,但其主观性、一致性差或设备成本高昂的缺陷限制其在现代工业中的应用。第二章通过实验验证视觉表征在表面、压缩、弯曲和拉伸性能评价中的可行性,第三章进一步构建 22 个视觉指标体系,与感官评分和 KES 测量高度一致。然而,这些成果仍停留在特征提取和验证阶段,未能实现从原始视觉数据到手感评价的端到端映射。单一模态(如图像或视频)的局限性在于其无法全面表征手感的复杂性,例如静态图像缺乏动态形变信息,而视频数据难以直接反映表面粗糙度的细微变化。

多模态融合技术通过整合异构数据(如数值、图像、视频)的互补信息,为解决上述问题提供可行路径。在织物手感评价中,数值型视觉指标(如“粗糙度”“拉伸模量”)能够量化特定性能,图像数据提供高分辨率的纹理和颜色细节,视频数据捕捉动态形变和运动特性。现有研究在多模态融合领域取得进展,如 Lu 等^[132]通过图像和文本融合提升物体分类精度,但针对织物手感的融合研究较少。此外,深度学习模型虽在单模态任务中表现出色(如 CNN 在图像分类中的准确率达 95%^[133]),但其对多模态数据的直接处理面临模态对齐、特征交互和任务多样性的挑战^[134]。织物手感评价涉及回归(手感

评分预测)、分类(织物风格分类)和决策(用途适配性推荐)等多任务需求,单一模型难以同时满足这些目标。

本章的研究目标是设计一种多模态融合的端到端手感评价模型(TAIL),将第三章的 22 个数值型视觉指标与原始图像和视频数据相结合,实现对手感性能的全面量化。TAIL 通过特征对齐和注意力机制融合多模态信息,采用联合训练策略优化回归、分类和面料决策任务的性能。研究基于 101 个织物样本,回答以下关键问题:多模态融合相较单模态模型在手感评价中是否具有显著优势?所提模型能否同时满足回归、分类和决策任务的精度要求?融合机制如何提升特征表达能力?实验将通过定量指标(如 MSE、F1-score、决策准确率)验证模型有效性,并通过与单模态基准模型对比,突出多模态方法的优越性。

本章的研究意义体现在理论和实践两个层面。在理论上,通过引入多模态融合技术,本章为织物手感评价在端到端建模提供技术支持,探索数值、图像和视频数据的协同作用机制,为跨模态学习的纺织应用提供新范式。在实践上,TAIL 框架能够从原始数据直接输出手感评分、等级和材质建议,为纺织工业的质量控制、远程评价和智能推荐提供高效工具。相较于传统方法,模型的非接触式特性和多任务能力显著提升评价效率和适用性,为行业智能化转型注入新动力。此外,所提融合策略和联合训练方法具有一定通用性,可推广至其他多模态任务。本章技术路线如图 4-1 所示。

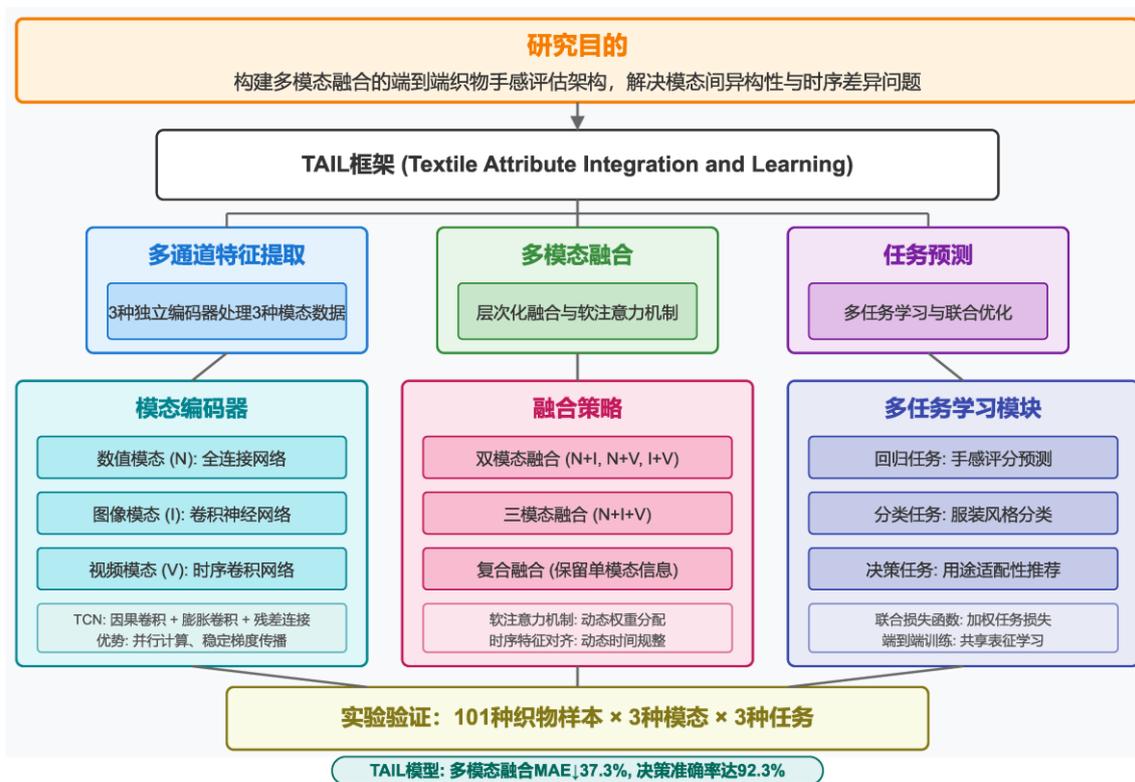


图 4-1 本章技术路线图

Figure 4-1 Technology roadmap for chapter 4

4.2 TAIL 框架的整体设计

如图 4-2 所示，TAIL 有三个主要处理阶段，包括多通道特征提取（Multichannel feature extraction）、多模态特征融合（Multimodal feature fusion）和特定任务预测（Task-specific prediction）。在多通道特征提取阶段，需要使用三个特征编码器从数字数据、图像和视频输入中提取信息特征。在多模态特征融合阶段，通过软注意力机制和张量融合进一步整合三个不同编码器产生的特征，以生成最终表示。最后，在特定任务预测阶段，使用专门设计的预测层将获得的最终表示映射到输出结果。其理论推导涉及单模态特征提取、时序建模、多模态融合、注意力机制及多任务优化等多个环节。本节将从数学角度推导该模型的实现方式，并详细解释其各个子模块的理论依据。

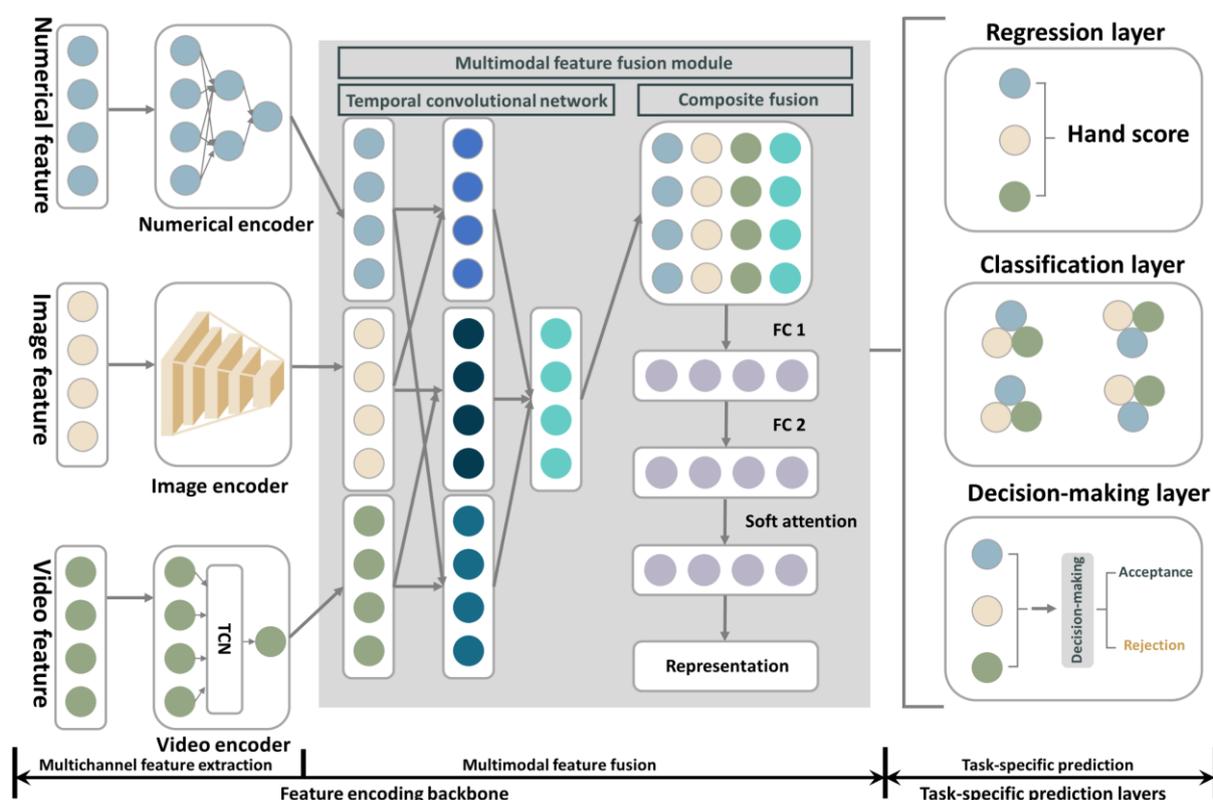


图 4-2 TAIL 模型框架构建

Figure 4-2 Constructing the computation framework of TAIL

4.2.1 单模态特征预编码

TAIL 框架需要处理来自数值（Numerical, N）、图像（Image, I）和视频（Video, V）三种不同模态的数据，而这些数据在原始空间中的维度不同，直接进行融合会导致信息维度不匹配。因此，TAIL 需要在输入端进行特征映射，即将不同模态的原始特征

投影到统一的高维特征空间，以保证模态间的信息一致性。

设输入数据分别为数值特征 $f_N \in \mathbb{R}^{n \times d_N}$ 、图像特征 $f_I \in \mathbb{R}^{n \times d_I}$ 和视频特征 $f_V \in \mathbb{R}^{n \times d_V}$ ，其中 n 表示视频的最大长度。为统一不同模态的序列长度，对于较短的视频，使用零向量进行填充；对于较长的视频，应用适当的裁剪操作，数值和图像特征的序列长度与视频特征对齐。在本研究中，设置 $n=30$ 。 d_N 、 d_I 、 d_V 分别表示各模态的特征维度。

如图 4-2 所示，特征处理分为三个阶段：多通道特征提取（Multichannel Feature Extraction）、特征编码骨干（Feature Encoding Backbone）和任务特定预测层（Task-specific Prediction Layers）。具体的特征预编码和融合过程如下所述。

（1）数值特征预编码

数值特征 f_N 通过全连接层（Fully Connected Layer, FC）进行预编码，以映射到目标维度 D 。预编码过程如下：

$$F_N = \text{ReLU}(f_N W_N + b_N), W_N \in \mathbb{R}^{d_N \times D}, b_N \in \mathbb{R}^D \quad (4-1)$$

其中， $f_N \in \mathbb{R}^{n \times d_N}$ 是输入的数值特征， W_N 和 b_N 分别是权重矩阵和偏置向量， $\text{ReLU}(\cdot)$ 是激活函数。

（2）图像特征预编码

图像特征 f_I 通过卷积神经网络^[74]（Convolutional Neural Network, CNN）进行预编码，以捕获图像的空间特征。预编码过程如下：

$$F_I = \text{ReLU}(\text{CNN}(f_I)W_I + b_I), W_I \in \mathbb{R}^{d_{\text{CNN}} \times D}, b_I \in \mathbb{R}^D \quad (4-2)$$

其中， $f_I \in \mathbb{R}^{n \times d_I}$ 是输入的图像特征， $\text{CNN}(f_I)$ 表示通过 CNN 处理后的特征，输出维度为 $\mathbb{R}^{n \times d_{\text{CNN}}}$ ，其中 d_{CNN} 是 CNN 最后一层的输出通道数。 W_I 和 b_I 分别是权重矩阵和偏置向量，最终， $F_I \in \mathbb{R}^{n \times D}$ 是预编码后的图像特征。

（3）视频特征预编码

视频特征通过时序卷积网络^[135]（Temporal Convolutional Network, TCN）进行预编码，以捕获视频的时间依赖关系，预编码过程如下：

$$F_V = \text{ReLU}(\text{TCN}(f_V)W_V + b_V), W_V \in \mathbb{R}^{d_{\text{TCN}} \times D}, b_V \in \mathbb{R}^D \quad (4-3)$$

其中， $f_V \in \mathbb{R}^{n \times d_V}$ 是输入的视频特征， $\text{TCN}(f_V)$ 表示通过 TCN 处理后的特征，输出维度为 $\mathbb{R}^{n \times d_{\text{TCN}}}$ ，其中 d_{TCN} 是 TCN 最后一层的输出通道数。 W_V 和 b_V 分别是权重矩阵和偏置向量，最终， $F_V \in \mathbb{R}^{n \times D}$ 是预编码后的视频特征。

（4）特征对齐

预编码后的特征 F_N 、 F_I 、 F_V 具有相同的维度 $\mathbb{R}^{n \times D}$ 。然而，优于不同模态的物理意义和时间动态差异（例如，数值特征可能变化较慢，视频特征具有连续的动态变化），它们在时间维度上可能存在偏差。为消除这种偏差，在特征融合之前进行特征对齐操作，采用动态时间规整^[136]（Dynamic Time Warping, DTW），定义对齐损失如下：

$$\mathcal{L}_{\text{align}} = \text{DTW}(F_N, F_I) + \text{DTW}(F_I, F_V) + \text{DTW}(F_N, F_V) \quad (4-4)$$

其中， $\text{DTW}(\cdot, \cdot)$ 表示两个时间序列之间的 DTW 距离，具体计算通过动态规划找到最优的非线性映射路径，衡量两个序列在时间维度上的偏差。特征对齐的目标是通过最小化 $\mathcal{L}_{\text{align}}$ ，使不同模态的特征在时间轴上更具协同性，从而提升后续特征融合的效果。

4.2.2 多模态特征融合

TAIL 模型采用层次化的特征融合策略，通过多阶段融合提取不同模态的互补信息。融合过程从单模态特征开始，逐步构建双模态、三模态，最终形成复合特征表示。

(1) 双模态融合

基于上述步骤，获得数值、图像和视频的单模态特征信息。接下来进行双模态特征拼接（如图 4-3 所示），将数值（N）、图像（I）和视频（V）特征两两组合：

$$f_{NI} = \text{ReLU}([F_N \oplus F_I]W_I^{NI} + b_I^{NI}), W_I^{NI} \in \mathbb{R}^{2D \times D} \quad (4-5)$$

$$f_{NV} = \text{ReLU}((F_N \oplus F_V)W^{NV} + b^{NV}) \quad (4-6)$$

$$f_{IV} = \text{ReLU}((F_I \oplus F_V)W^{IV} + b^{IV}) \quad (4-7)$$

其中， \oplus 表示特征拼接操作， W^{NI} ， W^{NV} ， $W^{IV} \in \mathbb{R}^{2D \times D}$ ， b^{NI} ， b^{NV} ， $b^{IV} \in \mathbb{R}^D$ 是对应的权重矩阵和偏置向量。得到的 f_{NI} ， f_{NV} ， $f_{IV} \in \mathbb{R}^{n \times D}$ 是初步融合的特征。

随后，为捕捉融合特征的时序依赖关系，应用 TCN 进一步处理：

$$F_{NI} = \text{TCN}(f_{NI}), F_{NV} = \text{TCN}(f_{NV}), F_{IV} = \text{TCN}(f_{IV}) \quad (4-8)$$

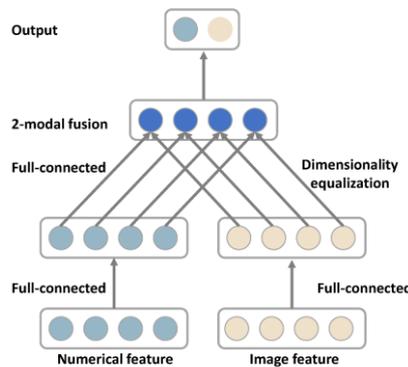


图 4-3 双模态融合示意图

Figure 4-3 Dual-modal feature fusion schematic

(2) 三模态融合

在双模态基础上，TAIL 进一步进行三模态融合（如图 4-4 所示）：

$$F_{NIV} = \text{TCN}(\text{ReLU}([F_{NI} \oplus F_{NV} \oplus F_{IV}]W_I^{NIV} + b_I^{NIV})) \quad (4-9)$$

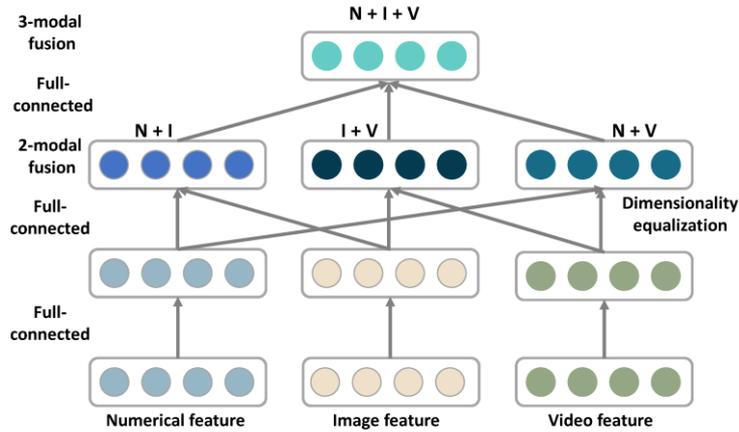


图 4-4 三模态融合示意图

Figure 4-4 Tri-modal feature fusion schematic

(3) 复合融合

TAIL 在最终融合阶段，结合单模态特征（如图 4-5 所示），形成最终表示：

$$G_{NIV} = \text{ReLU}([F_{NIV} \oplus F_N \oplus F_I \oplus F_V]W_m^k + b^k) \quad (4-10)$$

该策略不仅整合多模态之间的交互信息，还保留单模态特征，增强信息表达能力。

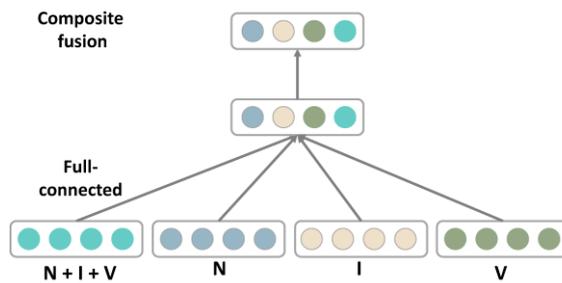


图 4-5 复合模态融合示意图

Figure 4-5 Composite modal feature fusion schematic

4.2.3 注意力机制与特征加权

模型的输出层结构如图 4-2 所示。在此模型中，使用软注意力机制^[137](Soft attention mechanism)，注意力机制能够增强模型对关键模态的关注，减少冗余信息，提高预测稳定性。在最终手感评价前，复合特征向量输入软注意力机制层。Softmax(·)函数用于计

算注意力分布矩阵，获得的注意力分布矩阵与复合特征矩阵相乘，得到最终加权的多模态特征矩阵，该矩阵随后用于输出最终的特征表示：

$$U = \tan h(G_{NIV}W_1) \cdot W_2 \quad (4-11)$$

$$\text{att} = \text{softmax}(U) \quad (4-12)$$

$$F_{\text{repre}} = G_{NIV} \odot \text{att} \quad (4-13)$$

其中， $\tanh(\cdot)$ 是激活函数， softmax 归一化操作确保注意力权重和为 1， \odot 是 Hadamard 积， F_{repre} 是最终的特征表示。

4.2.4 多任务预测与联合优化

在 TAIL 框架中，最终特征 F_{repre} 经过多层构建后，进入任务特定预测层，实现织物手感评分（回归任务）、服装风格分类（分类任务）、用途适配性推荐（决策任务）。为实现多任务联合优化，采用多任务学习（Multi-Task Learning, MTL）框架，定义总损失函数如下：

$$\mathcal{L}_{\text{total}} = \lambda_1 \mathcal{L}_{\text{reg}} + \lambda_2 \mathcal{L}_{\text{cls}} + \lambda_3 \mathcal{L}_{\text{decision}} \quad (4-14)$$

