

# 基于分段注意力机制对大麦数据分类

陈南阳

温州大学电气与电子工程学院, 浙江 温州

收稿日期: 2026年3月4日; 录用日期: 2026年6月15日; 发布日期: 2026年6月24日

## 摘要

近红外光谱技术因其快速、无损等优势, 在农产品品质分析中具有广泛应用, 但高维、非线性光谱数据给多品种精细分类带来挑战。文章提出一种基于分段独立卷积注意力模块(SI-CBAM)的近红外光谱分类方法, 用于埃塞俄比亚24个大麦品种的鉴别。针对大麦光谱在740~1070 nm范围内变化平缓、无明显吸收峰的特点, 设计基于光谱导数分析的物理意义分段策略, 将连续光谱划分为四个具有不同变化特征子区间。每个子区间独立嵌入CBAM模块, 通过通道注意力和空间注意力自适应强化局部判别特征, 提升模型对细微光谱差异的感知能力。实验结果表明, SI-CBAM在测试集上分类准确率达0.8333, 交叉验证准确率为0.8452, 显著优于随机森林(0.3194)、支持向量机(0.7194)及全局CBAM模型(0.8000)。研究表明, 结合光谱物理分段与注意力机制的策略, 能有效提升近红外光谱在复杂分类任务中的判别性能与模型可解释性。

## 关键词

近红外光谱, 卷积注意力模块, 分段策略

# Classification of Barley Data Based on a Segmented Attention Mechanism

Nanyang Chen

College of Electrical and Electronic Engineering, Wenzhou University, Wenzhou Zhejiang

Received: March 4, 2026; accepted: June 15, 2026; published: June 24, 2026

## Abstract

Near-infrared spectroscopy, owing to its rapid and non-destructive advantages, finds extensive application in agricultural product quality analysis. However, high-dimensional, non-linear spectral data poses challenges for precise classification across multiple varieties. This paper proposes a

near-infrared spectral classification method based on the Segmented Independent Convolutional Attention Module (SI-CBAM) for the identification of 24 barley varieties in Ethiopia. Addressing barley spectra's characteristic gradual variation without distinct absorption peaks across 740~1070 nm, a physically meaningful segmentation strategy based on spectral derivative analysis was devised. This divides the continuous spectrum into four sub-intervals exhibiting distinct variation patterns. Each sub-interval is independently embedded within the CBAM module, where adaptive reinforcement of local discriminative features through channel attention and spatial attention enhances the model's sensitivity to subtle spectral differences. Experimental results demonstrate that SI-CBAM achieves a classification accuracy of 0.8333 on the test set and a cross-validation accuracy of 0.8452, significantly outperforming Random Forest (0.3194), Support Vector Machine (0.7194), and the global CBAM model (0.8000). This research demonstrates that integrating spectral physical segmentation with attention mechanisms effectively enhances the discriminative performance and model interpretability of near-infrared spectroscopy in complex classification tasks.

## Keywords

Near-Infrared Spectroscopy, Convolutional Block Attention Module, Segmentation Strategy

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

近年来,近红外光谱技术,因其快速、无损、低成本的优势,已经被广泛应用于农业、化工、食品、医药等领域[1]-[4]。然而,基于光谱数据进行多品种分类仍面临显著挑战。原始的一维光谱数据通常包含数百至上千个波段,信息冗余度高,且易受环境噪声、样品状态及仪器波动干扰。传统的机器学习分类方法支持向量机[5] [6] (Support Vector Machine, SVM)、随机森林[7] [8] (Random Forest, RF)等在处理此类高维、非线性数据时,往往依赖于人工特征提取与降维技术(如主成分分析),难以从全局光谱中自适应地捕捉对分类最具判别力的局部敏感波段,导致在处理复杂多分类任务时性能受限,模型泛化能力不足。

为克服这一不足,本章研究引入注意力机制。注意力机制[9]-[11],的核心思想是模仿人类视觉认知过程,使模型能够从复杂输入中筛选关键信息,将有限的计算资源聚焦于任务相关的重要区域,同时抑制对次要信息的处理。卷积注意力模块[12]-[14] (Convolutional Block Attention Module, CBAM)是一种经典的轻量化双重注意力机制,它通过通道注意力来评估不同光谱波段的重要性,并通过空间注意力来评估同一通道内不同谱段区间的重要性。