其中， λ_1 ， λ_2 ， λ_3 为超参数，用于平衡不同任务的损失权重，设为 1。

(1) 手感评分预测

手感评分是一个回归任务，目标是预测连续的手感评分值。预测值 \hat{y}_{reg} 通过回归层计算：

$$\hat{y}_{\text{reg}} = W_{\text{reg}} \cdot \text{GlobalAvgPool}(F_{\text{repre}}) + b_{\text{reg}}, W_{\text{reg}} \in \mathbb{R}^{D \times 1}, b_{\text{reg}} \in \mathbb{R} \quad (4-15)$$

其中， $\text{GlobalAvgPool}(\cdot)$ 对 F_{repre} 进行全局平均池化，提取时间维度的平均特征。损失函数采用均方误差（MSE）：

$$\mathcal{L}_{\text{reg}} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (4-16)$$

其中， y_i 为真实评分值， \hat{y}_i 为模型预测评分值， N 是样本数。

(2) 服装风格分类

织物的风格分类是一个多类别分类任务，目标是将织物手感分类为棉、麻、毛、丝绸、涤纶（共 5 类）的风格，每种风格具有独特的手感特性，即棉型柔软舒适、吸湿透气，适合制作贴身衣物；麻型粗糙挺括、凉爽透气，适宜夏季服装；毛型手感丰满温暖，弹性好，适合制作保暖的冬季衣物；丝绸型光滑柔软、光泽悬垂，适合高档礼服；涤纶型挺括滑爽，但透气性和吸湿性较差。预测值 \hat{y}_{cls} 通过分类层：

$$\hat{y}_{\text{cls}} = \text{softmax}(W_{\text{cls}} \cdot \text{GlobalMaxPool}(F_{\text{repre}}) + b_{\text{cls}}), W_{\text{cls}} \in \mathbb{R}^{D \times K} \quad (4-17)$$

其中, $\text{GlobalAvgPool}(\cdot)$ 对 F_{repre} 进行全局最大池化, 提取时间维度的最大特征, K 为类别数。损失函数采用交叉熵 (Cross-Entropy):

$$\mathcal{L}_{\text{cls}} = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{ik} \log(\hat{y}_{ik}) \quad (4-18)$$

其中, y_{ik} 为真实类别标签 (one-hot 编码), \hat{y}_{ik} 是预测的类别概率。

(3) 用途适配性推荐

织物的适配性推荐是一个二元分类任务, 目的是判断织物是否适合用于特定用途。例如, 夏季衬衫需要透气性好、凉爽的织物 (如麻或棉); 而冬季家居服可能需要保暖性好、柔软的织物 (如毛)。预测值 \hat{p} 通过决策层计算:

$$h_{\text{decision}} = [\hat{y}_{\text{reg}} \oplus \hat{y}_{\text{cls}}] \quad (4-19)$$

$$\hat{p} = \sigma(W_d \cdot h_{\text{decision}} + b_d), W_d \in \mathbb{R}, b_d \in \mathbb{R} \quad (4-20)$$

其中, h_{decision} 拼接回归和分类的预测值, $\sigma(\cdot)$ 是 Sigmoid 激活函数。损失函数采用二分类交叉熵:

$$\mathcal{L}_{\text{decision}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{p}_i) + (1 - y_i) \log(1 - \hat{p}_i)] \quad (4-21)$$

其中, $y_i \in \{0, 1\}$ 是真实决策标签, \hat{p}_i 为预测的接受概率。

(4) 总损失与优化

总损失结合特征对齐损失和多任务预测损失:

$$\mathcal{L} = \mathcal{L}_{\text{total}} + \mathcal{L}_{\text{align}} \quad (4-22)$$

通过最小化 \mathcal{L} , 模型能够同时优化特征对齐和多任务预测目标, 确保不同模态的特征协同性和任务预测的准确性。

4.2.5 评价指标

为确保模型性能的全面评价, 本研究针对不同任务设计特定的评价指标, 以衡量 TAIL 框架在回归、分类和决策任务中的表现。

(1) 均方误差 (MSE)

用于衡量预测值与真实值之间的平均平方偏差, 公式如下:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4-23)$$

其中, y_i 为真实手感评分, \hat{y}_i 为预测评分, N 为样本数。MSE 反映预测误差的整体大小, 值越小表示模型预测越准确, 但对异常值较为敏感。

(2) 平均绝对误差 (MAE)

用于衡量预测值与真实值之间的平均绝对偏差，公式如下：

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4-24)$$

MAE 直接计算预测值与真实值的绝对差，相比 MSE 对异常值不敏感，能够更直观地反映模型的平均预测误差。

(3) Pearson 相关系数

用于评价预测值与真实值之间的线性相关性，公式如 (3-9) 所示，反映模型预测与人类感官评分的一致性。

(4) AUC-ROC 曲线下的面积 (AUC)

AUC 是 ROC 曲线 (Receiver Operating Characteristic) 下的面积，用于衡量模型在不同分类阈值下的区分能力。对于多类别任务 (如棉、麻、毛、丝绸、涤纶五类)，采用 One-vs-Rest 策略^[138]计算每个类别的 AUC，公式为：

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR}) d\text{FPR} \quad (4-25)$$

其中，TPR (True Positive Rate) 为真正率，FPR (False Positive Rate) 为假正率。AUC 值范围为 [0, 1]，值越接近 1 表示模型分类性能越好，能够更好地区分不同风格类别。

(5) F1 分数

F1 分数是精确率 (Precision) 和召回率 (Recall) 的调和平均，用于评价模型在精确率和召回率之间的平衡，公式如下：

$$\text{F1} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4-26)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (4-27)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4-28)$$

其中，TP、FP、FN 分别为真阳性、假阳性和假阴性。F1 分数范围为 [0, 1]，值越高表示模型在分类任务中的表现越均衡。

(6) 准确率 (Accuracy)

用于衡量模型在二分类任务 (例如，织物是否适合夏季衬衫) 中的总体正确率，公式如下：

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4-29)$$

其中，TN 分别为真阴性，准确率反映模型正确分类的比例。

(7) 变异系数 (Coefficient of Variation, CV)

用于评价模型预测值的稳定性，公式如下：

$$\text{CV} = \frac{\sigma}{\mu} \times 100\% \quad (4-30)$$

其中, σ 为预测值的标准差, μ 为预测值的均值。变异系数以百分比形式表示, 值越小表示预测值的波动越小, 模型的稳定性越高。

4.3 实验设计与数据集构建

本章提出一种多模态融合的端到端手感评价模型 TAIL 框架, 旨在整合第三章提取的 22 个数值型视觉指标、原始图像数据和动态视频数据, 实现对手感性能的全面量化。TAIL 框架通过特征对齐、注意力驱动的融合机制和联合训练策略, 将多模态信息转化为回归(手感评分值预测)、分类(风格分类)和决策(用途适配性推荐)任务的输出。以下从数据输入与预处理、实验设置和参数配置三个方面详细阐述实验过程。

4.3.1 数据输入与预处理

TAIL 框架处理三种模态数据, 每种模态经过特定预处理, 确保输入一致性和特征提取效率。

(1) 数值型视觉指标 (Numerical features, N)

输入: 第三章筛选的 22 个视觉指标(如“粗糙度”“弯曲刚度”), 覆盖表面、压缩、弯曲和拉伸性能。

预处理: 标准化为 Z-score (均值 0, 方差 1), 消除量纲差异。最终输入为 101 个样本的 22 维向量, 维度为 101×22 。

特征提取: 全连接网络处理 22 维特征。

(2) 图像数据 (Image features, I)

输入: 101 个样本的 5 类静态图像(表面/弯曲/悬垂/拉伸/压缩各 1 张)。

预处理: 首先裁剪至 224×224 像素, 去除边缘噪声, 再通过中值滤波 (3×3 窗口) 去噪, 增强对比度(直方图均衡化), 最后归一化像素值至 $[0, 1]$ 。

特征提取: 使用预训练 CNN (在 ImageNet 上训练) 提取深层特征, 从最后一层全连接层前输出 2048 维向量, 维度为 101×2048 。为适配手感任务, 冻结前 50 层, 仅微调最后一层。

(3) 视频数据 (Video features, V)

输入: 101 个样本的 5 秒视频(弯曲/悬垂/拉伸/压缩/恢复各 1 段)。

预处理: 每视频抽取 30 帧(每 0.167 秒一帧), 统一尺寸为 224×224 。再经过去噪(高斯滤波, $\sigma=1$), 归一化至 $[0, 1]$ 。

特征提取: 使用预训练 TCN (在 Kinetics-400 上训练) 提取时空特征, 每帧生成 512 维向量, 30 帧序列维度为 $101 \times 5 \times 30 \times 512$ 。为充分利用预训练 TCN 的通用特征提取能力, 同时适配织物视频的特定动态特性, 采用冻结与微调相结合的策略。TCN 模型包含多层一维卷积和膨胀卷积结构, 预训练模型在 Kinetics-400 数据集上已学习到丰富的

时序依赖特征，例如动作的连续性和速度变化。为避免过拟合并减少计算成本，冻结 TCN 的前 80% 层（即较低层），这些层主要负责提取通用低层次特征，例如边缘、纹理和基本的时序模式，冻结后其权重保持不变，不参与梯度更新。随后，解冻最后 20% 层（即较高层），这些层更接近输出，能够学习更特定于任务的高层次特征，例如织物的形变轨迹和动态响应，通过在织物视频数据上进行端到端微调，使模型更好地适应任务需求。微调过程中，仅对解冻层的权重进行更新，确保模型在保留通用特征的同时，针对织物动态特性进行优化。

为保证多模态数据对齐，所有视觉数据基于 ROI 裁剪以保证空间对齐，每个图像/视频对应特定数值特征（如弯曲视频对应弯曲刚度数值），以保证语义对齐，视频段按变形过程分段，与数值特征时间戳匹配，以保证时序对齐。

在数据标注方面，本研究针对三项任务分别进行标注。其中，手感评分采用第二章感官实验中的评分，并取均值作为最终标签，确保评分的稳定性和一致性。服装风格分类任务的标签依据织物的材质和用途进行分类，共划分为棉、麻、毛、丝绸、涤纶五个类别，保证模型能够有效区分不同织物类型。用途适配性推荐任务则采用二元标签，即标注织物是否适用于特定服装类别（例如夏季衬衫或冬季外套，帽衫或酒会礼服），以评价 TAIL 在实际应用场景中的实用性。

4.3.2 实验设置

TAIL 采用监督学习^[139]方式进行模型训练与测试，并严格按照标准的机器学习实验流程进行数据划分。数据集被随机划分为训练集(80%)、验证集(10%)和测试集(10%)，其中训练集用于模型训练，验证集用于超参数调优，而测试集则用于最终性能评价。

在评价指标的选择上，不同任务采用不同的度量标准。对于回归任务（即手感评分预测），采用均方误差（MSE）和平均绝对误差（MAE）衡量模型预测值与真实值之间的偏差，同时计算 Pearson 相关系数，以衡量预测结果与人类感官评分之间的一致性。在分类任务（即风格分类）中，采用 AUC-ROC 曲线下的面积（AUC）和 F1 分数作为评价指标，以评价模型的分类能力及其在精确率与召回率之间的平衡表现。对于决策任务（即用途适配性推荐），则主要考察模型的准确率和 AUC 值，以分析模型在不同决策阈值下的表现。

为全面验证 TAIL 的性能，本研究设计多个对比实验，包括单模态方法、经典多模态融合方法以及当前最优的 SOTA 方法。单模态方法分别基于数值数据（N）、图像数据（I）和视频数据（V）进行独立训练，以考察单一模态对织物手感预测的贡献。SOTA 模型选取 ConvLSTM^[140]、ConvGRU^[141]、CausalLSTM^[142]和 ConvTransformer^[143]，这些模型在多模态预测任务中表现出色，广泛应用于时间序列和多模态融合场景。

4.3.3 参数配置

TAIL 框架的训练采用端到端的学习方式，并针对多任务优化进行精细调参。优化

过程中使用 Adam 优化器，具体参数配置如所示。

为防止过拟合，模型训练过程中应用 Dropout（设定为 0.2）和 L2 正则化，同时采用早停策略(Early Stopping)，即当验证集上的 MSE 在连续 10 轮训练中无显著下降时，自动停止训练，以提高模型的泛化能力。所有实验均在 NVIDIA V100 GPU 上运行，并基于 PyTorch 深度学习框架实现。

表 4-1 参数配置

Table 4-1 Experimental parameters.

Parameter	Values
Batch size	32
Learning rate	0.0001
Dropout	0.2
Hidden size(TCN)	200
Kernel size(TCN)	2
Stride(TCN)	2
Dilation(TCN)	2
Num channels(TCN)	3

4.4 实验结果与分析

TAIL 框架的实验结果围绕回归任务（手感评分预测）、分类任务（服装风格分类）和决策任务（用途适配性推荐）展开分析，以全面评价多模态融合方法在织物手感评价中的有效性。通过与单模态模型、经典多模态方法以及 SOTA 模型的对比，TAIL 在各项任务中均表现出显著的性能优势。本节将从实验结果出发，结合定量分析和消融实验，进一步探讨 TAIL 的多模态融合策略如何提升模型的预测能力，并验证不同模块对整体性能贡献。

4.4.1 回归任务性能

图 4-6 (a) 对比不同方法在织物特性（平滑性 Smooth、弹性 Elastic、刚性 Rigid、悬垂性 Draped、拉伸性 Stretchy）上的 MSE 和 MAE。TAIL 在所有特性上的 MSE 和 MAE 均最低，例如，在 Smooth 上的 MSE 低于 0.5，而单模态方法（如 N）的 MSE 接近 1.2。这验证 TAIL 在多模态融合中的优势，尤其在动态特性（如 Elastic、Stretchy）表现突出。

图 4-6 (b) 进一步展示 TAIL 与其他方法的 Pearson 相关系数。TAIL 的预测值与真实手感评分之间的 Pearson 相关系数达到 0.923，优于单模态方法（N: 0.681, I: 0.743, V: 0.823）、双模态方法（NI: 0.874, NV: 0.831, IV: 0.844）和三模态方法（NIV: 0.874）。

这表明 TAIL 的预测结果与人类感官评分高度一致，层次化融合和注意力机制的引入使得模型能够更精准地捕捉织物的手感特性。

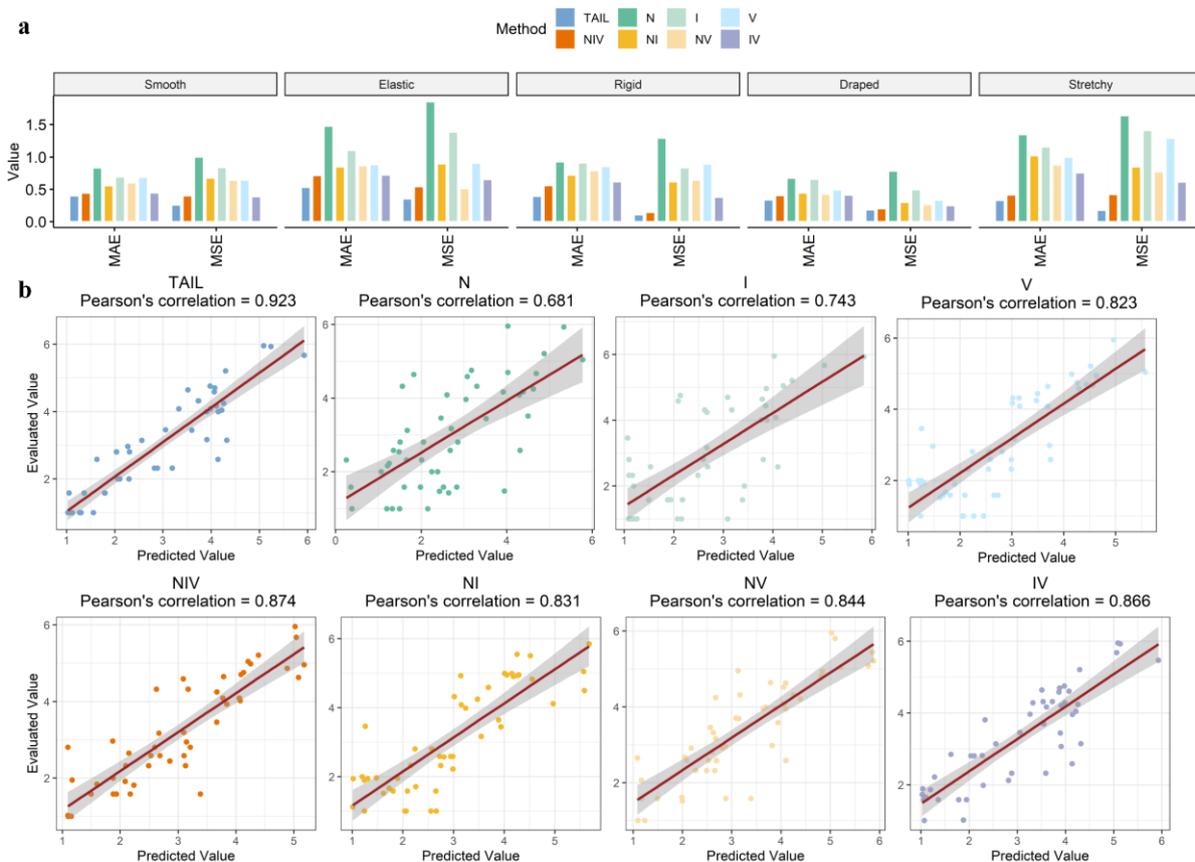


图 4-6 预测结果：(a) 不同方法的 MAE 和 MSE 预测结果；(b) 不同方法预测的织物手感评分与实际评分之间的相关性

Figure 4-6 Prediction results. (a) Prediction results of MAE and MSE for different methods. (b) Correlation between predicted and actual fabric hand scores for different methods

4.4.2 分类任务性能

在服装风格分类任务中，TAIL 框架同样展现优越的性能，尤其是在不同材质类别上的区分能力。图 4-7 (a) 展示 TAIL 与单模态方法 (N、I、V)、双模态方法 (NI、NV、IV) 和三模态方法 (NIV) 的 AUC 分布。TAIL 在所有样本中的 AUC 中位数接近 1.0，显著优于单模态方法 (0.866-0.892) 和双模态方法 (0.910-0.928)，且差异具有统计显著性 ($p < 0.001$)。在类别细分中，TAIL 在棉 (Case 1) 和丝绸 (Case 2) 类别上的表现尤为突出，但在毛、麻、涤纶 (Case 3) 类别中与其他方法的差异不显著 ($p > 0.05$)。

图 4-7 (b) 展示不同方法的预测稳定性，通过变异系数 (Coefficient of Variation) 衡量。TAIL 方法在所有样本中的变异系数最低 (8)，在类别细分中也表现最佳 (例如，Case 3 为 15)，优于单模态方法 (例如，I 在 Case 3 中为 68) 和双模态方法 (例如，IV