在此基础上,本研究创新性地提出一种基于分段策略的CBAM注意力网络,用于大麦品种的近红外光谱分类。由于大麦光谱在740~1070 nm范围内整体较为平缓,无明显尖锐吸收峰,传统全局建模方法难以充分挖掘其细微的品种间差异。针对这一特点,本文采用分段建模策略,将连续光谱依据其变化特性划分为若干具有物理意义的子区间。随后,在每个子区间内部分别嵌入CBAM注意力模块构建分段独立CBAM架构(Segment-Independent Convolutional Block Attention Module, SI-CBAM)。该架构使模型能够聚焦于不同谱段的局部响应特征,从而有效提取更具判别力的光谱信息。该方法充分发挥了分段策略的结构化先验优势,实现了对24个大麦品种光谱细微差异的高效、鲁棒判别。本章将详细阐述该方法的网络架构、分段策略设计,并通过与大麦光谱数据集的实验对比,验证其相较于传统机器学习方法的有效

性与优越性。

## 2. 实验数据与分类方法

### 2.1. 实验数据与分析

该数据集包含 1200 份埃塞俄比亚大麦样本的近红外光谱测量数据, 涵盖 24 种不同大麦品种变体[15]。光谱在 740 至 1070 nm 波长范围内以 1 nm 分辨率记录。每个样本对应一条包含 331 个波长点的连续光谱曲线。本研究旨在基于近红外光谱实现对给定样本的大麦品种变体分类。为客观评估模型性能, 采用分层抽样算法将数据集按 7:3 比例划分为训练集与测试集, 确保训练集与测试集中各类别样本的比例分布与原始数据集保持一致。

由于原始光谱图中含有很多噪声与不必要的散射干扰, 因此使用标准正态变换[16] (Standard Normal Variate, SNV)进行预处理。SNV 能够有效消除因样品颗粒大小、表面散射及光程差异所引起的光谱基线偏移与幅度变化, 从而增强光谱与目标属性之间的相关性, 并提高后续分类模型的稳健性与准确度。经过 SNV 预处理后, 各样本光谱之间更具可比性, 更利于品种特征的提取与判别。大麦原始光谱与 SNV 预处理后的光谱对比如图 1 所示。




Figure 1. Comparison of barley raw spectra with spectra after SNV preprocessing

图 1. 大麦原始光谱与 SNV 预处理后的光谱对比

### 2.2. 随机森林

随机森林[17]是一种集成学习算法, 它通过组合归纳规则集来构建决策树森林。首先, 从变量和观测值的随机子集开始生长决策树。在每个节点处, 选择平均产生所有分支中最低类熵的属性, 并根据每个分支的观测值数量进行加权。树的每个叶节点(或最终节点)对应一条规则, 其条件由决策路径上所有边标签的组合构成。决策树的关键特征在于: 条件选择方式能同时优化节点所有后继节点的样本分布。在随机森林模型中, 每棵树都由数据集的引导抽样构建而成。通过对生成的树进行多数投票, 最终确定观测值的分类结果。

### 2.3. 支持向量机

支持向量机[18] (SVM)是一种强大的监督学习算法, 已广泛应用于模式识别[19]、信号控制[20]、通信[21]等领域。SVM 的核心思想是通过寻找一个最优超平面, 将不同类别的样本数据最大限度地分隔开, 并同时最大化超平面两侧的间隔。训练过程中, 观测值根据是否位于间隔之外、违反间隔或位于间隔上进行分类。分离超平面依赖于位于边界上的数据点, 即“支持向量”。SVM 通过非线性映射将数据投射

至高维特征空间。对于非线性可分数据，其边界假设得到放宽，允许部分观测值违反边界条件。核函数的选择影响模型性能，本文采用多项式核函数。

## 2.4. 卷积注意力模块

卷积注意力模块[22](CBAM)是一种旨在优化卷积神经网络特征表征的注意力机制。通过依次执行通道注意力模块与空间注意力模块，该机制显著提升了模型性能。通道注意力模块评估并赋予各通道权重；空间注意力模块则聚焦关键空间位置，从而增强卷积模型对光谱数据局部细节的敏感度与识别精度。

给定特征图  $F \in \mathbb{R}^{C \times H \times W}$  作为输入，CBAM 依次推导出 1D 通道注意力图  $M_c \in \mathbb{R}^{C \times 1 \times 1}$  和 2D 空间注意力图  $M_s \in \mathbb{R}^{1 \times H \times W}$ ，如图 2 所示。整体注意力过程可概括为：