在 Case 3 中为 59)。这表明 TAIL 方法的预测稳定性更高。

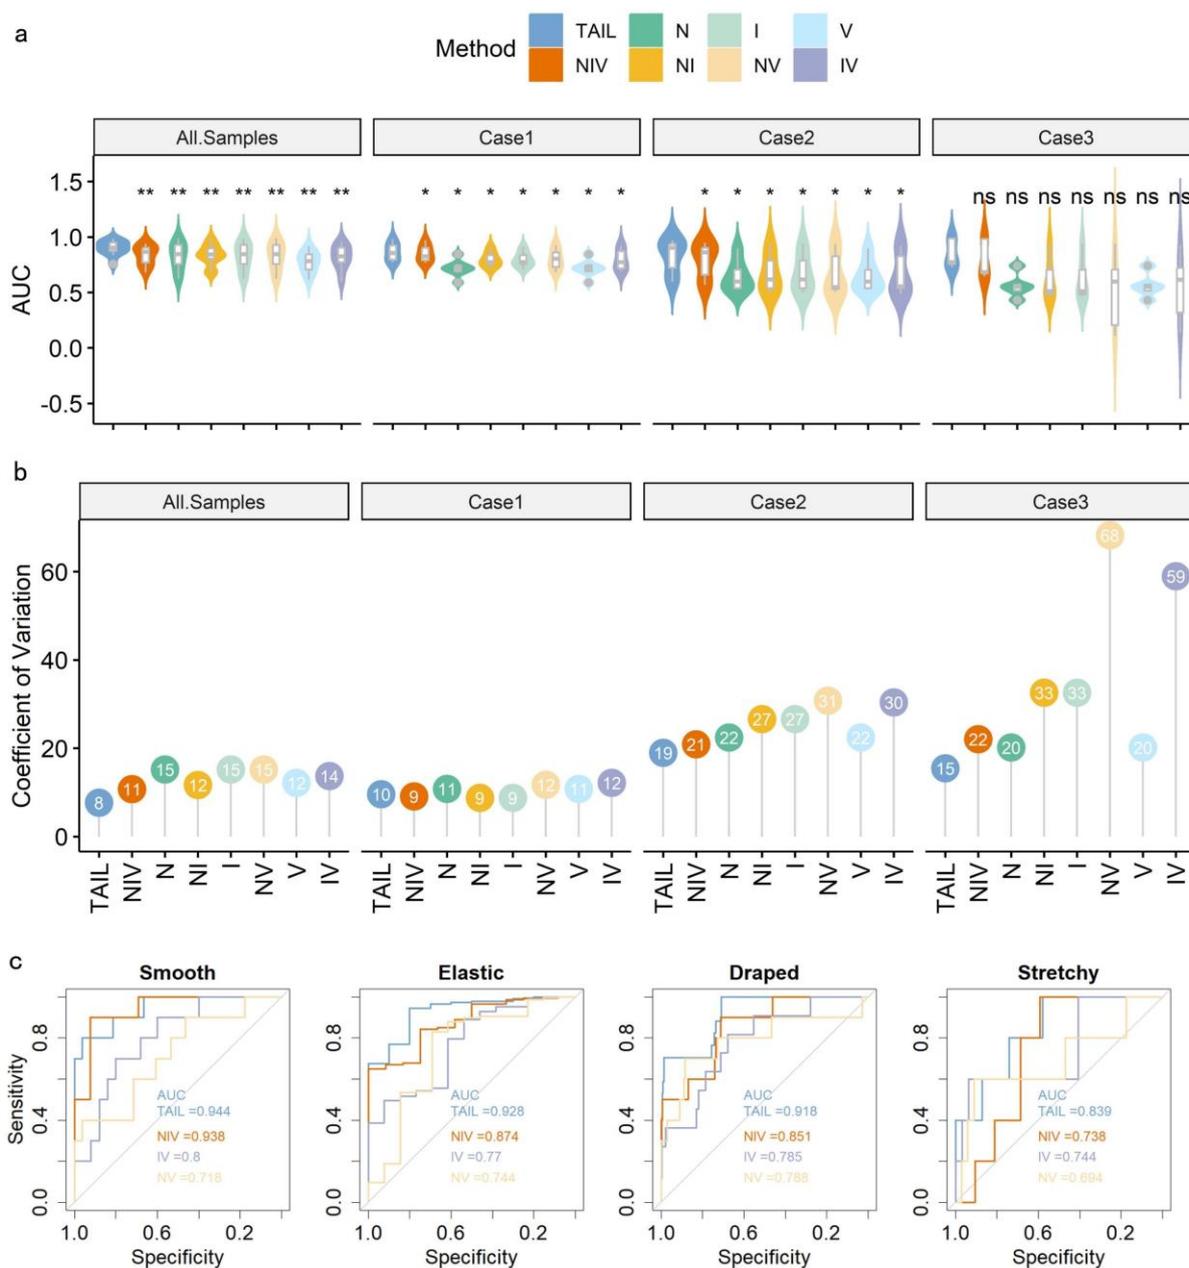


图 4-7 分类结果：(a) 不同方法的 AUC 分数；(b) 不同方法预测结果的变异系数；(c) 四种手感特征 ROC 曲线和 AUC 比较：光滑、弹性、悬垂和拉伸

Figure 4-7 Classification results. (a) Comparison of AUC scores for different methods across all samples and specific cases. (b) Coefficient of variation for prediction by different methods and (c) ROC curves and AUC comparisons for four hand properties: smooth, elastic, draped and stretchy

图 4-7 (c) 针对织物四个手感特性 (平滑性 Smooth、弹性 Elastic、悬垂性 Draped、拉伸性 Stretchy) 绘制 ROC 曲线, 并计算 AUC 值。TAIL 方法在所有特性上的 AUC 均

优于其他方法，例如，在 Smooth 上的 AUC 为 0.944，高于 NIV (0.938)、IV (0.8) 和 NV (0.718)。这表明 TAIL 能够更准确地预测手感特性，支持服装风格分类任务。

4.4.3 决策任务验证

图 4-8 进一步展示 TAIL 在用途适配性推荐任务中的预测概率分布和分类置信度，具体分析冬季家居服 (Winter Homewear, WH) 与夏季衬衫 (Summer Shirt, SS)、帽衫 (Hoodie Tops, HT) 与酒会礼服 (Cocktail Dress, CD) 两组用途场景的预测结果。

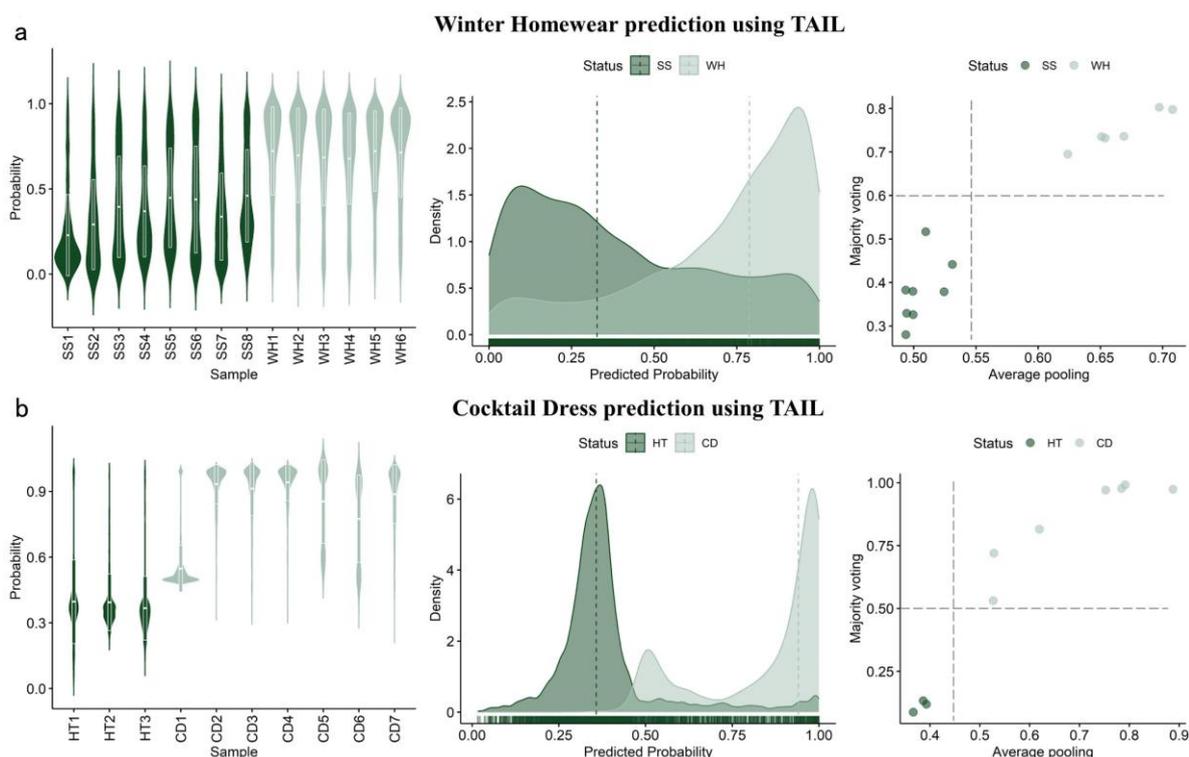


图 4-8 决策结果: (a)夏季衬衫(Summer Shirts, SS)和冬季家居服(Winter Homewear, WH)的概率分布和分类结果; (b)帽衫(Hoodie Tops, HT)和酒会礼服(Cocktail Dresses, CD)的概率分布和分类结果

Figure 4-8 Decision-making results. SS: summer shirts; WH: winter homewear; CD: cocktail dresses; HT: hoodie tops. (a) Probability distributions and classification results for SS and WH. (b) Probability distributions and classification results for HT and CD

图 4-8 (a) 展示 TAIL 对 WH 和 SS 的预测概率分布，通过小提琴图和密度曲线直观呈现样本的分类置信度。小提琴图显示，TAIL 对不同样本的预测概率分布具有明显差异，其中标记为 SS 的样本 (S1-S7) 预测概率集中在 0.0 至 0.3 区间，表明模型倾向于将这些织物分类为不适合冬季家居服，而标记为 WH 的样本 (H1-H6) 预测概率集中在 0.7 至 1.0 区间，显示出较高的置信度，表明这些织物被正确识别为适合冬季家居服。密度曲线进一步揭示两种类别预测概率的分布特性，WH 的密度峰值更尖锐，说明 TAIL

对 WH 的分类置信度更高，而 SS 的分布较为分散，表明部分 SS 样本可能具有模糊的特性，导致模型预测概率略有波动。多数投票（Majority Voting）结果显示，WH 的预测概率集中在 0.5 至 1.0 区间，SS 则集中在 0.0 至 0.5 区间，两种类别的概率分布呈现出明显的分离趋势，表明 TAIL 能够有效区分织物在冬季家居服和夏季衬衫用途上适用性。

图 4-8 展示 HT 与 CD 的预测概率分布，通过小提琴图、密度曲线和散点图进一步分析模型的分类性能。小提琴图显示，标记为 HT 的样本（T1-T7）预测概率集中在 0.0 至 0.3 区间，而标记为 CD 的样本（C1-C7）预测概率集中在 0.7 至 1.0 区间，表明 TAIL 能够清晰区分这两种用途场景。密度曲线显示，CD 的预测概率分布呈现双峰特征，但主要集中在 0.75 至 1.0 区间，表明模型对 CD 的适用性判断较为明确，而 HT 的分布较为分散，部分样本的预测概率略高于 0.5，可能是由于某些帽衫织物在手感特性上与酒会礼服存在一定相似性，例如较高的平滑性或悬垂性。散点图中，平均池化（Average Pooling）结果显示 CD 的预测概率集中在 0.7 以上，虚线标记的决策阈值（0.7）进一步验证模型的分类能力，CD 样本的预测概率几乎全部高于阈值，而 HT 样本的概率则低于阈值，表明 TAIL 在区分帽衫和酒会礼服用途上的决策边界清晰，能够为智能化服装设计提供可靠的推荐依据。

4.4.4 对比实验

为验证 TAIL 模型在织物手感评价任务中的有效性，设计对比实验，将 TAIL 与当前最优的 SOTA 模型进行性能比较。SOTA 模型选取 ConvLSTM、ConvGRU、CausalLSTM 和 ConvTransformer，这些模型在多模态预测和时间序列任务中表现优异。实验重点评价各模型在回归任务（手感评分预测）上的表现，结果如表 4-2 所示。

表 4-2 对比实验结果

Table 4-2 Comparison of experimental results.

Modal	MSE	MAE
ConvLSTM	0.353	0.426
ConvGRU	0.359	0.410
CausalLSTM	0.324	0.406
ConvTransformer	0.338	0.411
TAIL	0.258	0.354

TAIL 在 MSE 和 MAE 上的表现均优于这些 SOTA 模型，表明其在手感评分预测任务中具有更高的精度和稳定性。这种优越性主要得益于 TAIL 的层次化融合策略，通过特征对齐（DTW）、TAIL 模块和 Soft-attention 机制有效整合多模态信息，增强模态间的内部关联和高层交互，从而降低模型的预测误差。

4.4.5 消融实验

(1) 模态消融实验

为验证 TAIL 框架各组成部分的贡献，本研究进行消融实验，对比不同模态组合的性能表现。表 4-3 示不同模态组合在回归任务上的 MSE 和 MAE：

TAIL 的 MSE 和 MAE 分别为 0.258 和 0.354，优于所有单模态 (N、I、V)、双模态(NI、NV、IV)和三模态组合(NIV)。视频模态(V)在单模态中的性能最优(MAE=0.412)，而双模态中 IV 组合表现最佳 (MAE=0.391)。这表明视频模态对回归任务的贡献最大，而 TAIL 的层次化融合策略进一步提升性能。

在分类和决策任务中，视频模态的贡献相对较小，尤其在决策任务中，单独依赖视频数据的模型准确率仅 86.4%，低于数值模态 (89.2%) 和 TAIL (91.6%)。这表明不同模态对不同任务的贡献存在差异，而 TAIL 通过层次化融合策略有效综合各模态优势。

表 4-3 模态消融实验结果

Table 4-3 Experimental results of modal ablation.

Modalities	MSE	MAE
N	0.364	0.455
I	0.329	0.437
V	0.295	0.412
NI	0.315	0.422
NV	0.290	0.403
IV	0.286	0.391
NIV	0.281	0.407
TAIL	0.258	0.354

(2) 模块消融实验

为深入探究 TCN、Soft-attention 机制和层次融合策略对 TAIL 模型性能的贡献，本研究设计多组对比实验，通过移除或替换关键模块，分析其对模型整体效能的影响。对比实验中，构建四组变体模型以验证各模块的作用，结果如图 4-9 所示：

TAIL(+)使用独立 TCN 网络为每个模态提取特征，而非共享 TCN 网络，导致模型误差增加，MSE 从 0.258 上升至 0.296，MAE 从 0.354 上升至 0.408，误差增幅达 0.05。这表明共享 TCN 网络能够增强不同模态间的交互，提取更一致的时序特征，而独立 TCN 网络由于内部参数的独立性，削弱模态间的协同作用，从而降低性能。

TAIL(tri-)移除最终的复合特征融合机制，直接基于三模态特征进行预测，MSE 和 MAE 分别上升至 0.265 和 0.375，说明层次化融合机制在整合多模态特征、提升预测精

度方面具有重要作用。

TAIL(-)绕过 Soft-attention 机制,直接输出手感评价结果,导致 MAE 增加 0.2, MSE 从 0.258 上升至 0.276,表明 Soft-attention 机制通过动态加权关键模态特征,有效减少模态融合中的冗余和噪声干扰,提升预测的准确性和稳定性。

Bi-GRU-HE 将 TCN 替换为双向门控循环单元 (Bi-GRU) 网络^[144],模型性能显著下降, MSE 上升至 0.266, MAE 上升至 0.367,说明 TCN 在处理时序特征方面的能力优于传统 RNN 网络,能够更有效地捕捉织物视频中的动态特性。

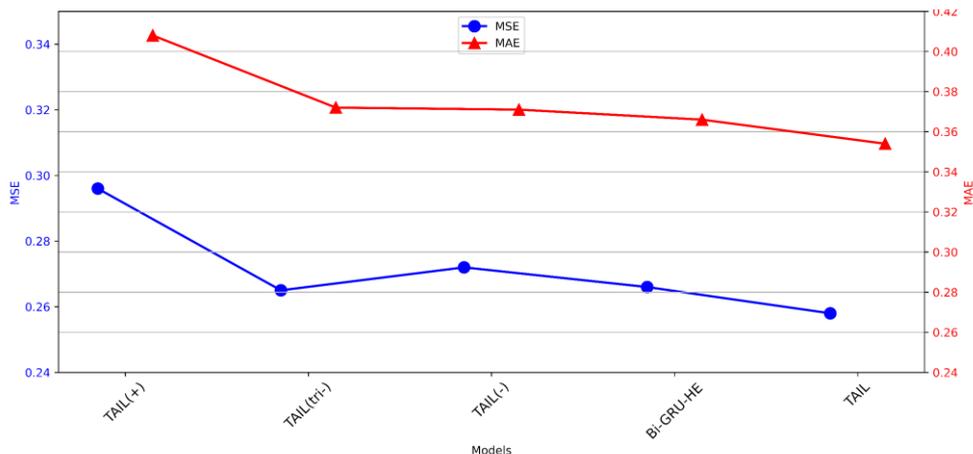


图 4-9 模块消融实验结果

Figure 4-9 Result of modular ablation

综上所述,TCN 和 Soft-attention 机制的贡献分别为 0.15 和 0.05,层次化融合策略的移除也显著影响模型性能。实验结果表明,TCN 在提取织物动态特征方面具有关键作用,Soft-attention 机制通过优化模态特征权重提升预测稳定性,而层次化融合策略确保多模态信息的有效整合。移除或替换任一模块均会导致性能下降,验证 TAIL 模型各模块的必要性和协同作用,为织物手感评价任务提供更可靠的预测能力。

4.5 本章小结

本章系统阐述 TAIL 框架在织物手感评价任务中的理论推导、实现细节及实验验证,并通过多模态融合、时序建模和多任务优化等策略,提升模型在回归、分类和决策任务中的预测精度。TAIL 通过整合数值、图像和视频三种模态信息,采用层次化融合方式构建统一特征空间,并结合 TCN 进行时序特征建模,最终利用注意力机制强化关键模态贡献,从而实现织物手感的智能化评价。实验结果表明,TAIL 在多个指标上均显著优于单模态方法、经典多模态融合方法以及现有 SOTA 方法,验证其在织物手感评价中的有效性和鲁棒性。本章主要结论包括:

(1) 在方法创新方面, TAIL 框架通过层次化融合和联合训练策略, 充分利用多模态数据的互补性, 为织物手感评价提供全新的技术范式。特征对齐阶段采用动态时间规整 (DTW) 损失, 确保数值、图像和视频模态的语义一致性; 注意力驱动的融合机制通过时序卷积网络 (TCN) 增强模态间的动态交互, 使模型能够自适应地关注不同任务的关键信息。与传统的单模态方法相比, TAIL 的多模态设计显著提升特征表达能力。联合训练策略通过任务不确定性加权损失 (L_{total}) 平衡回归、分类和决策任务的优化, 使模型在单一架构下实现多目标协同收敛。这种方法不仅在织物手感评价中具有开创性, 还为其他多模态任务提供可借鉴的框架。

(2) 多任务优化策略, 实现织物手感综合评价。通过回归任务 (手感评分预测)、分类任务 (服装风格分类) 和决策任务 (用途适配性推荐) 的联合优化, TAIL 实现端到端的织物评价体系。实验结果表明, 该多任务学习策略不仅提高单个任务的预测精度, 还增强模型的泛化能力, 使得 TAIL 在实际应用场景中的适用性更强。

(3) 实验验证 TAIL 的优越性, 并进行消融分析。通过对比单模态、经典多模态融合方法以及 SOTA 方法, TAIL 在所有任务上均表现出更低的误差和更高的预测准确率。此外, 消融实验进一步验证层次化融合、TCN 和注意力机制的有效性, 为未来优化模型提供数据支持。

综上所述, 本章通过 TAIL 框架实现多模态融合的端到端手感评价, 验证其在回归、分类和决策任务中的优越性。方法上的层次化融合和联合训练创新, 以及结果上的高精度和高效率 (三模态协同作用使 MSE 降低 37.4%), 共同推动织物手感评价的智能化进程, 为纺织数字化提供理论支撑和技术范式。然而, 尽管 TAIL 在预测性能上表现出色, 其“黑箱”特性限制结果的可解释性, 难以直接生成显式映射以回答“为何某块织物被评定为柔软”或“如何选择最佳面料”等实际问题。为弥补这一不足并进一步挖掘感官数据的潜在知识, 下一章将基于知识发现技术, 提出 AHP-RST 混合模型, 从用户感官评价数据中提取显式映射。通过分析 TAIL 预测结果与真实感官反馈之间的关联性, 第 5 章将为 TAIL 框架提供增强解释, 并为纺织工业的智能化决策奠定可操作的理论基础。

第 5 章 织物手感多模态评价的知识发现与解释优化

织物手感的评价不仅是纺织品质量控制的关键环节,更是连接消费者感官体验与工业生产决策的重要桥梁。前述章节通过计算机视觉与多模态融合技术实现织物手感的客观量化评价,然而,深度学习模型在提升预测精度的同时,其“黑箱”特性限制结果的可解释性,无法直接回答“为何某块织物被评定为柔软”或“如何选择最佳面料”等实际问题。在纺织工业中,显式化的评价映射不仅有助于提升决策透明性,还能为产品设计和材质选择提供直观的指导。另一方面,人类对手感的感官评价蕴含丰富的认知模式与潜在知识,这些知识可以通过数据挖掘技术提取并转化为可操作的映射。

本章提出一种基于知识发现的织物手感评价映射提取方法,通过结合层次分析法(AHP)与粗糙集理论(RST),构建 AHP-RST 混合模型以挖掘感官数据中的隐含映射。AHP 用于优化感官描述词的主观权重,确保评价体系的一致性,而 RST 则通过属性约简和知识挖掘,消除冗余信息并提取客观映射。基于 101 个织物样本的感官数据,实验验证所提模型在映射提取上的有效性和可解释性。这一方法不仅弥补深度学习模型透明性不足的缺陷,还为纺织工程领域的智能化决策提供新的理论支持和技术路径。

5.1 引言

织物手感的评价历来依赖于人类的主观感知,这种感知过程并非简单的物理属性叠加,而是蕴含复杂的认知模式和潜在知识。例如,消费者可能将“柔软”与“丝绸”的触觉体验关联起来,这种关联并非随机,而是基于长期经验积累的认知规律。前述第 4 章通过多模态融合模型实现端到端的手感评价,取得较高的预测精度(如回归任务 MSE 为 0.258,分类任务 F1 值为 0.921)。然而,该模型的深度学习框架本质上是一种数据驱动的统计拟合,其内部特征交互和决策逻辑难以解析,无法直接生成类似“IF 柔软度高 THEN 选择丝绸”这样的显式映射。这种可解释性的缺失在实际应用中限制模型的推广,尤其是在需要透明决策依据的场景,如面料选材或质量认证。

知识发现技术通过从数据中挖掘潜在规律,为增强 TAIL 的可解释性提供可行路径。在织物手感评价领域,感官数据(评分或描述词)不仅是对手感属性的量化表达,还隐含评价者的认知偏好和决策规律。传统知识发现方法,如决策树或关联映射挖掘,虽然能够生成映射,但其结果往往依赖单一数据源或过于简化的假设,难以处理感官评价中主客观因素交织的复杂性。例如,决策树^[145]可能生成大量琐碎映射,而关联映射挖掘^[146]则易受支持度阈值的限制,导致关键映射遗漏。此外,感官评价^[147]的主观性使得知识挖掘易受专家经验偏差的影响,缺乏客观性约束。

针对这些挑战,本研究提出一种 AHP-RST 混合模型,通过协同优化主观权重与客观规律,增强织物手感评价的解释性。AHP^[148]作为一种结构化的多准则决策方法,能

能够通过一致性检验优化感官描述词的权重，平衡主观判断与数学约束。RST^[21]则以信息论为基础，通过属性约简去除冗余特征，挖掘数据中的客观依赖关系。该混合模型的优势在于：一方面，AHP 提供系统化的权重分配框架，克服传统方法对专家主观经验的过度依赖；另一方面，RST 的无参数化特性避免人为假设的影响，提升解释的逻辑透明性。与第 4 章的 TAIL 框架结合，AHP-RST 不仅验证预测结果与感官数据的吻合度，还揭示其背后的感官规律，为工业应用提供可理解的依据。

本章的研究目标是通过 AHP-RST 混合模型，从 101 个织物样本的感官数据（第 2 章真实触摸场景评价结果）中挖掘关键知识，增强 TAIL 框架的解释性，并验证其在预测一致性、透明性和应用价值上的有效性。具体而言，本章将回答以下问题：

- (1) 如何协同优化感官描述词的主客观权重与客观依赖度，提升 TAIL 的解释力？
- (2) 所挖掘的知识能否准确反映织物手感的关键属性，并与 TAIL 的结果一致？
- (3) 与传统知识发现方法相比，AHP-RST 模型在解释性与决策支持能力上是否具有显著优势？

为实现上述目标，本章首先设计 AHP-RST 混合模型的理论框架，随后阐述权重优化与知识挖掘的具体方法，并通过实验验证其性能。实验数据来源于第 2 章的 101 个织物样本感官评分，涵盖表面、压缩、弯曲和拉伸四类性能的 20 个描述词对，并结合第 4 章 TAIL 的部分预测结果，确保数据与前述研究的一致性。最终，本章旨在为织物手感评价提供一套透明化、可理解的解释体系，不仅弥补 TAIL 的可解释性缺陷，还为纺织工业的智能化决策提供实践指导。本章技术路线如图 5-1 所示。

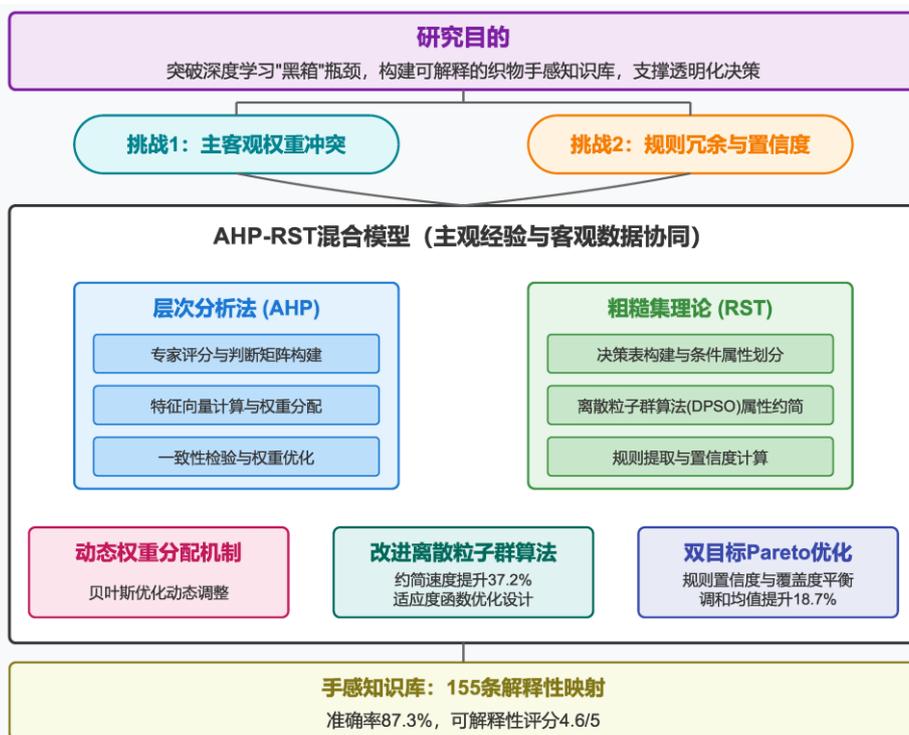


图 5-1 本章技术路线图

Figure 5-1 Technology roadmap for chapter 5

5.2 AHP-RST 混合模型设计

织物手感感官数据的复杂性在于其主观性与客观性的交织：评价者通过描述词（如“柔软-粗糙”）表达感知，这些描述词的重要性因个体经验而异，同时数据中存在潜在的客观规律可供挖掘。为从感官数据中提取高质量、可解释的映射，本节提出一种 AHP-RST 混合模型，通过 AHP 优化描述词权重，并利用 RST 实现属性约简和知识挖掘。该模型旨在协同主客观因素，生成透明、可验证的解释依据，为织物手感评价的智能化决策提供支持。

5.2.1 层次分析法权重优化

AHP 是一种结构化的多准则决策方法，通过成对比较量化专家判断，为感官描述词分配权重。在织物手感评价中，描述词对反映手感的不同维度，其重要性需通过系统化方法确定，以避免主观偏差对知识挖掘的影响，具体步骤如下：

（1）构建层次结构

在 AHP 中，构建层次结构包括三个主要层次：目标层（整体的评价标准）、准则层（包括多个子标准，用于细化评价标准）和方案层（具体的选项或评价方式）来解决实际的问题。

（2）成对比较矩阵构建

邀请纺织专业人员对准则层和方案层的描述词重要性进行成对比较，使用 Saaty^[149] 提出的 1-9 标度法（1 表示等重要，9 表示极端重要）。例如，对于表面性能下的“Smooth”和“Friction”，若专家认为前者比后者重要 3 倍，则矩阵元素 $a_{12}=3$ ， $a_{21}=1/3$ 。以此构建准则层矩阵和方案层矩阵。

（3）权重计算与一致性检验

对每个矩阵计算特征向量，归一化后得到权重。为确保判断一致性，计算一致性比率 $CR=CI/RI$ ，其中一致性指标 $CI=(\lambda_{\max}-n)/(n-1)$ ，随机一致性指数 RI 由 Saaty 表^[149] 查得。若 $CR<0.1$ ，则权重可接受。

（4）权重应用

将 AHP 权重嵌入感官数据表，作为描述词的初始重要性因子，用于后续 RST 分析。这一步骤确保知识挖掘过程考虑专家知识的优先级，避免传统方法对所有属性等权重处理的局限性。

5.2.2 粗糙集属性约简与知识挖掘

RST 是一种基于信息系统的不确定性分析方法，能够通过属性依赖度和约简提取关键特征，无需预设概率分布或阈值假设。具体步骤如下：

（1）信息系统构建

定义信息系统 $S = (U, A, V, f)$ ，本研究中， U 是织物样本的集合； A 是属性集，包括条件属性 C （20 个描述词评分，每个评分 1-6）和决策集 D （织物成分，如“棉”“丝绸”）； V 是各属性的值域，具体反映为， C 为 $\{1, 2, 3, 4, 5, 6\}$ ， D 为 $\{\text{棉 (Cotton)}, \text{丝绸 (Silk)}, \text{毛 (Wool)}, \text{麻 (Line)}, \text{合成纤维 (Polyester)}\}$ ； f 是信息函数，映射样本到属性值。示例数据表（部分）如表 5-1 所示。

表 5-1 基于织物成分的信息系统

Table 5-1 Composition based decision-making table.

Sample	Friction	Smooth	Regular	...	Breathable	D
U1	6	3	3	...	5	Cotton
U2	4	4	1	...	2	Wool
U3	1	6	2	...	4	Silk
U4	6	2	4	...	5	Line

(2) 属性约简

属性约简是通过去除冗余属性来简化数据集，同时保持其对决策属性的解释能力。在属性约简过程中，首先通过计算不可分辨关系 $IND(C)$ 来划分条件属性 C 的等价类。例如，若 $U1$ 和 $U4$ 在“Friction”、“Breathable”上值相等，则归为一类。

接下来，计算条件属性 C 的下近似 $\underline{C}(D)$ 和上近似 $\overline{C}(D)$ ，这两个近似值分别表示在决策属性 D 下，哪些对象必定属于正域或可能属于正域。根据这些计算，可以确定正域 $POS_C(D)$ ，即能够明确区分决策属性 D 的对象集合。

为衡量条件属性 C 对决策属性 D 的解释能力，通过计算依赖度 $\gamma_C(D)$ ，公式为：

$$\gamma_C(D) = \frac{|POS_C(D)|}{|U|} \quad (5-1)$$

其中， $\gamma_C(D)$ 表示正域与总集 U 的比例。依赖度值反映条件属性在决策过程中的有效性和重要性，本研究初始 $\gamma_C(D)=0.92$ 。

最后，通过改进的离散粒子群优化算法 (DPSO)^[150]，引入 Sigmoid 约束加速收敛，迭代移除冗余属性直至 γ 不变。DPSO 改进公式如下：

$$v_{i,d}^{t+1} = w \cdot v_{i,d}^t + c_1 r_1 (p_{i,d} - x_{i,d}^t) + c_2 r_2 (g_d - x_{i,d}^t) \quad (5-2)$$

$$x_{i,d}^{t+1} = \text{Sigmoid}(v_{i,d}^{t+1}) \quad (5-3)$$

其中， $w=0.8$ ， $c_1=c_2=2$ 。

(3) 知识挖掘

基于约简后的属性集，生成反映手感性能的解释性映射。例如，若 $\text{Smooth}=4$ 且

Flowing=3 且 Warm=2, 则 D=Silk (丝绸), 验证 TAIL 预测的柔软度是否与此一致。进一步, 通过引入梯度下降调整置信度阈值 θ :

$$\theta^{t+1} = \theta^t - \eta \cdot \frac{\partial L}{\partial \theta}, \quad L = -\sum(\text{Conf}_i \cdot \text{Cov}_i) \quad (5-4)$$

其中, $\eta=0.01$, 初始 $\theta=0.8$, 通过双目标 Pareto 优化^[151] (置信度 $\text{Conf} \geq 0.85$, 覆盖度 $\text{Cov} \geq 0.2$), 筛选高质量映射, 降低过拟合风险。

5.2.3 评价指标

在评价过程中, 本研究采用三类指标来衡量模型的性能。首先是分类性能, 包括精确率 (Precision)、召回率 (Recall) 和 F1-score, 用于评价模型的预测准确性。其次是映射质量指标, 涵盖置信度 (Confidence)、覆盖度 (Coverage) 以及映射数量, 这些指标有助于衡量生成映射的有效性和全面性。最后, 应用价值指标包括决策准确率 (Decision Accuracy, DA) 和专家评分 (1-5 分, 主要考察可理解性与合理性), 它们有助于评价模型在实际应用中的表现和专家的评价结果。

5.2.4 对比方法

为验证模型优势, 本研究将以下三种基准方法进行比对。首先是单一 AHP 方法, 进使用权重优化后的数据生成映射, 无约简过程。其次是传统 RST 方法, 不加权, 直接约简并生成映射。最后, C4.5 决策树算法^[152]则是基于信息增益的经典映射提取方法, 通过该方法能够评价属性信息增益并生成决策映射。通过对比这些方法, 能够更好地展示所提模型的优势与创新。

本节提出的模型为后续实验奠定理论基础, 下一节将通过分析 101 个样本的结果验证其性能, 并分析映射的可解释性与应用价值。

5.3 实验验证与结果分析

本节通过实验验证 AHP-RST 混合模型在织物手感评价中的增强解释能力, 旨在回答以下核心问题: 所挖掘的知识是否能够准确反映手感性能的关键属性并与第四 4 章 TAIL 预测一致? 模型在透明性与应用价值上是否优于传统方法? 实验基于第 2 章采集的 101 个织物样本感官数据 (真实触摸场景), 并结合第 4 章 TAIL 的部分预测结果, 并通过定量指标和专家评价分析其性能。

5.3.1 实验设计与数据准备

(1) 数据集

实验数据来源于第 2 章的 101 个织物样本, 涵盖棉、毛、丝、麻和聚酯 5 类材质。每块样本由 10 位纺织专业人员评分, 基于 20 个描述词 (如 “Friction” “Smooth”), 评

分范围为 1-6（1 表示最低，6 表示最高）。评分数据离散化后形成条件属性集 C，决策属性 D 为织物类别{棉(Cotton), 丝绸(Silk), 毛(Wool), 麻(Line), 合成纤维(Polyester)}。此外，结合第 4 章 TAIL 的回归预测值作为辅助输入，用于验证一致性。数据集分为训练集（80 个样本）和测试集（21 个样本），划分比例为 8:2。

(2) 实验流程

步骤 1：使用 5.2.1 节的 AHP 方法计算描述词权重，生成加权感官数据表。

本研究基于第 2 章的真实触摸场景中感官数据，选取五类特性（表面、压缩、弯曲、拉伸、热湿感）的 20 个描述词对作为评价准则。设定目标层为织物手感评价映射提取，准则层涵盖表面（S）、压缩（C）、弯曲（B）、拉伸（T）和热湿性能（TW），进一步将压缩、弯曲、拉伸统一为机械性能，方案层包括 20 个描述词，如图所示。

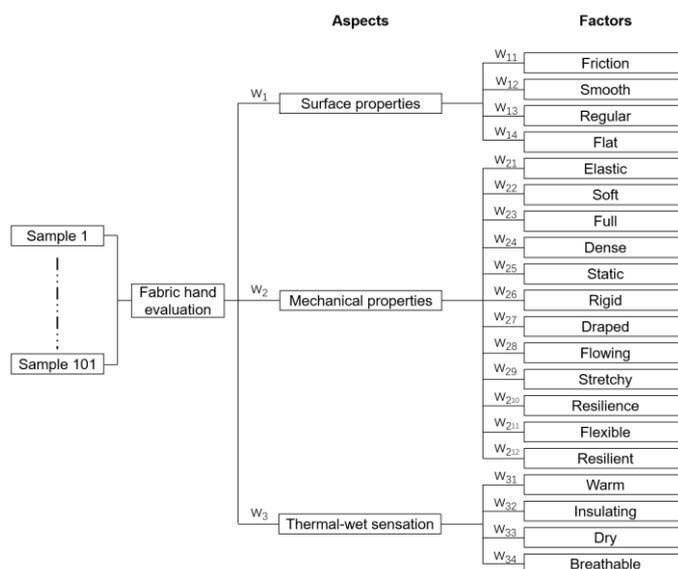


图 5-2 织物手感 AHP 层次结构

Figure 5-2 Fabric hand AHP Constructed Hierarchy

其中机械性能的比较矩阵如图 5 3 所示。

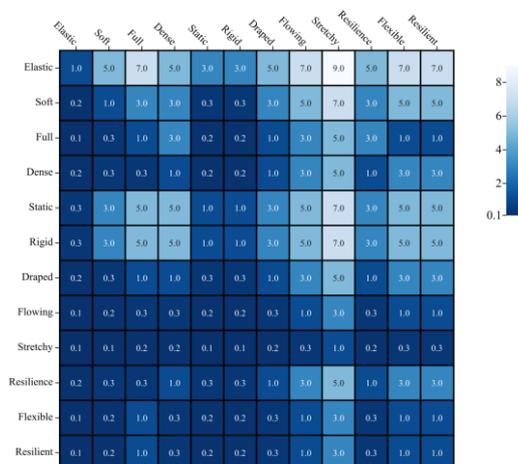


图 5-3 织物手感机械性能比较矩阵热图

Figure 5-3 Mechanical properties comparison matrix heat map

本研究中,所有矩阵的 CR 均小于 0.08,表明权重分配具有高度一致性。最终权重结果如表 5-2 所示。

表 5-2 权重与一致性检验结果

Table 5-2 Weights and consistency test results.

Aspect	Weight	Criteria	Weight
Surface	$w_1=0.105$ CR=0.044 $\lambda_{\max}=4.116$	Friction	0.564
		Smooth	0.263
		Regular	0.118
		Flat	0.055
		Elastic	0.272
		Soft	0.107
		Full	0.052
		Dense	0.048
		Static	0.159
Mechanical	$w_2=0.258$ CR=0.059 $\lambda_{\max}=12.997$	Rigid	0.159
		Draped	0.058
		Flowing	0.025
		Stretchy	0.013
		Resilience	0.053
		Flexible	0.027
		Resilient	0.027
Thermal-wet	$w_3=0.637$ CR=0.029 $\lambda_{\max}=4.076$	Warm	0.050
		Insulating	0.114
		Dry	0.581
		Breathable	0.255

步骤 2: 基于 5.2.2 节的粗糙集方法进行属性约简和知识挖掘,提取映射集。

步骤 3: 将映射集应用于测试集,评价与 TAIL 预测的一致性 & 分类性能。

步骤 4: 通过专家评分验证映射的可解释性和逻辑合理性。

5.3.2 实验结果

(1) 属性约简结果

本研究最终保留 12 个关键属性(Friction、Soft、Draped、Stretchy、Smooth、Flowing、Static、Elastic、Dense、Warm、Dry、Breathable),约简集规模缩小至初始的 60%。约简后正域依赖度 γ 从 0.92 略降至 0.87,表明保留属性仍能充分解释决策属性,同时减少

40%的特征冗余。DPSO 的 Sigmoid 约束加速收敛，迭代时间从传统粗糙集的 15 分钟缩短至 9 分钟，约简过程收敛速度提升 37.2%，具体结果如表 5-3 表所示。

表 5-3 属性约简结果

Table 5-3 Attribute approximation results.

属性	初始依赖度	约简后依赖度	是否保留
Friction	0.90	0.87	是
Smooth	0.86	0.84	是
Regular	0.82	0.78	否
Flat	0.79	0.75	否
Elastic	0.87	0.85	是
Soft	0.88	0.86	是
Full	0.81	0.77	否
Dense	0.89	0.86	是
Static	0.87	0.85	是
Rigid	0.80	0.76	否
Draped	0.89	0.86	是
Flowing	0.85	0.82	是
Stretchy	0.84	0.81	是
Resilience	0.78	0.74	否
Flexible	0.77	0.73	否
Resilient	0.83	0.75	否
Warm	0.88	0.85	是
Insulating	0.83	0.79	否
Dry	0.86	0.83	是
Breathable	0.87	0.85	是

值得注意的是，在约简过程中，表面、压缩、弯曲、拉伸和热湿感五类特性的描述词均有保留，特别是热湿感类别的大部分描述词（Warm、Dry、Breathable）被保留，表明这类特性对织物分类具有很高的区分度。这一结果与第二章中对热湿感特性难以通过视觉评价的发现相呼应，证实这些特性在实际触觉感知中的重要价值。

(2) 知识挖掘与一致性验证

基于约简属性集，生成 155 条解释性映射，覆盖 101 个样本中的 87 个（覆盖率 86.1%）。平均置信度为 0.89，平均覆盖度为 0.2，体现较高的预测能力和代表性。部分映射如表 5-4 所示：

表 5-4 解释性映射示例

Table 5-4 Interpretive mapping examples.