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

其中， $\otimes$  表示元素乘法。在乘法过程中，注意力值会相应地通过广播(复制)进行处理：通道注意力值沿空间维度广播，反之亦然。 $F''$  为最终输出。

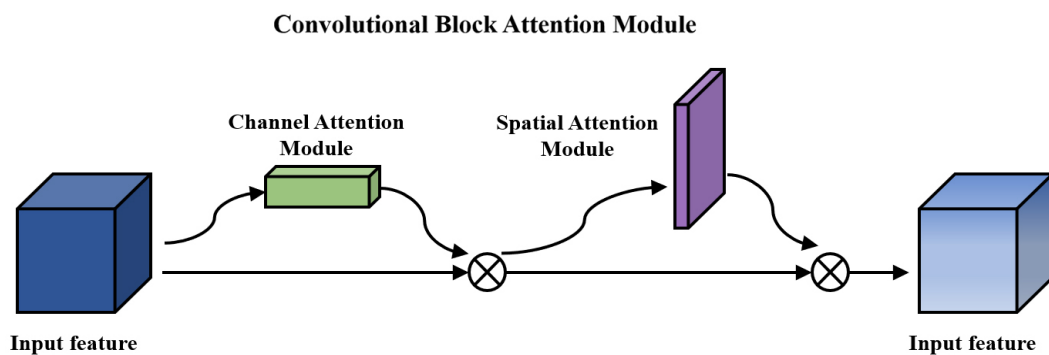


Figure 2. The overview of CBAM  
图 2. 卷积注意力模块示意图

### 2.4.1. 通道注意力

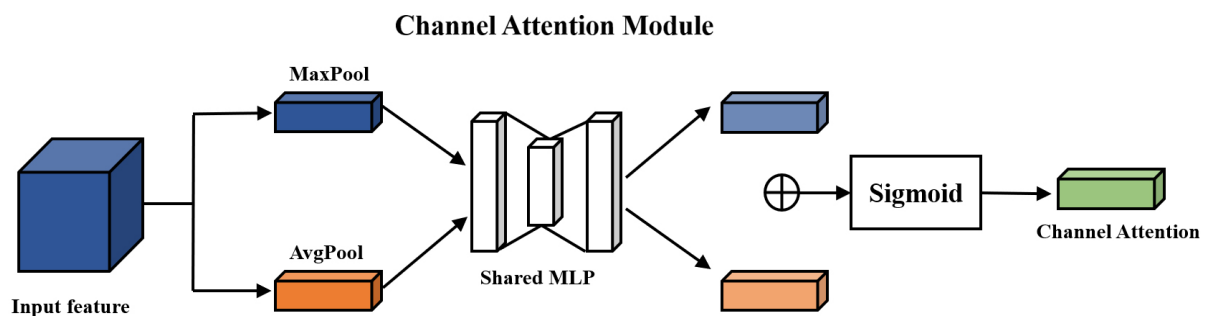


Figure 3. Channel attention network architecture diagram  
图 3. 通道注意力网络结构图

如图 3 所示，通道注意力模块(Channel Attention Module, CAM)通过学习每个通道之间的相互作用来提高特征图的表示能力。具体地，通道注意力模块首先对输入特征图中的每个通道分别进行全局平均

池化与全局最大池化操作，得到最大池化和平均池化的特征图。然后将这两个特征图作为输入，通过共享的包含一个隐藏层的多层感知机(MLP)和 Sigmoid 函数得到每个通道的权重。通道注意力机制可以表达为：

$$\begin{aligned} M_c(F) &= \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \\ &= \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \end{aligned} \quad (3)$$

其中  $\sigma$  表示 sigmoid 函数， $W_0 \in \mathbb{R}^{C/r \times C}$ ， $W_1 \in \mathbb{R}^{C \times C/r}$ ， $r$  为缩减比。 $F_{avg}^c$  和  $F_{max}^c$  分别表示平均池化和最大池化。需注意，MLP 权重  $W_0$  和  $W_1$  为两个输入共享。