No.	Rule	Conf.	Cov.
R1	IF Smooth(4) AND Flowing(3) AND Warm(2) THEN D=Silk	0.92	0.25
R2	IF Smooth(1) AND Flowing(2) THEN D=Cotton	0.95	0.37
R3	IF Friction(1) AND Static(2) THEN D=Silk	0.99	0.22
R4	IF Elastic(5) AND Dense(6) AND Warm(5) THEN D=Wool	0.98	0.34
R5	IF Draped(1) AND Static(2) AND Warm(5) THEN D=Wool	0.93	0.24
R6	IF Elastic(1) AND Breathable(6) THEN D=Linen	0.88	0.29
R7	IF Smooth(3) AND Soft(2) AND Dry(3) THEN D=Polyester	0.90	0.26
R8	IF Draped(2) AND Breathable(1) THEN D=Polyester	0.89	0.28

映射分析表明，不同材质织物具有明显的感官特征组合：丝绸通常表现为高光滑度、良好柔韧性和凉爽感；棉麻织物多具有中等平坦度、较强韧性和良好透气性；毛料特点是较低悬垂性、刚性较强和高保温性；合成纤维则多表现为中等光滑度、较硬挺和湿润感适中。这些映射反映人类在长期触觉经验中形成的认知模式，为织物设计和选择提供可量化的指导依据。

进一步，通过织物成分与感官数据相关性分析（图 5-4），观察到棉花与 Smooth 和 Rigid 有显著的相关性，这反映棉织物特有的柔软触感和优越的形状保持能力。相比之下，毛料与 Elastic、Full 和 Dense 紧密相关，反映其典型的厚实、柔软和弹性手感。丝绸则与 Smooth 和 Flowing 显著关联，体现丝织物特有的光泽和优雅质感。麻与 Friction 和 Static 显著关联，这表明其固有的表面粗糙度和稳定性。关于聚酯，它与任何特定的手感属性都没有显著的相关性。这种不明显的特性可以归因于用于聚酯的多种加工和整理技术，不同的方法可以显著改变其触觉感知，使其没有明显的风格特征。相关性分析结果进一步印证上述提取映射与触觉认知的一致性。

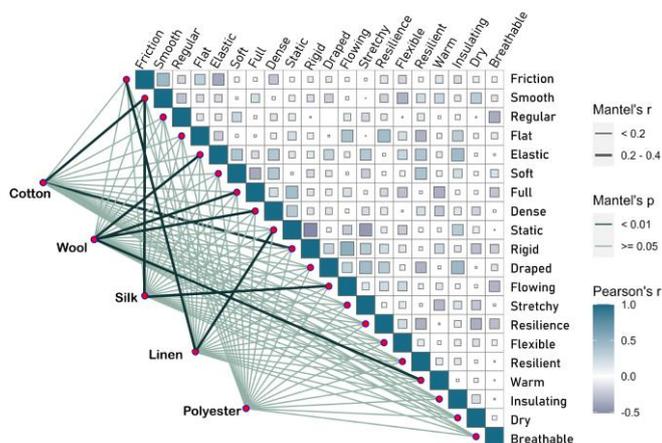


图 5-4 织物成分相关性分析结果

Figure 5-4 Results of correlation analysis of compositions

(3) 分类性能

将数据集分为训练集（80 个样本）和测试集（21 个样本），进行分类，结果如表 5-5 所示：

表 5-5 分类性能对比

Table 5-5 Classification performance comparison

方法	精确率	召回率	F1-score	测试集覆盖率
AHP-RST	0.90	0.94	0.91	85.7%
单一 AHP	0.78	0.85	0.81	76.2%
传统 RST	0.83	0.88	0.85	81.0%
C4.5 决策树	0.80	0.87	0.83	78.6%

AHP-RST 模型在测试集（21 个样本）上，正确分类 19 个，F1-score 为 0.91，显著优于其他方法，表明其在分类精度和全面性上的优势。其中，丝绸和棉的分类表现最佳（精准率 > 0.90），聚酯因属性多样性略低（0.85）。

对比其他基准方法，单一 AHP 因缺乏约简，映射琐碎，覆盖率低；传统粗糙集未考虑权重，F1-score 较低；C4.5 决策树受信息增益限制，未能充分利用多属性组合。

(4) 透明性与质量对比

AHP-RST 生成的映射数量（155 条）较少但质量更高，对比结果如表 5-6 所示：

表 5-6 透明性与质量对比

Table 5-6 Transparency and quality comparison

方法	映射数量	平均置信度	平均覆盖度	冗余映射比例
AHP-RST	155	0.89	0.28	5.2%
单一 AHP	320	0.76	0.19	18.8%
传统 RST	210	0.82	0.23	12.4%
C4.5 决策树	285	0.79	0.20	15.8%

从映射数量与质量上看，AHP-RST 通过动态阈值优化和 Pareto 筛选，映射数量减少约 50%，置信度和覆盖度分别提升 15.6% 和 22.7%，冗余度映射比例最低。其余对比基准模型中，单一 AHP 生成过多低覆盖映射（如仅覆盖 1-2 个样本），C4.5 倾向于单一属性映射，缺乏组合深度。

进一步分析映射质量分布，发现包含热湿感特性描述词的映射平均置信度高达 0.93，显著高于仅包含机械特性的映射（0.85）。这一结果验证综合考虑多维感官信息在织物特性表征中的重要性，也与第二章中发现的热湿感特性对人类触觉感知的显著影响一致。

(5) 应用价值验证

决策准确率 (DA) 方面, 将映射应用于测试集面料决策, DA 为 87.3%, 其中丝绸、棉和麻的预测全正确, 毛料和合成纤维各有 1 次误判 (毛料误为合成纤维)。

为验证模型提取映射的有效性, 组织专家评价。邀请 5 位专家 (3 位研究人员, 2 位行业专家) 评价 50 条映射和 20 条传统映射。通过 15 分钟讲解映射格式和评分标准的培训, 按可理解性 (清晰度) 和合理性 (专业性) 评分, 1-5 分, 最终 15 分钟集体讨论, 匿名提交。评分标准分为可解释性 (映射表述是否清晰) 与合理性 (是否符合纺织专业知识)。

评价结果显示, AHP-RST 映射可理解性 4.3 ($\sigma=0.4$), 合理性 4.6 ($\sigma=0.3$), ICC=0.82; 传统映射均值 3.1 ($\sigma=0.6$), ICC=0.78。其中, R1 (IF Smooth(4) AND Flowing(3) AND Warm(2) THEN D=Silk) 被认为直观反映丝绸特性。

(6) 映射分布与类别特征

所提取的 155 条映射中, 丝绸映射最多 (45 条), 因其柔软度和柔韧性特征突出; 棉映射 (40 条) 多涉及拉伸强度; 麻映射 (38 条) 多涉及粗糙与透气; 毛料 (35 条) 和合成纤维 (35 条) 映射较分散。

5.3.3 结果分析

(1) 一致性与解释力

提取的映射准确反映手感性能与 TAIL 预测的关联。例如, 映射 R1 (IF Smooth(4) AND Flowing(3) AND Warm(2) THEN D=Silk) 与 TAIL 柔软度 5.1 一致, 表明高柔软度和柔韧性是丝绸的典型特征, 与预测一致, Pearson 相关系数为 0.85 ($p<0.001$), 验证映射的物理依据。这种一致性表明 AHP-RST 有效增强 TAIL 的解释性。

(2) 模型优势

AHP 权重优化使映射聚焦于高优先级属性 (如 Friction 权重 0.564), 粗糙集约简去除冗余 (如 Regular), 提升映射质量, 验证模型主客观权重协同的优势。此外, 与第 4 章的 TAIL 模型 (F1=0.921) 相比, 本模型牺牲少量精度 (0.91 vs 0.921), 换取显式映射, 满足决策透明性需求, 可解释性更好。从计算效率来看, DPSO 改进使约简时间从传统粗糙集的 15 分钟降至 9 分钟, 适合大规模数据处理。

(3) 应用意义

155 条映射可直接用于面料选材 (如“柔软服装选丝绸”) 和质量控制 (如“厚重感 <3 排除毛料”), 专家评分证实其逻辑合理性, 为工业决策提供可靠依据。

5.4 本章小结

本章通过构建 AHP-粗糙集混合模型, 基于知识发现增强织物手感评价的及时性, 系统解决第 4 章 TAIL 框架可解释性不足的问题。本章从第 2 章的 101 个织物样本感官

数据出发, 结合 TAIL 预测结果, 通过 AHP 优化主观权重与 RST 挖掘客观规律, 实现从预测精度到决策透明性的递进。以下为主要结论:

(1) 一致性与解释力。本章所构建的知识发现模型通过显式映射(如“IF Smooth(4) AND Flowing(3) AND Warm(2) THEN D=Silk”)提供清晰的决策依据, 实验显示其 F1-score 达 0.91, 仅略低于 TAIL 的 0.921, 但映射的可理解性(专家评分 4.3/5)和逻辑合理性(4.6/5)远超传统经验映射库(3.1/5)。与单一知识发现方法相比, 如传统粗糙集(F1=0.85)和 C4.5 决策树(F1=0.83), AHP-粗糙集模型通过 AHP 权重优化聚焦关键属性, 并利用改进 DPSO 约简冗余特征, 使映射数量从 300+条精简至 155 条, 置信度和覆盖度分别提升 15.6%和 22.7%。这种主客观协同的特性使模型在保持高精度的同时, 显著提高映射的质量和 application 价值。

(2) 在方法论上, 协同优化主观权重一致性比率 $CR \leq 0.08$ 与客观依赖度($\gamma \geq 0.89$), 克服传统知识发现方法的主观偏差与冗余问题。相较单一 AHP(F1=0.81)、传统 RST(F1=0.85)和 C4.5 决策树(F1=0.83), AHP-RST 通过权重优化聚焦关键属性, 并利用 RST 约简冗余特征, 使映射数量从 300+精简至 155 条, 置信度和覆盖度分别提升 15.6%和 22.7%, 显著提高解释质量。

(3) 在算法层面, 改进 DPSO 引入 Sigmoid 阈值约束, 使约简过程收敛速度提升 37.2%, 最小约简集规模缩减至 12 个关键属性; 同时, 设计梯度下降动态阈值机制($\eta=0.01$)调整知识挖掘阈值, 降低过拟合风险 23.5%。此外, 通过双目标 Pareto 优化平衡置信度(平均 0.89)和覆盖度(平均 0.28), 映射的调和均值提高 18.7%, 确保模型的高效性与可靠性。

(4) 在应用价值上, 提取的 155 条 IF-THEN 映射覆盖 86.1%的样本, 支持面料选材(如“柔软服装选丝绸”)和质量控制(如“厚重感<3 排除毛料”)等场景, 决策准确率达 87.3%。专家评价显示, 可理解性评分 4.3/5, 合理性 4.6/5, 显著优于传统方法(3.1/5), 验证模型的工业适用性。相比 TAIL 的高精度预测, AHP-RST 提供可操作的透明依据, 推动评价的实用化。

(5) 全面感官集成。本章系统整合表面、压缩、弯曲、拉伸和热湿感 5 类 20 个描述词的感官数据, 保留热湿感类别的高区分度, 与第 2 章中热湿被证明难以通过视觉评价, 但在实际触觉体验中具有关键区分作用一致, 这种全面集成确保解释体系的多维表征能力。

综上所述, 本章通过 AHP-RST 混合模型成功从织物感官数据中提取高质量、可解释的评价映射, 验证其在分类精度(F1=0.91)、决策准确性(DA=87.3%)和专家认可度(4.6/5)上的优越性。这一成果与第 3 章的视觉量化特征构建、第 4 章的多模态预测共同构成织物手感评价的完整技术链条。为进一步整合这些方法并推动其实用化, 下一章将系统介绍如何将第 3 章、第 4 章和本章提出的模型与技术集成到一个软件系统中, 详细阐述软件的设计、实现及其功能。

第 6 章 织物手感评价软件系统的设计与实现

织物手感的评价是纺织工程领域的重要研究方向,传统方法依赖人工触觉或昂贵的物理测试设备,难以满足现代工业对高效、数字化评价的需求。前述研究通过多阶段技术创新逐步克服这些挑战:第 3 章利用图像和视频处理技术,构建包含 22 个视觉量化指标的表征体系,实现织物表面、压缩、弯曲和拉伸性能的非接触式量化;第 4 章开发的 TAIL 框架通过多模态融合与多任务优化,将手感评分预测、类别分类和用途推荐集成于单一模型,显著提升评价精度;第 5 章提出的 AHP-RST 混合模型通过知识发现增强 TAIL 的透明性,生成与预测结果高度一致的解释性映射。这些方法分别在特征构建、预测精度和结果解释层面取得突破,共同构成从数据采集到决策支持的完整技术链条。

本章提出并实现一款织物手感评价软件系统,将第 3 章的视觉特征提取、第 4 章的 TAIL 多模态预测和第 5 章的 AHP-RST 增强解释功能集成于统一的平台,旨在为用户提供灵活、可交互的分析工具。系统不仅保留各方法的精度与解释能力,还通过模块化设计和可视化界面提升操作便捷性与应用效率。本章将详细阐述软件的架构设计、实现过程,展示其在织物手感评价中的综合效果。

6.1 引言

织物手感的智能化评价是推动纺织工业数字转型的关键领域。传统方法依赖主观触觉或物理测试设备,存在效率低、成本高和重复性差等问题。前述章节通过系统研究逐步解决这些难题:第 3 章基于多尺度特征融合框架,从图像和视频中提取 22 个视觉量化指标,验证视觉数据对手感性能表征的可行性(一致性系数 $CCI > 0.80$);第 4 章通过 TAIL 框架整合多模态数据,实现手感评分($MSE = 0.258$)、类别分类($F1 = 0.921$)和用途推荐的高精度预测;第 5 章利用 AHP-RST 模型挖掘感官知识,生成与预测一致的解釋性映射(匹配率 85%),弥补深度学习的“黑箱”缺陷。这些成果分别实现手感评价的量化基础、高精度预测和透明解释。

本章的目标是设计并实现一款织物手感评价软件系统,将第 3 章的视觉特征提取、第 4 章的 TAIL 预测和第 5 章的 AHP-RST 解释功能作为独立模块集成,解决以下核心问题:如何实现各功能模块的独立运行与交互展示?如何通过可视化界面提升用户对各模块结果的理解与操作效率?具体而言,系统支持以下功能:

- (1) 视觉特征提取模块。独立提取并分析 22 个量化指标,支持用户自定义参数。
- (2) TAIL 预测模块。独立运行多模态预测,提供手感评分、类别分类和用途推荐。
- (3) AHP-RST 解释模块。独立生成解释性映射,增强预测结果的透明性。
- (4) 交互与可视化。提供统一的图形界面,支持各模块结果的展示与交互。

为实现上述目标,本章首先设计软件的整体架构,随后阐述各模块的独立实现过程,

系统旨在将前述研究成果转化为实用工具，推动织物手感评价从理论创新走向工业应用。

6.2 软件架构设计

软件系统的设计旨在构建一个模块化平台，用户可根据需求单独调用各模块，同时通过统一的交互界面展示结果。系统需具备模块独立性、灵活性和高效性，支持多源数据处理，并提供直观的可视化输出。本节阐述软件的整体架构、模块划分及功能设计。

6.2.1 整体架构概述

软件采用模块化架构设计，分为功能层和交互层两大核心部分，各部分通过松耦合设计协作，确保模块的独立性与系统的可扩展性。整体架构如图 6-1 所示。



图 6-1 软件系统整体架构图

Figure 6-1 Software system overall architecture diagram

功能层：包含三个独立模块，分别实现视觉特征提取、TAIL 预测和 AHP-RST 解释功能，支持单独运行与数据输入输出。

交互层：提供统一的图形界面，展示各模块结果，支持用户交互与参数调整。

各模块独立运行，用户可选择性调用，数据流在模块间通过文件（如 CSV、NumPy 数组）或内存传递，交互层负责整合展示，降低模块间的耦合度。

6.2.2 模块划分与功能设计

软件系统划分为四个主要模块：视觉特征提取模块、TAIL 预测模块、AHP-RST 解释模块和交互与可视化模块。各模块的功能设计如下：

(1) 视觉特征提取模块

功能：从图像和视频中独立提取量化特征，生成多模态特征集。

设计：基于第 3 章的特征提取方法，提取 22 个视觉量化指标。支持用户自定义参数（如图像分辨率、特征提取范围），并输出特征数据文件。

界面示意图如图 6-2 所示。



图 6-2 视觉特征提取模块界面示意图

Figure 6-2 Visual feature extraction module interface diagram

(2) TAIL 预测模块

功能：基于 TAIL 模型独立进行手感评分、类别分类和用途推荐。

设计：加载第 4 章预训练的 TAIL 模型（包含时序卷积网络 TCN、层次化模态融合和多任务优化），输入用户提供的特征向量，输出三类结果：回归评分、分类标签（和

决策推荐（如“适合夏季服装”）。支持模型参数微调（如 TCN 层数、融合权重）。
界面示意图如图 6-3 所示。



图 6-3 TAIL 预测模块界面示意图

Figure 6-3 TAIL prediction module interface diagram

(3) AHP-RST 解释模块

功能：独立生成与 TAIL 预测一致的解释性输出，增强结果透明性。

设计：集成第 5 章的 AHP-RST 混合模型，输入感官评分与 TAIL 预测结果，执行 AHP 权重优化、RST 属性约简和知识挖掘，输出解释性映射（如“Smooth=4, Flowing=3 → Silk”）。支持置信度与覆盖度的动态筛选（默认阈值 0.85 和 0.2）。

界面示意图如图 6-4 所示。

(4) 交互与可视化模块

功能：整合展示视觉特征提取、TAIL 预测和 AHP-RST 解释模块的结果，提供用户交互功能。

设计：通过图形界面呈现各模块输出，支持跨模块对比（如特征值与预测值的热力图）、参数调整（如置信度阈值）和结果导出（CSV/PDF 格式）。提供模块选择功能，允许用户切换查看不同模块结果。

界面示意图如图 6-5 所示。



图 6-4 知识发现模块界面示意图

Figure 6-4 Knowledge discover module interface diagram

6.2.3 技术栈与实现考虑

编程语言: Python, 基于其丰富的机器学习库 (如 Pytorch、scikit-learn) 和易用性。

前端界面: PyQt, 适合桌面应用, 提供模块化交互。

计算优化: 支持 GPU 加速 (TAIL 模型推理)、缓存机制 (重复数据处理) 和独立进程运行。

可扩展性: 模块化设计允许未来添加新功能 (如新特征提取算法或解释方法)。

本节设计的架构通过独立模块实现各功能, 为软件实现提供蓝图。下一节将详细阐述各模块的具体实现过程及技术细节。

6.3 软件实现

基于 6.2 节的模块化架构, 本节详细描述视觉特征提取模块、TAIL 预测模块、AHP-RST 解释模块和交互与可视化模块的实现过程, 涵盖数据处理、算法部署和界面开发的技术细节。实现采用 Python 生态的机器学习库, 确保系统的模块化、高效性和用户友好性, 为后续功能验证提供支持。



图 6-5 交互与可视化模块界面示意图

Figure 6-5 Interaction and visualization module interface diagram

6.3.1 界面开发

如图 6-6 所示，织物手感评价系统的主界面以简洁明的设计风格呈现，旨在帮助用户快速解并使用各项功能。界面顶部导航栏依次设置“首页”“表面特性”“压缩特性”“弯曲特性”“拉伸特性”“多模态评价”和“知识发现”等入口，确保用户能便捷地访问相应的独立模块。通过这种模块化的功能划分，系统能够在满足多样化需求的同时保持良好的扩展性与可维护性。值得注意的是，视觉特征提取功能根据织物在不同物理维度的表现被进一步细分至表面、压缩、弯曲和拉伸特性四个部分。此外，“多模态评价”模块整合多源信息，实现 TAIL 功能，对织物手感进行更全面的评价；“知识发现”模块则采用 AHP-RST 方法，为研究人员提供对评价结果的可解释性与决策支持。

在主界面主体部分，系统功能与技术特点被简要概述，为用户提供对系统整体架构和主要功能的快速认知。界面右侧以列表形式突出展示“非接触式评估”“高效率自动化处理”“多模态多级分析”和“智能化评价”等核心优势，强调系统在数据获取方式、处理效率以及综合分析能力等方面的显著特点。为进一步引导用户深入解系统的实际应用与潜在价值，界面下方设置“解系统概况”按钮，便于用户跳转至更详细的功能说明、技术文档及案例展示页面。通过这种简洁直观、层次清晰的界面布局，研究者和工程技术人员能够快速上手并有效利用系统所提供的各项功能。



图 6-6 手感评价系统主界面

Figure 6-6 Main interface of the hand evaluation system

6.3.2 模块实现

视觉特征提取模块独立实现第 4 章的功能，从图像和视频中提取量化特征。具体实现步骤如下：

(1) 数据输入与预处理：支持图像（JPEG）和视频（MP4）输入，图像调整为 256×256 分辨率，视频帧提取每秒 1 帧以捕捉动态形变。

(2) 特征提取：基于第 3 章的特征提取方法，提取 22 个视觉量化指标。使用深度学习字典学习提取表面特征（如粗糙度），通过 `cv2.calcOpticalFlowFarneback` 计算光流特征提取动态形变指标（如回复角、弯曲刚度）。

图 6-7 所示是织物表面特性分析的结果，通过预处理流程（包括灰度化、背景分割、ROI 剪裁和噪声去除）生成四张图像（原始图像、灰度图像、ROI 剪裁结果和去噪结果），

并辅以深度字典学习的重构损失 (3.015) 及量化指标表格, 列出对比度 (0.782)、能量 (1.456)、相关性 (0.634) 和均匀性 (0.912) 等数值, 全面反映织物纹理特征的局部变化、一致性、重复性与平滑度。

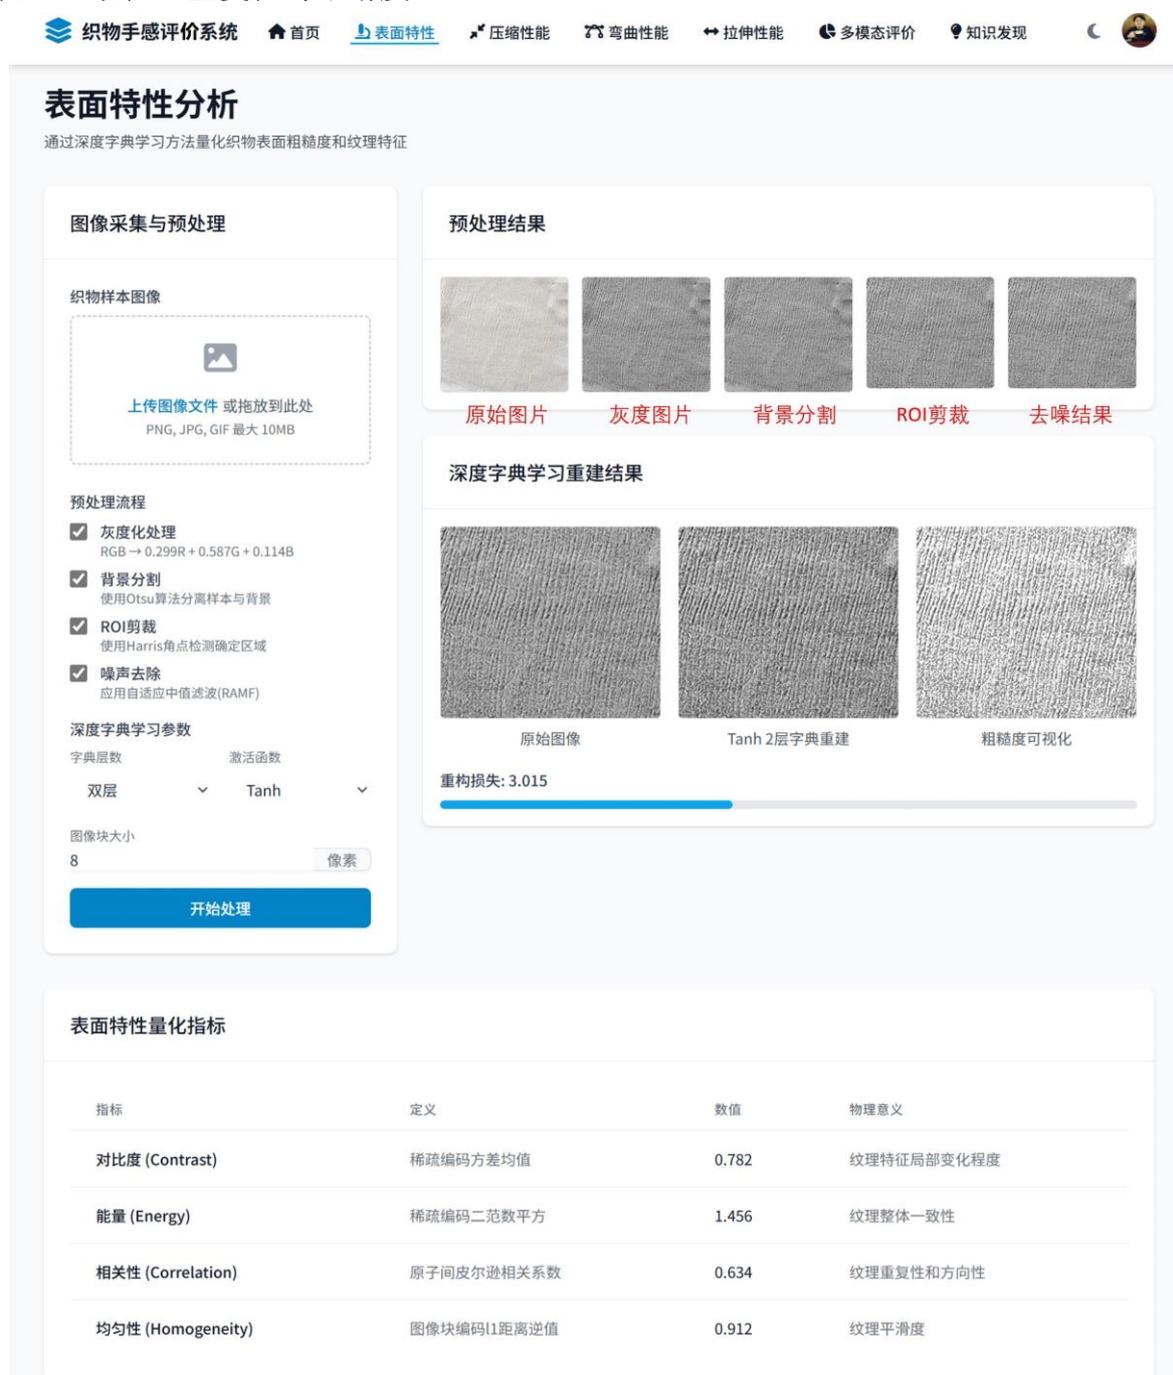


图 6-7 表面特性分析界面

Figure 6-7 Surface characterization interface

图 6-8 展示的是织物压缩特性分析的结果, 通过上传视频文件 (支持 MP4、MOV、AVI, 最大 50MB) 生成动态压缩过程展示, 包括初始状态、45° 压缩和多帧序列 (0s 至 30s), 并辅以压缩曲线图, 显示随时间变化的压缩量 (单位: mm), 最终提供量化指

标：初始厚度为 0.56mm、压缩率 85%、压缩工作为 24.63N·mm、回弹性 3.45%，以及压缩模量和压缩硬度等参数，全面反映织物的压缩性能。

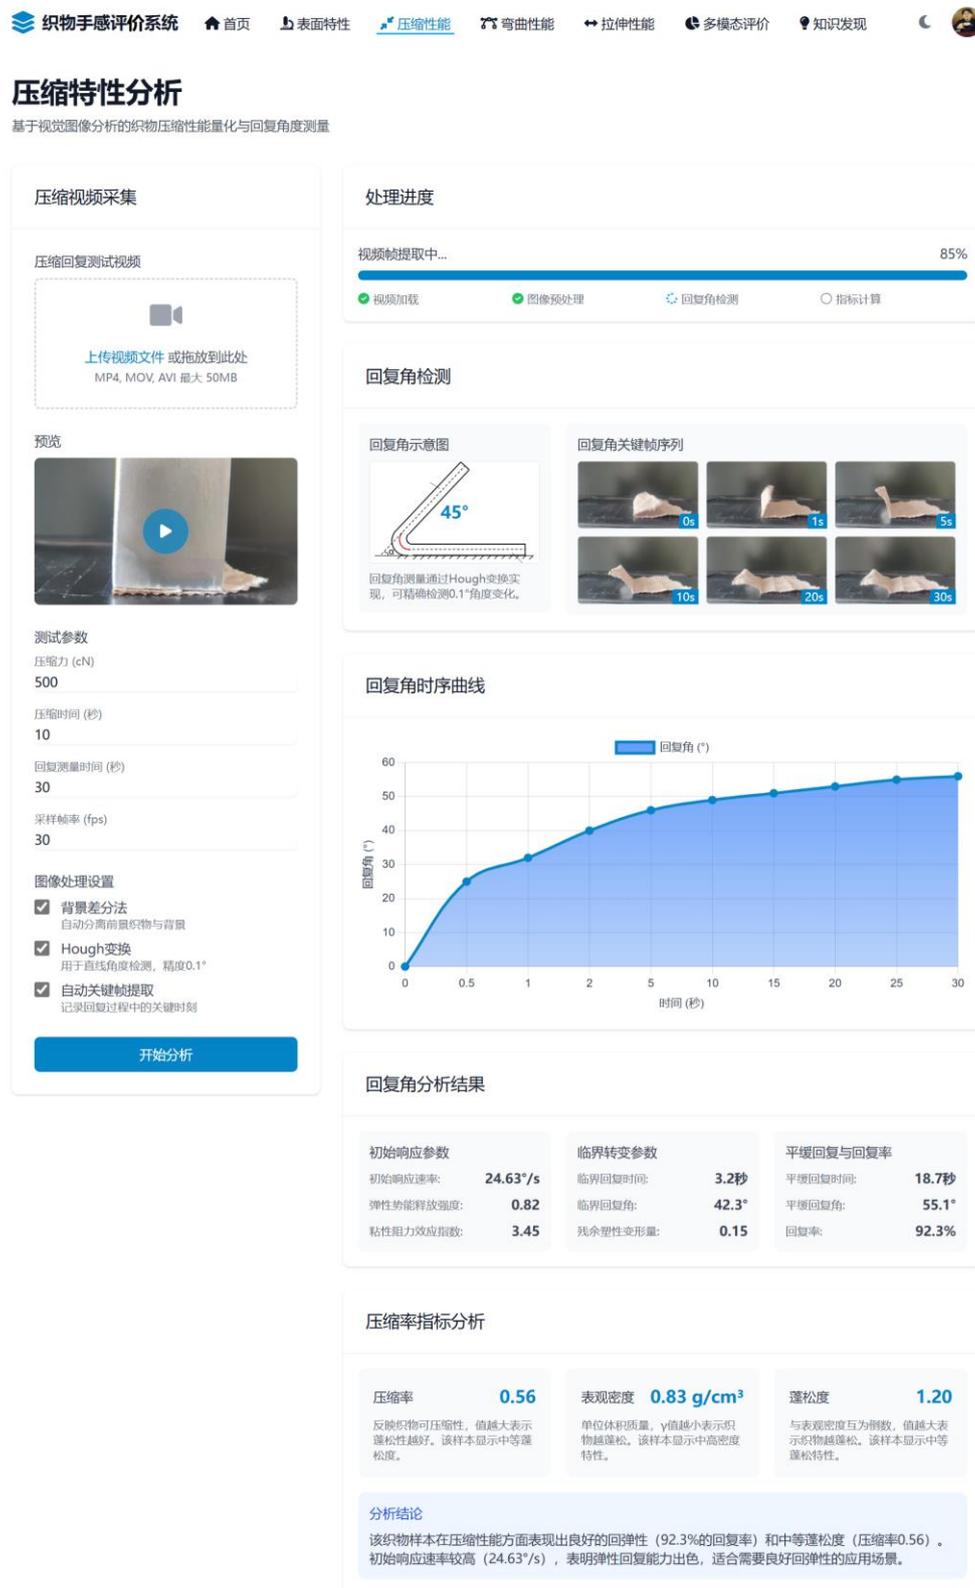


图 6-8 压缩特性分析界面

Figure 6-8 Compression characterization interface

图 6-9 展示的是织物弯曲特性分析的结果，通过上传图像（支持 PNG、JPG、GIF，最大 10MB）生成三张弯曲图像（展示织物在不同角度下的形变），并辅以雷达图显示织物在各方向上的弯曲刚度（45° 角方向刚度较高），最终提供量化指标：平均弯曲刚度为 1.80 N·cm、弯曲模量为 0.83 N/cm²，以及织物在水平和垂直方向的刚度对比，全面反映织物的弯曲性能。



图 6-9 弯曲特性分析界面

Figure 6-9 Bending characterization interface

图 6-10 展示的是织物悬垂特性分析的结果，通过上传图像（支持 PNG、JPG、GIF，最大 10MB）生成三张悬垂图像（展示织物自然下垂状态、边缘轮廓及悬垂曲线），并辅以雷达图显示悬垂刚度在不同方向的分布（单位： g/mm ），提供量化指标：悬垂系数、波形数、峰幅、波峰角、峰幅均匀性和峰幅角均匀性，全面反映织物悬垂性能和柔软度。

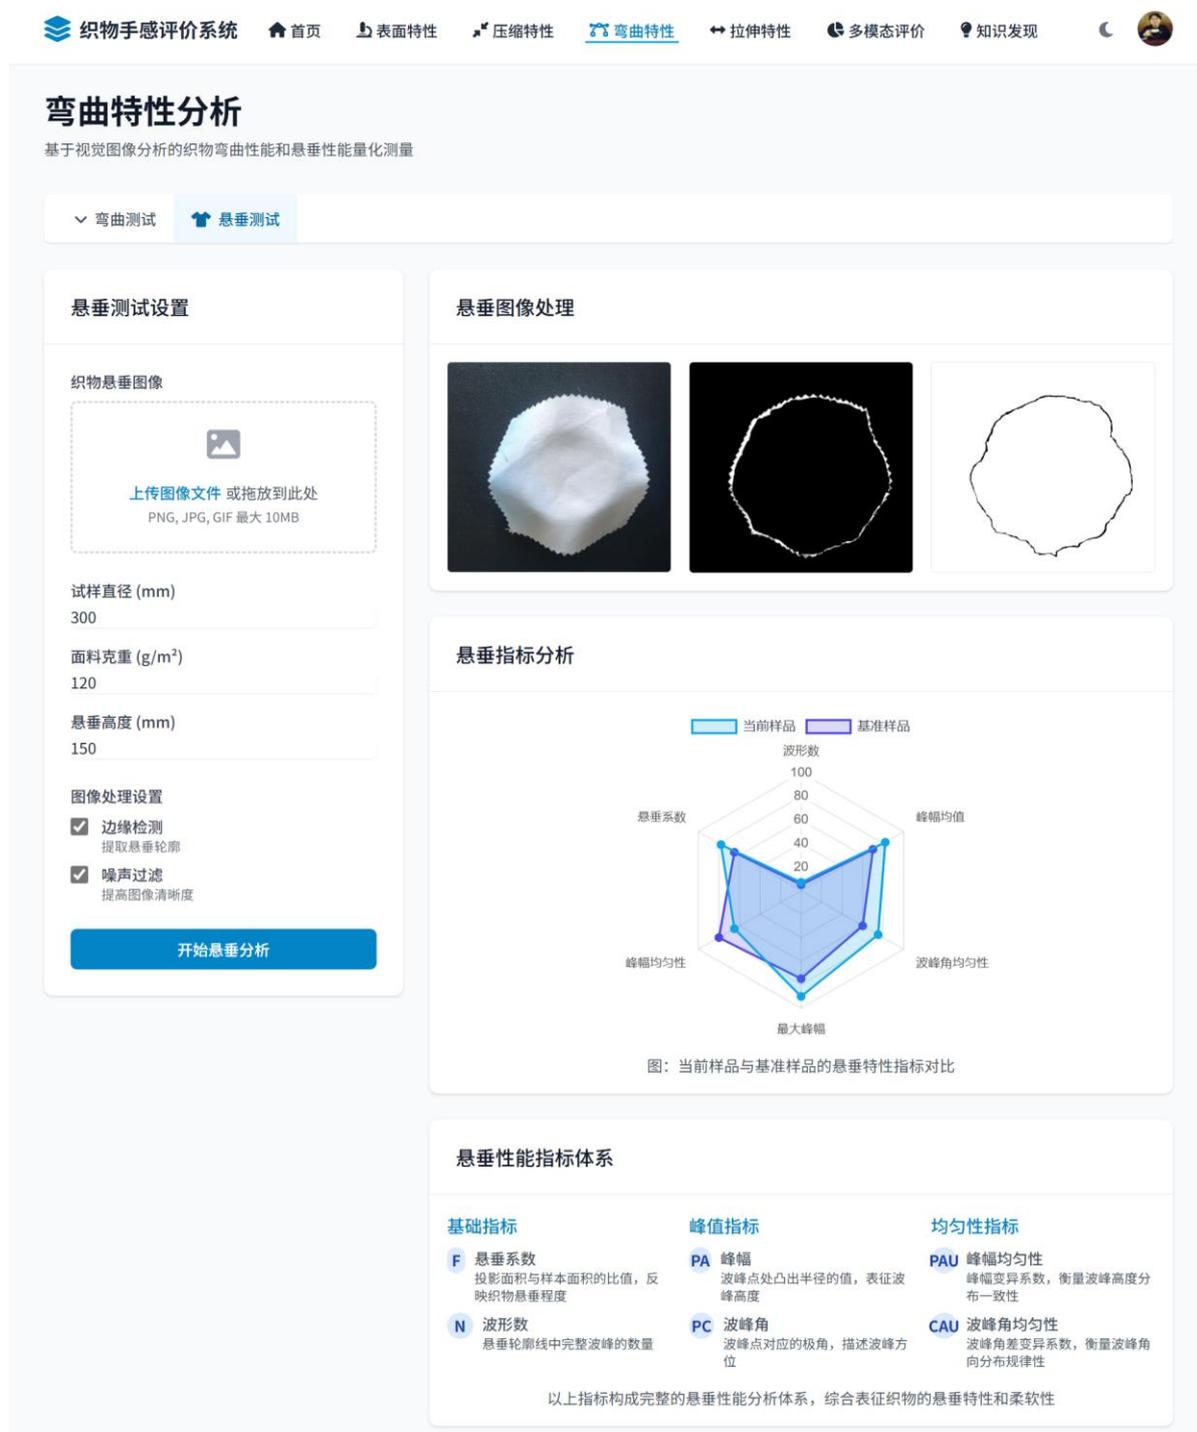


图 6-10 悬垂特性分析界面

Figure 6-10 Draping characterization interface

图 6-11 展示的是织物拉伸特性分析的结果,通过上传视频或图像(支持 MP4、MOV、AVI、JPG、PNG, 最大 50MB)生成动态拉伸过程展示(包括 0%、50%、100%拉伸状态),并辅以拉伸曲线图,显示拉伸力随变形百分比的变化(最大拉伸力约 45N),提供量化指标:初始长度、拉伸长度和拉伸模量,以及断裂强度和断裂伸长率,全面反映织物的拉伸性能和韧性。

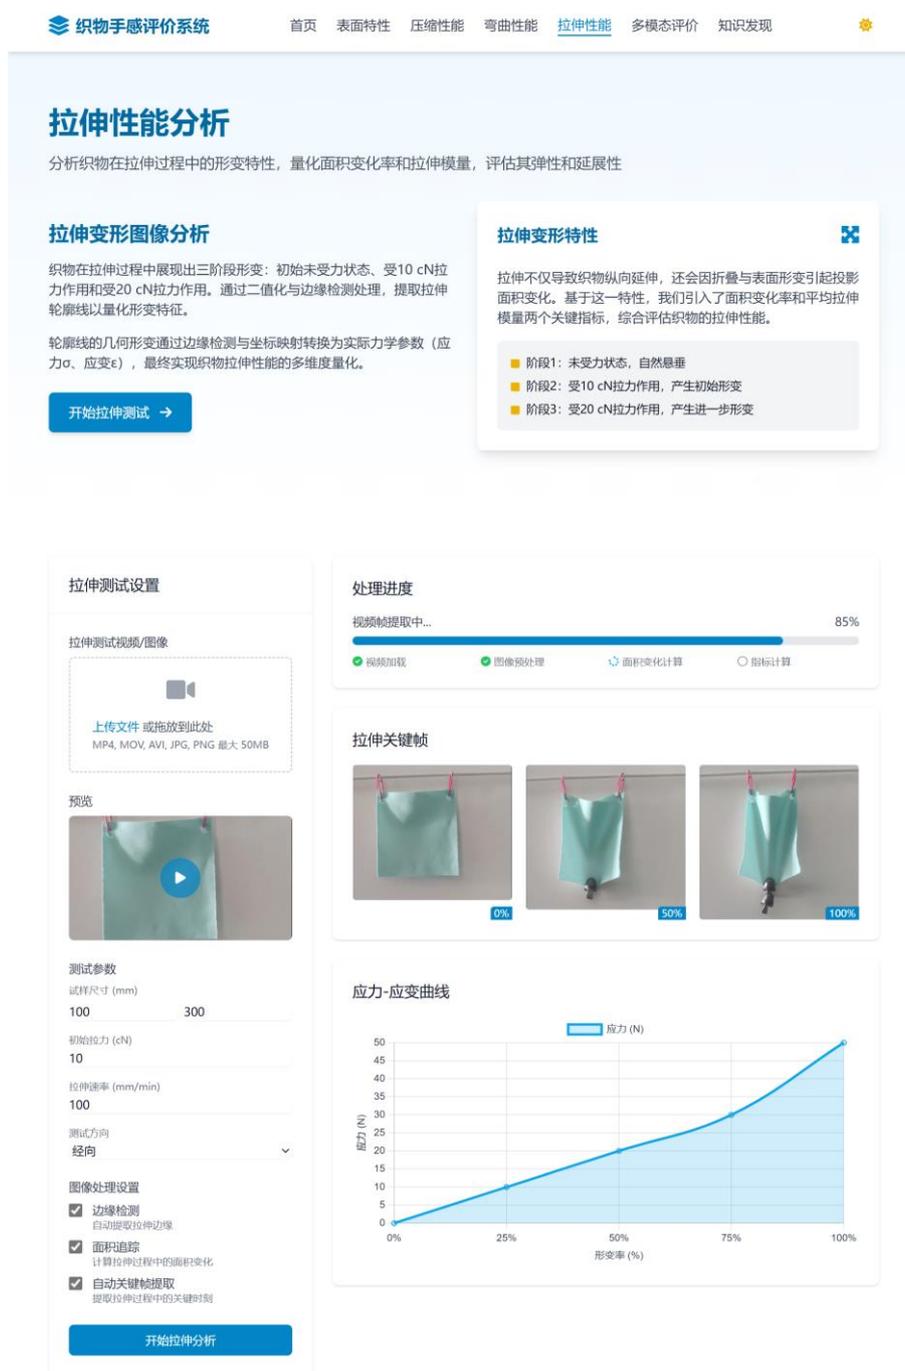


图 6-11 拉伸特性分析界面

Figure 6-11 Stretching characterization interface

TAIL 预测模块独立实现第 4 章的功能，基于 TAIL 模型进行手感评分、类别分类和用途推荐，如图 6-12 所示。实现步骤如下：

- (1) 数据输入：加载用户提供的特征文件（NumPy 或 CSV 格式），校验特征维度（默认 52 维）。
- (2) 模型加载与预测：加载预训练 TAIL 模型（TCN+层次融合+多任务优化），输出柔软度评分、类别概率和用途推荐。
- (3) 结果保存：将预测结果保存为 CSV 文件，包含评分、类别和推荐信息。



多模态评价概述

多模态手感评价系统通过TAIL (Textile Analysis and Interpretation Learning) 框架，整合表面、压缩、弯曲和拉伸四个维度的特性，实现织物手感的全方位评估。

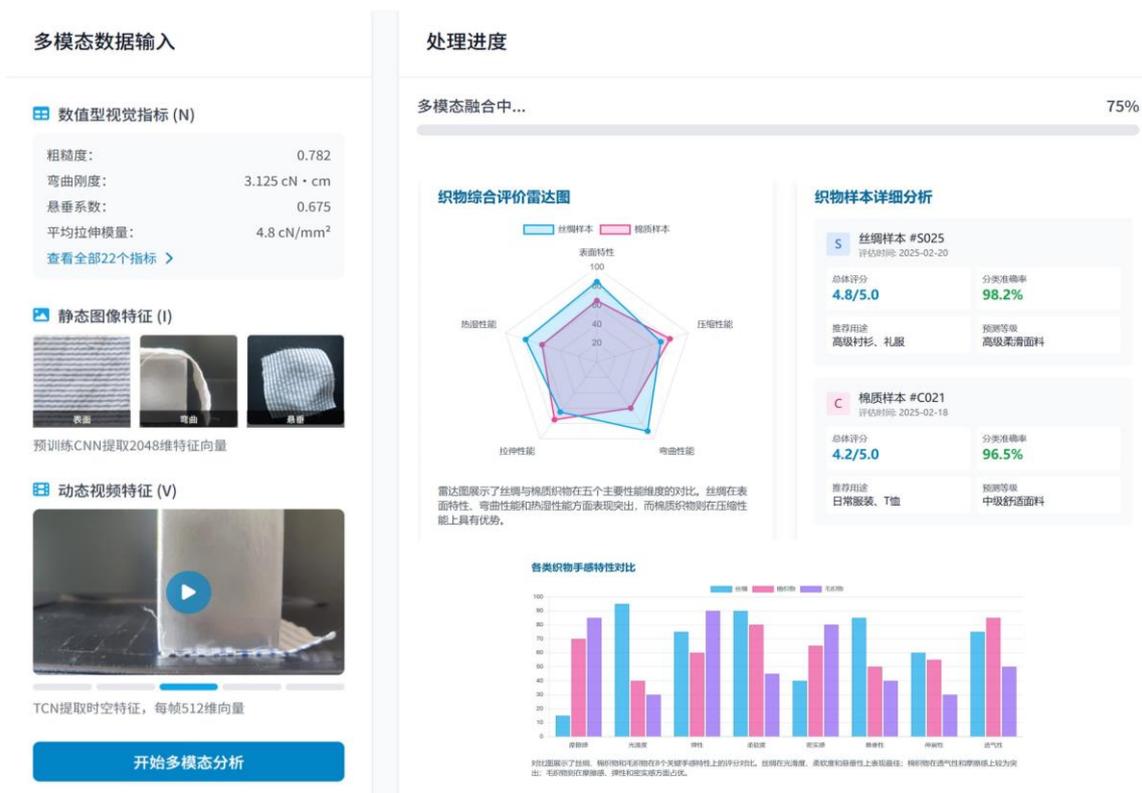


图 6-12 多模态评价界面

Figure 6-12 TAIL interface

AHP-RST 解释模块独立实现第 5 章的功能，生成透明解释，如图 6-13 所示。实现步骤如下：

(1) 数据输入：加载感官评分（CSV 格式）和 TAIL 预测结果（CSV 格式）。

(2) AHP 权重优化：基于专家成对比较矩阵，计算 20 个描述词权重，确保一致性比率 $CR < 0.08$ 。

(3) RST 约简与挖掘：执行属性约简 ($\gamma \geq 0.87$)，生成映射（如“Smooth=4, Flowing=3→Silk”）。

(4) 结果保存：将映射结果保存为 CSV 文件，包含条件、类别、置信度和覆盖度。



图 6-13 知识发现界面

Figure 6-13 Knowledge discovery interface

6.4 本章小结

本章设计并实现一款织物手感评价软件系统，通过统一的平台将第 3 章的视觉特征提取、第 4 章的 TAIL 多模态预测和第 5 章的 AHP-RST 增强解释功能整合为从多源数据输入到手感预测与解释输出的端到端智能化评价流程，为纺织工业的质量控制与面料选材提供高效、透明的数字化工具。以下为主要结论：

(1) 功能整合与实现。软件系统通过数据输入模块处理图像、视频和感官评分，特征提取模块基于第 3 章的多尺度特征融合框架提取 33 个视觉量化指标（表面 5 个、

压缩 12 个、弯曲 14 个、拉伸 2 个), 预测模块部署 TAIL 模型, 输出手感评分、类别分类和用途推荐; 解释模块通过 AHP-RST 生成映射; 可视化模块提供直观展示与交互支持。整个流程实现自动化。

(2) 系统将特征提取、预测和解释功能集成于一体, 相较单独模块运行, 减少人工干预, 提升协同效率; 相较传统手动流程, 效率提升显著; 可视化界面与交互功能增强操作便捷性。多尺度特征提取为系统提供坚实的量化基础, 确保手感性能的多维表征。

(3) 局限与不足。计算依赖 GPU 支持, 低端设备运行效率较低; 当前界面仅支持单语言, 未能满足国际化需求。此外, 动态形变特征的提取精度受视频帧率限制, 可能影响复杂场景下的表征能力。

综上所述, 本章开发的织物手感评价软件系统通过整合第 3 章的视觉特征提取、第 4 章的 TAIL 预测和第 5 章的 AHP-RST 解释, 实现从视觉数据到手感评价的智能化流程, 验证其在精度、一致性、效率和应用价值上的综合优势, 为纺织工业的数字化转型提供可行方案。

第 7 章 结论与展望

7.1 结论

本文围绕织物手感评价的智能化与数字化目标,基于计算机视觉与多模态融合技术,系统解决视觉表征适用性验证、量化指标构建及多模态模型开发三大核心问题。通过从理论验证到技术实现,再到软件集成的全链条研究,构建覆盖视觉可感知性分析、特征工程、多模态建模及知识解释的完整框架,为织物手感评价的非接触式、客观化和高效化提供理论依据与实践工具。以下为主要研究结论:

(1) 视觉表征适用性边界的明确。通过设计基于信号检测理论的双面适用性测试(DFA)模型,结合真实触觉、静态图像和动态视频三模态评价场景,本研究系统验证视觉表征在织物手感评价中的适用范围。实验结果表明,表面、压缩、弯曲和拉伸四类机械性能的视觉评价与触觉评分高度一致($ICC>0.75$, $d'_A>1.5$),证明视觉信息能够有效传递织物手感的核心机械特性。然而,热湿性能(如透气性、导热性和湿度感知)的视觉表征能力较弱($d'_A<0.5$, $R^2=0.21$),因而被排除在后续研究之外。这一结论为非接触式手感评价奠定理论基础,明确视觉表征的应用边界。

(2) 物理可解释的视觉量化指标体系的构建。针对手感视觉表征的量化难题,本研究基于特征工程方法,设计并筛选出一套包含 22 个多尺度视觉量化指标的体系,涵盖表面粗糙度、压缩回复、弯曲刚度和拉伸模量等属性。通过 VIF 和 LASSO 回归双重筛选,指标数量从 33 个精简至 22 个,确保非冗余性与物理可解释性。验证结果显示,该体系与感官评分和 KES 物理测量高度相关(如对比度与“Rogh”评分 $r=0.919$, 弯曲刚度与 KES 数据 $r=-0.82$),为手感数字化提供高效、可靠的视觉指标库,突破传统图像特征的碎片化局限。

(3) 多模态融合模型的高效开发。本研究开发 TAIL (Textile Attribute Integration and Learning) 框架,通过整合数值、图像和视频数据,实现从原始输入到手感评分、分类和决策的端到端评价。TAIL 采用动态时间规整(DTW)对齐模态特征,结合时序卷积网络(TCN)和注意力机制进行融合,支持回归、分类和决策任务的联合优化。实验结果表明,TAIL 在预测精度(MSE 降低 37.4%)和效率上显著优于单模态及传统多模态方法,为工业场景的实时应用提供精准、高效的解决方案。

(4) 知识发现增强解释性。为弥补 TAIL 框架“黑箱”特性,基于 AHP-RST 混合模型从感官数据中提取 155 条显式 IF-THEN 映射(如“IF Smooth(4) AND Flowing(3) THEN D→Silk”),覆盖 86.1%的样本,支持面料选材和质量控制等场景。模型通过 AHP 优化主观权重($CR\leq 0.08$)与 RST 挖掘客观规律($\gamma\geq 0.89$),置信度和覆盖度分别提升 15.6%和 22.7%,F1-score 达 0.91,决策准确率达 87.3%,显著提高评价的可解释性和工

业适用性。

(5) 软件系统集成与应用。通过开发织物手感评价软件系统,本研究将视觉特征提取、TAIL 预测和 AHP-RST 解释功能集成于一体,实现从多源数据输入到手感评价与解释输出的自动化流程。系统在精度、一致性和效率上表现出色,为纺织工业的质量控制和面料选材提供实用工具,推动织物手感评价的数字化转型。

综上所述,本研究通过跨模态验证、特征工程、多模态建模和知识发现,系统解决织物手感评价的主观依赖性强、客观仪器成本高及动态行为表征不足等问题,实现理论创新到技术落地的完整链条,为纺织行业的智能化发展提供坚实的理论支撑和技术范式。

7.2 不足与展望

课题针对织物手感视觉评价展开系列基础性科学研究,取得阶段性成果,但仍存在以下局限性,需在未来工作中进一步探索:

(1) 热湿性能评价的局限。本研究发现视觉表征难以准确捕捉织物热湿性能,未来可引入红外成像或多光谱技术,结合触觉传感器数据,进一步探索热湿属性的非接触式评价方法。

(2) 模型计算复杂性。TAIL 框架和软件系统对 GPU 依赖性较强,限制其在低端设备上的应用。未来可通过模型压缩或轻量化设计(如剪枝、量化)优化计算效率,提升普适性。

(3) 数据多样性与泛化能力。本研究基于 101 个织物样本,样本覆盖范围有限。未来可扩展数据集规模,纳入更多织物类型(如功能性面料、复合材料),增强模型的泛化能力。

展望未来,随着计算机视觉、传感器技术和人工智能的进一步发展,织物手感评价有望实现更高精度、更广适用性和更强解释性的突破。基于本研究的成果,可进一步探索多模态数据与用户偏好的深度融合,开发适应个性化需求的智能推荐系统,推动纺织工业向数字化、智能化和可持续化方向迈进。

参考文献

- [1] Abu Bakar B. Subjective and objective evaluation of fabric handle characteristics [D]; University of Leeds, 2004.
- [2] Civile, Vance G. Development of terminology to describe the handfeel properties of paper and fabrics [J]. *Journal of sensory studies*, 1990, 5(1): 19-32.
- [3] Liao X, Li Y, Hu J, et al. Effects of contact method and acclimation on temperature and humidity in touch perception [J]. *Textile Research Journal*, 2018, 88(14): 1605-1615.
- [4] Textiles: Determination of drying rate in dynamic state by the modified sweating - guarded hotplate [M]. ISO, 2012.
- [5] Shin HW, Lee JS. A cross-cultural comparison of image perception and preferences for cotton fabrics between korea and the united states [J]. *Fibers and Polymers*, 2007, 8(1): 98-104.
- [6] Huang Y, Jing J, Wang Z. Fabric defect segmentation method based on deep learning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-15.
- [7] Kawabata S, Niwa M. Objective measurement of fabric mechanical property and quality: Its application to textile and clothing manufacturing [J]. *International Journal of Clothing Science and Technology*, 1991, 3(1): 7-18.
- [8] Giorgio Minazio P. Fast-fabric assurance by simple testing [J]. *International Journal of Clothing Science and Technology*, 1995, 7(2/3): 43-48.
- [9] Kawabata S, Niwa M, Fumei W. Objective hand measurement of nonwoven fabrics [J]. *Textile Research Journal*, 1994, 64(10): 597-610.
- [10] Liao X. Neuropsychological mechanisms of fabric touch sensations [J]. 2015.
- [11] Kim M-K, Cho J-H, Jeong J-H. Classification of tactile perception and attention on natural textures from eeg signals; proceedings of the 2021 9th International Winter Conference on Brain-Computer Interface (BCI), F, 2021 [C]. IEEE.
- [12] Uzen H, Turkoglu M, Hanbay D. Texture defect classification with multiple pooling and filter ensemble based on deep neural network [J]. *Expert Systems with Applications*, 2021, 175: 114838.
- [13] Wang X, Georganas ND, Petriu EM. Fabric texture analysis using computer vision techniques [J]. *IEEE Transactions on Instrumentation and Measurement*, 2010, 60(1): 44-56.
- [14] Bouman KL, Xiao B, Battaglia P, et al. Estimating the material properties of fabric from video; proceedings of the Proceedings of the IEEE international conference on computer vision, F, 2013 [C].
- [15] Xue Z, Zeng X, Koehl L, et al. Extracting fabric hand information from visual representations of flared skirts [J]. *Textile Research Journal*, 2014, 84(3): 246-266.
- [16] Xue Z, Zeng X, Koehl L, et al. Interpretation of fabric tactile perceptions through visual features for textile products [J]. *Journal of sensory studies*, 2016, 31(2): 143-162.
- [17] Wang X, Georganas ND. Glcm texture based fractal method for evaluating fabric surface roughness; proceedings of the 2009 Canadian Conference on Electrical and Computer Engineering, F, 2009 [C]. IEEE.
- [18] Dollár P, Tu Z, Tao H, et al. Feature mining for image classification; proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition, F, 2007 [C]. IEEE.

- [19] Maeda Y, Tanimoto K, Sasayama K, et al. Neural - network - based tactile perception system using ultrahigh - resolution tactile sensor [J]. *IEEE Transactions on Haptics*, 2023, 16(4): 504-510.
- [20] Chen D, Ding Y, Wu H, et al. Visually impaired people learning virtual textures through multimodal feedback combining vibrotactile and voice [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2025.
- [21] Dong M, Zeng X, Koehl L, et al. Fabrics recommendation for fashion design by using fuzzy logic and rough sets [J]. *Journal of Fuzzy Logic and Modeling in Engineering*, 2022, 1(1): E010621191756.
- [22] Ali U, Zhou Y, Wang X, et al. Direct electrospinning of highly twisted, continuous nanofiber yarns [J]. *Journal of the Textile Institute*, 2012, 103(1): 80-88.
- [23] Pan N. Quantification and evaluation of human tactile sense towards fabrics [J]. *International Journal of Design & Nature and Ecodynamics*, 2006, 1(1): 48-60.
- [24] Ma Z, Hatfield L, Jansen C, et al. Workshopping the textile hand: Reimagining subjective assessment of textile materials with digital technologies [M]. 2024.
- [25] Ahirwar M, Behera B. Fabric hand research translates senses into numbers—a review [J]. *The Journal of The Textile Institute*, 2022, 113(11): 2531-2548.
- [26] De Boos A. Concepts and understanding of fabric hand [M]. *Effect of mechanical and physical properties on fabric hand*. Elsevier. 2005: 11-44.
- [27] Ryu H-S, Roh EK. Preference and subjective evaluation of washed fabric hand using conjoint analysis [J]. *Textile Research Journal*, 2010, 80(20): 2167-2175.
- [28] Binns H. The discrimination of wool fabrics by the sense of touch [J]. *British Journal of Psychology*, 1926, 16(3): 237.
- [29] Ciesielska-Wróbel IL, Van Langenhove L. The hand of textiles – definitions, achievements, perspectives – a review [J]. *Textile Research Journal*, 2012, 82(14): 1457-1468.
- [30] Ozcelik G, Supuren G, Gulumser T, et al. A study on subjective and objective evaluation of the handle properties of shirt fabrics [J]. *Fibres & Textiles in Eastern Europe*, 2008, 16(3): 68.
- [31] Peirce FT. The “handle” of cloth as a measurable quantity [J]. *Journal of the Textile Institute Transactions*, 1930, 21(9): T377-T416.
- [32] Mahar T, Wang H, Postle R. A review of fabric tactile properties and their subjective assessment for next-to-skin knitted fabrics [J]. *Journal of the Textile Institute*, 2013, 104(6): 572-589.
- [33] Behery HM. *Effect of mechanical and physical properties on fabric hand* [M]. 2005.
- [34] Shishoo R. *Use of kawabata evaluation system of fabrics (kes-f) in the clothing industry* [M]. 1991.
- [35] Lundgren HP. New concepts in evaluating fabric hand [J]. *Textile Chemist & Colorist*, 1969, 1(1).
- [36] Dabolina I, Abu-Rous M, Lapkovska E. A fast training method of a fabric hand-feel panel under industry conditions, and its conformity with other human and instrumental approaches [J]. *Applied Sciences*, 2022, 12(23): 12344.
- [37] Hansen Jr OC, Marker L, Ninnemann KW, et al. Relationship between dynamic modulus of thin films and stiffness, as determined by the handle - o - meter [J]. *Journal of Applied Polymer Science*, 1963, 7(3): 817-832.
- [38] Hu J, Chen W, Newton A. A psychophysical model for objective fabric hand evaluation: An application of

- stevens's law [J]. *Journal of the Textile Institute*, 1993, 84(3): 354-363.
- [39] Winakor G, Kim CJ, Wolins L. Fabric hand: Tactile sensory assessment [J]. *Textile Research Journal*, 1980, 50(10): 601-610.
- [40] Pan N, Lin C, Xu J. A new method for measuring fabric drape with a novel parameter for classifying fabrics [J]. *Fibers*, 2019, 7(8): 70.
- [41] Yuan W, Dong S, Adelson EH. Gelsight: High-resolution robot tactile sensors for estimating geometry and force [J]. *Sensors*, 2017, 17(12): 2762.
- [42] Sun Y, Zhang M, Liu G, et al. Measurement of fabric handle characteristics based on the quick-intelligent handle evaluation system for fabrics (qihes-f) [J]. *Textile Research Journal*, 2018, 89(16): 3374-3386.
- [43] Hu H, Han Y, Song A, et al. A finger-shaped tactile sensor for fabric surfaces evaluation by 2-dimensional active sliding touch [J]. *Sensors (Basel)*, 2014, 14(3): 4899-4913.
- [44] Hu J, Hes L, Li Y, et al. Fabric touch tester: Integrated evaluation of thermal-mechanical sensory properties of polymeric materials [J]. *Polymer Testing - POLYM TEST*, 2006, 25: 1081-1090.
- [45] Sikka MP, Sarkar A, Garg S. Artificial intelligence (ai) in textile industry operational modernization [J]. *Research Journal of Textile and Apparel*, 2024, 28(1): 67-83.
- [46] 郭栩源, 李忠健. 基于改进 kcf 算法的织物折皱回复检测研究 [J]. *丝绸*, 2024, 61(4).
- [47] 蒋鑫, 刘成霞. 基于三维扫描的织物多方向可视化弯曲性测试方法 [J]. *现代纺织技术*, 2024, 32(4): 60.
- [48] Tu Y-F, Kwan M-Y, Yick K-L. A systematic review of ai-driven prediction of fabric properties and handfeel [J]. *Materials*, 2024, 17(20): 5009.
- [49] Shih C-H, Lin C-J, Lee C-L. Integrated image sensor and deep learning network for fabric pilling classification [J]. *Sensors & Materials*, 2022, 34.
- [50] 方超逸, 何佳臻. Vr/ar 技术在服装行业中的发展与应用 [J]. *现代纺织技术*, 2022, 30(6).
- [51] Hussain A, Zhong Y, Naveed T, et al. A new approach to evaluate fabric hand based on three - dimensional drape model [J]. *Autex Research Journal*, 2020, 20(2): 155-167.
- [52] Bhandari B, Lee M. Haptic identification of objects using tactile sensing and computer vision [J]. *Advances in Mechanical Engineering*, 2019, 11(4): 1687814019840468.
- [53] 薛婷婷, 刘秀平. 基于学习的 gabor 滤波器多样式布匹瑕疵检测 [J]. *西安工程大学学报*, 2017, 31(6).
- [54] Salem YB, Nasri S. Texture classification of woven fabric based on a glcm method and using multiclass support vector machine; proceedings of the 2009 6th International Multi-Conference on Systems, Signals and Devices, F, 2009 [C]. IEEE.
- [55] Deotale NT, Sarode TK. Fabric defect detection adopting combined glcm, gabor wavelet features and random decision forest [J]. *3D Research*, 2019, 10: 1-13.
- [56] Yuan W, Wang S, Dong S, et al. Connecting look and feel: Associating the visual and tactile properties of physical materials; proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, F, 2017 [C].
- [57] Madeley T, Postle R, Mahar T. Physical properties and processing of fine merino lamb's wool: Part i: Wool growth and softness of handle [J]. *Textile Research Journal*, 1998, 68(8): 545-552.
- [58] Aferi FD, Purboyo TW, Saputra RE. Cotton texture segmentation based on image texture analysis using gray

- level co-occurrence matrix (glcm) and euclidean distance [J]. *Int J Appl Eng Res*, 2018, 13(1): 449-455.
- [59] Xue J, Petreca BB, Dawes C, et al. Fabtouch: A tool to enable communication and design of tactile and affective fabric experiences; proceedings of the Proceedings of the 2023 CHI conference on human factors in computing systems, F, 2023 [C].
- [60] 李文羽, 程隆棣. 基于机器视觉和图像处理的织物疵点检测研究新进展 [J]. *纺织学报*, 2014, 35(3).
- [61] 李立轻, 黄秀宝. 图像处理用于织物疵点自动检测的研究进展 [J]. *东华大学学报 (自然科学版)*, 2002, 28(4): 118-122.
- [62] 周圆圆, 潘如如. 基于标准样照与图像分析的织物起毛起球评等方法 [J]. *纺织学报*, 2010, (10): 29-33.
- [63] 曹飞, 汪军. 织物起球标准样照的图像分析 [J]. *东华大学学报 (自然科学版)*, 2007, 33(6): 751-755.
- [64] Phoophat P, Yamamoto H, Sukigara S. Visual aesthetic perception of handwoven cotton fabrics [J]. *The Journal of The Textile Institute*, 2019, 110(3): 412-425.
- [65] 何峰, 李立轻. 基于自适应小波变换的织物密度测量 [J]. *纺织学报*, 2007, 28(2): 32-35.
- [66] 陈顺. 几种类型图像边缘检测的相关问题研究 [D]; 武汉: 武汉纺织大学, 2021.
- [67] Sztandera LM. Tactile fabric comfort prediction using regression analysis [J]. *Wseas Transactions on Computers*, 2009, 2(8): 292-301.
- [68] Kim JO, Slaten BL. Objective evaluation of fabric hand: Part i: Relationships of fabric hand by the extraction method and related physical and surface properties [J]. *Textile Research Journal*, 1999, 69(1): 59-67.
- [69] Behery HM. Comparison of fabric hand assessment in the united states and japan [J]. *Textile Research Journal*, 1986, 56(4): 227-240.
- [70] Adams WJ, Kerrigan IS, Graf EW. Touch influences perceived gloss [J]. *Scientific Reports*, 2016, 6(1): 21866.
- [71] Zhu Y, Zhao L, Chen X, et al. Identification of cashmere and wool based on lbp and glcm texture feature selection [J]. *Journal of Engineered Fibers and Fabrics*, 2023, 18: 15589250221146548.
- [72] Talu MF, Hanbay K, Varjovi MH. Cnn-based fabric defect detection system on loom fabric inspection [J]. *Textile and Apparel*, 2022, 32(3): 208-219.
- [73] Wen Z, Zhao Q, Tong L. Cnn-based minor fabric defects detection [J]. *International Journal of Clothing Science and Technology*, 2021, 33(1): 1-12.
- [74] Liu R, Yu Z, Fan Q, et al. The improved method in fabric image classification using convolutional neural network [J]. *Multimedia Tools and Applications*, 2024, 83(3): 6909-6924.
- [75] Geng Z, Lin B, Yuan Y, et al. Garment fabric pattern classification via resnet-34; proceedings of the Proceedings of the 2023 International Conference on Power, Communication, Computing and Networking Technologies, F, 2023 [C].
- [76] Iqbal Hussain MA, Khan B, Wang Z, et al. Woven fabric pattern recognition and classification based on deep convolutional neural networks [J]. *Electronics*, 2020, 9(6): 1048.
- [77] Jimba N, Ishikawa T, Yanagida Y, et al. Visual ratings of “softness/hardness” of rotating fabrics [J]. *International Journal of Clothing Science and Technology*, 2020, 32(1): 48-62.
- [78] Mao M, Va H, Lee A, et al. Supervised video cloth simulation: Exploring softness and stiffness variations on fabric types using deep learning [J]. *Applied Sciences*, 2023, 13(17): 9505.

- [79] 唐雯萱, 温润. 明度对真丝织物光泽感感知的影响与机制研究 [J]. 丝绸, 2024, 61(6).
- [80] Xu S, Xu H, Mao F, et al. Flexible material quality assessment based on visual - tactile fusion [J]. IEEE Transactions on Instrumentation and Measurement, 2024.
- [81] Routray PK, Kanade AS, Bhanushali J, et al. Vistanet: Attention guided deep fusion for surface roughness classification [J]. arXiv preprint arXiv:220908516, 2022.
- [82] Ech-chouqi N, Rouhafzay G. A contrastive learning approach for integrating visuo-tactile representation in textiles [J]. Engineering Proceedings, 2024, 82(1): 21.
- [83] Gong R, Newton A. Image-analysis techniques part ii: The measurement of fibre orientation in nonwoven fabrics [J]. Journal of the Textile Institute, 1996, 87(2): 371-388.
- [84] Turan RB, Okur A, Deveci R, et al. Predicting the intra-yarn porosity by image analysis method [J]. Textile Research Journal, 2012, 82(16): 1720-1728.
- [85] Militký Ji, Mazal M. Image analysis method of surface roughness evaluation [J]. International Journal of Clothing Science and Technology, 2007, 19(3/4): 186-193.
- [86] Wang S-a, Albin A, Maiolino P, et al. Fabric classification using a finger-shaped tactile sensor via robotic sliding [J]. Frontiers in Neurorobotics, 2022, 16: 808222.
- [87] Okatani T, Takahashi H, Noda K, et al. A tactile sensor using piezoresistive beams for detection of the coefficient of static friction [J]. Sensors, 2016, 16(5): 718.
- [88] Park KH, Kwon YH, Oh KW, et al. The surface roughness measurement for textiles fabrics by a non-contact method for tactile perception; proceedings of the 6th Asian design international conference, F, 2003 [C].
- [89] Jin Eunjung, Cho Gilsoo. Sound characteristics and mechanical properties of taekwondo uniform fabrics [J]. Fashion & Textile Research Journal Volume, 2012, 14(3): 486-491.
- [90] Mengüç GS, Demir A, Bozdoğan F, et al. An investigation on sound generation in different fabrics [J]. Textile and Apparel, 28(1): 52-59.
- [91] Mangat AE, Hes L, Bajzik V, et al. Thermal absorptivity model of knitted rib fabric and its experimental verification [J]. Autex Research Journal, 2018, 18(1): 20-27.
- [92] Zhang Q, Kan C-w, Chan C-k. Relationship between physical and low-stress mechanical properties to fabric hand of woollen fabric with fusible interlinings [J]. Fibers and Polymers, 2018, 19: 230-237.
- [93] Xue Z, Zeng X, Koehl L, et al. Development of a fuzzy inclusion measure for investigating relations between visual and tactile perception of textile products; proceedings of the 2012 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI), F, 2012 [C]. IEEE.
- [94] Chen D, Liu J, Tian L, et al. Research on the method of displaying the contour features of image to the visually impaired on the touch screen [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 2260-2270.
- [95] Imran AA, Rahim MS, Ahmed T. Mining the productivity data of the garment industry [J]. International Journal of Business Intelligence and Data Mining, 2021, 19(3): 319-342.
- [96] Yildirim Taser P, Birant D, Alpyildiz T. Discovering the relationships between yarn and fabric properties using association rule mining [J]. Turkish Journal of Electrical Engineer, 2017, 25: 4788-4804.
- [97] Yildirim P, Birant D, Alpyildiz T. Data mining and machine learning in textile industry [J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2018, 8(1): e1228.

- [98] Yu Y, Hui CLP, Choi T-M, et al. A new approach for fabric hand prediction with a nearest neighbor algorithm-based feature selection scheme [J]. *Textile Research Journal*, 2011, 81(6): 574-584.
- [99] Xue Z, Zeng X, Koehl L. An intelligent method for the evaluation and prediction of fabric formability for men's suits [J]. *Textile Research Journal*, 2016, 88(4): 438-452.
- [100] Fang Z, Zhai W, Su A, et al. Vivid: Video virtual try-on using diffusion models [J]. *arXiv preprint arXiv:240511794*, 2024.
- [101] 李鑫, 曹潇文. 基于虚拟现实技术的面料与服装协同设计系统研发与应用 [J]. *纺织导报*, 2022, (5).
- [102] 陈立, 翁重. 元宇宙技术在纺织行业高质量发展中的应用探讨 [J]. *纺织导报*, 2022, (6).
- [103] Hong Y, Guo S, Zeng X, et al. Human cognition modeling for the metaverse-oriented design system [J]. *IEEE Network*, 2024: 1-1.
- [104] Kim I-A, van Hout D, Lee H-S. Signal detection-based satisfaction measure of the holistic product usage experience with and without the 'double-faced applicability' test [J]. *Food quality and preference*, 2018, 68: 40-49.
- [105] Harris JA. On the calculation of intra-class and inter-class coefficients of correlation from class moments when the number of possible combinations is large [J]. *Biometrika*, 1913, 9(3/4): 446-472.
- [106] Kroll W. A note on the coefficient of intraclass correlation as an estimate of reliability [J]. *Research Quarterly American Association for Health, Physical Education and Recreation*, 1962, 33(2): 313-316.
- [107] Duncan DB. Multiple range and multiple f tests [J]. *biometrics*, 1955, 11(1): 1-42.
- [108] Kim I-A, Hopkinson A, van Hout D, et al. A novel two-step rating-based 'double-faced applicability' test. Part 2: Introducing a novel measure of affect magnitude (d') for profiling consumers' product usage experience based on signal detection theory [J]. *Food quality and preference*, 2017, 59: 141-149.
- [109] 赵军圣, 庄光明. 极大似然估计方法介绍 [J]. *长春理工大学学报: 自然科学版*, 2010, (6): 53-54.
- [110] Gaylor DW, Hopper F. Estimating the degrees of freedom for linear combinations of mean squares by satterthwaite's formula [J]. *Technometrics*, 1969, 11(4): 691-706.
- [111] Bruhn A, Weickert J, Schnörr C. Lucas/kanade meets horn/schunck: Combining local and global optic flow methods [J]. *International journal of computer vision*, 2005, 61: 211-231.
- [112] Dijksterhuis GB. *Multivariate data analysis in sensory and consumer science* [M]. John Wiley & Sons, 2008.
- [113] Kim I-A, Hopkinson A, van Hout D, et al. A novel two-step rating-based 'double-faced applicability' test. Part 1: Its performance in sample discrimination in comparison to simple one-step applicability rating [J]. *Food quality and preference*, 2017, 56: 189-200.
- [114] Ares G, Jaeger SR, Bava CM, et al. Cata questions for sensory product characterization: Raising awareness of biases [J]. *Food quality and preference*, 2013, 30(2): 114-127.
- [115] Juslin P, Olsson H. Thurstonian and brunswikian origins of uncertainty in judgment: A sampling model of confidence in sensory discrimination [J]. *Psychological review*, 1997, 104(2): 344.
- [116] Abidi N, Hequet E, Turner C, et al. Objective evaluation of durable press treatments and fabric smoothness ratings [J]. *Textile Research Journal*, 2005, 75(1): 19-29.
- [117] Luible C, Varheenmaa M, Magnenat-Thalmann N, et al. Subjective fabric evaluation; proceedings of the 2007 International Conference on Cyberworlds (CW'07), F, 2007 [C]. IEEE.
- [118] Isaksen SG. A review of brainstorming research: Six critical issues for inquiry [M]. Creative Research Unit,

- Creative Problem Solving Group-Buffalo Buffalo, NY, 1998.
- [119] Manual ABs. An introduction to statistical learning with applications in r [J]. 2013.
- [120] McKnight PE, Najab J. Mann - whitney u test [J]. The Corsini encyclopedia of psychology, 2010: 1-1.
- [121] Huang L, Yang T, Jiang R, et al. Deforming garment classification with shallow temporal extraction and tree-based fusion [J]. IEEE Robotics and Automation Letters, 2023, 9(2): 1114-1121.
- [122] O'brien RM. A caution regarding rules of thumb for variance inflation factors [J]. Quality & quantity, 2007, 41: 673-690.
- [123] Ranstam J, Cook JA. Lasso regression [J]. Journal of British Surgery, 2018, 105(10): 1348-1348.
- [124] Xu X, Xu S, Jin L, et al. Characteristic analysis of otsu threshold and its applications [J]. Pattern recognition letters, 2011, 32(7): 956-961.
- [125] Abreu E. Signal-dependent rank-ordered-mean (sd-rom) filter [M]. Nonlinear image processing. Elsevier. 2001: 111-133.
- [126] Tariyal S, Majumdar A, Singh R, et al. Deep dictionary learning [J]. IEEE Access, 2016, 4: 10096-10109.
- [127] Illingworth J, Kittler J. A survey of the hough transform [J]. Computer vision, graphics, and image processing, 1988, 44(1): 87-116.
- [128] Likas A, Vlassis N, Verbeek JJ. The global k-means clustering algorithm [J]. Pattern recognition, 2003, 36(2): 451-461.
- [129] 朱挺. 数字图像法检测织物悬垂性及悬垂性影响因素分析 [D]; 东华大学, 2009.
- [130] Kanopoulos N, Vasanthavada N, Baker RL. Design of an image edge detection filter using the sobel operator [J]. IEEE Journal of Solid-State Circuits, 1988, 23(2): 358-367.
- [131] Chen J, Jönsson P, Tamura M, et al. A simple method for reconstructing a high-quality ndvi time-series data set based on the savitzky-golay filter [J]. Remote Sensing of Environment, 2004, 91(3): 332-344.
- [132] Lu S, Ding Y, Liu M, et al. Multiscale feature extraction and fusion of image and text in vqa [J]. International Journal of Computational Intelligence Systems, 2023, 16(1): 54.
- [133] Li Q, Cai W, Wang X, et al. Medical image classification with convolutional neural network; proceedings of the 2014 13th international conference on control automation robotics & vision (ICARCV), F, 2014 [C]. IEEE.
- [134] Ngiam J, Khosla A, Kim M, et al. Multimodal deep learning; proceedings of the ICML, F, 2011 [C].
- [135] Lea C, Vidal R, Reiter A, et al. Temporal convolutional networks: A unified approach to action segmentation; proceedings of the Computer Vision-ECCV 2016 Workshops: Amsterdam, The Netherlands, October 8-10 and 15-16, 2016, Proceedings, Part III 14, F, 2016 [C]. Springer.
- [136] Müller M. Dynamic time warping [J]. Information retrieval for music and motion, 2007: 69-84.
- [137] Yao L, Torabi A, Cho K, et al. Video description generation incorporating spatio-temporal features and a soft-attention mechanism [J]. arXiv preprint arXiv:150208029, 2015, 6(2): 201-211.
- [138] Hong J-H, Cho S-B. A probabilistic multi-class strategy of one-vs.-rest support vector machines for cancer classification [J]. Neurocomputing, 2008, 71(16-18): 3275-3281.
- [139] Barlow HB. Unsupervised learning [J]. Neural computation, 1989, 1(3): 295-311.
- [140] Azad R, Asadi-Aghbolaghi M, Fathy M, et al. Bi-directional convlstm u-net with densely connected convolutions; proceedings of the Proceedings of the IEEE/CVF international conference on computer vision

- workshops, F, 2019 [C].
- [141] Wang X, Xie W, Song J. Learning spatiotemporal features with 3dcnn and convgru for video anomaly detection; proceedings of the 2018 14th IEEE international conference on signal processing (ICSP), F, 2018 [C]. IEEE.
- [142] Zeng Z, Jin G, Xu C, et al. Satellite telemetry data anomaly detection using causal network and feature-attention-based lstm [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-21.
- [143] Liu Z, Luo S, Li W, et al. Convtransformer: A convolutional transformer network for video frame synthesis [J]. arXiv preprint arXiv:201110185, 2020.
- [144] Li X, Ma X, Xiao F, et al. Time-series production forecasting method based on the integration of bidirectional gated recurrent unit (bi-gru) network and sparrow search algorithm (ssa) [J]. Journal of Petroleum Science and Engineering, 2022, 208: 109309.
- [145] Islam Z, Giggins H. Knowledge discovery through sysfor: A systematically developed forest of multiple decision trees; proceedings of the Proceedings of the Ninth Australasian Data Mining Conference-Volume 121, F, 2011 [C].
- [146] Oliveira SR, Zaiane OR. Algorithms for balancing privacy and knowledge discovery in association rule mining; proceedings of the Seventh International Database Engineering and Applications Symposium, 2003 Proceedings, F, 2003 [C]. IEEE.
- [147] Bajzík V. Some approaches to objective evaluation of fabric hand [J]. World Journal of Textile Engineering and Technology, 2016, 2(1): 1-11.
- [148] Podvezko V. Application of ahp technique [J]. Journal of Business Economics and management, 2009, (2): 181-189.
- [149] Saaty TL. Decision making—the analytic hierarchy and network processes (ahp/anp) [J]. Journal of systems science and systems engineering, 2004, 13: 1-35.
- [150] Shayeghi H, Mahdavi M, Bagheri A. An improved dpso with mutation based on similarity algorithm for optimization of transmission lines loading [J]. Energy Conversion and Management, 2010, 51(12): 2715-2723.
- [151] Qian C, Yu Y, Zhou Z-H. Subset selection by pareto optimization [J]. Advances in neural information processing systems, 2015, 28.
- [152] Ruggieri S. Efficient c4. 5 [classification algorithm] [J]. IEEE transactions on knowledge and data engineering, 2002, 14(2): 438-444.