#### 2.4.2. 空间注意力

空间注意力模块(Spatial Attention Module, SAM)通过学习特征图中每个空间位置之间的相互作用来提高特征图的表示能力。如图 4 所示，该模块的输入特征图是通道注意力模块输出的特征图。首先，空间注意力模块对输入特征图进行最大池化和平均池化操作，得到最大池化和平均池化特征图。然后将这两个特征图拼接起来，通过一个核大小为 7 的一维卷积层和 Sigmoid 函数得到每个空间位置的权重。空间注意力机制可以表示为：

$$\begin{aligned} M_s(F) &= \sigma(f^7([\text{AvgPool}(F); \text{MaxPool}(F)])) \\ &= \sigma(f^7([F_{avg}^s; F_{max}^s])) \end{aligned} \quad (4)$$

其中  $\sigma$  表示 sigmoid 函数， $f^7$  代表核大小为 7 的一维卷积操作。 $F_{avg}^s$  和  $F_{max}^s$  分别表示平均池化和最大池化。

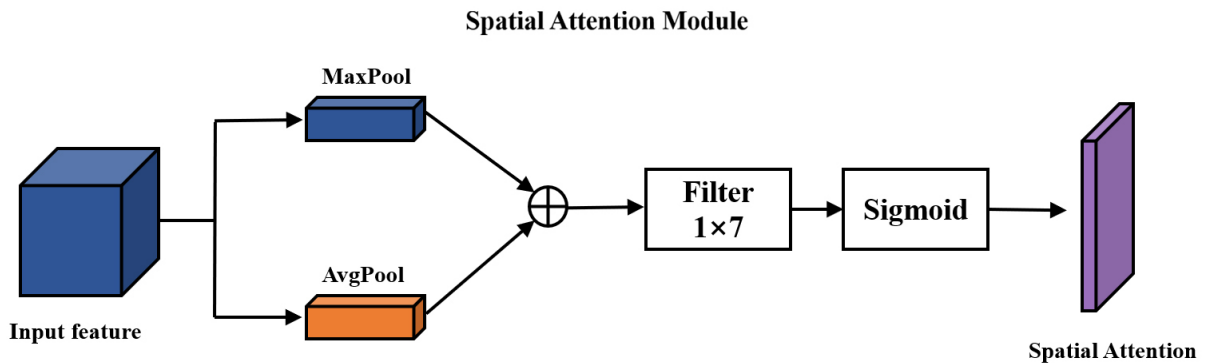


Figure 4. Spatial attention network architecture diagram  
图 4. 空间注意力网络结构图

在本研究中，我们针对近红外光谱数据的一维序列特性，对原始 CBAM 模块进行了适应性改造，提出了适用于光谱分析的一维 CBAM 变体。具体而言，我们将原本处理二维图像的空间注意力模块中的二维卷积操作，转换为沿波长维度滑动的一维卷积，以有效捕捉光谱序列中相邻波长的局部相关性。这一改造不仅更贴合光谱数据连续、有序的物理本质，使得模型能够精准聚焦于关键的吸收峰与特征波段，同时也显著降低了模型的参数量与计算复杂度，提升了运算效率。实验证明，此适配后的注意力机制能够有效引导网络有效识别并强化对分类判别至关重要的光谱区域，从而在提升模型性能的同时，也增强了其可解释性。

### 3. 结果与讨论

#### 3.1. 全局 CBAM 分类性能

本文提出的全局 CBAM 分类模型流程如图 5 所示。首先,对原始光谱进行 SNV 预处理。将处理后的光谱数据通过一维卷积层(卷积核大小 3,填充 1,输出通道 32)生成特征图,再将特征图输入 CBAM 注意力模块。该模块由通道注意力与空间注意力串联组成。通道注意力通过全局平均池化与全局最大池化压缩空间维度,经共享多层感知机生成通道权重,实现对重要光谱波段的全局筛选;空间注意力沿通道维度进行平均池化与最大池化,拼接后经核大小为 7 的一维卷积生成空间权重,再与原特征图逐元素相乘,聚焦于光谱序列中具有判别性的局部区域。然后,将加权后的特征图展平为一维向量,输入由三层全连接层构成的降维网络:256 → 128 → 64,每层后均接批归一化、ReLU 激活及 Dropout 提取出 64 维的高级特征表示;最终分类器由两层全连接网络构成:64 → 32 → 24,层间插入 ReLU 激活与 Dropout,输出层无激活函数,直接产生 24 个类别的原始得分(logits),经 Softmax 函数归一化后得到各类别预测概率。为防止过拟合,全连接层采用 0.2 概率的 Dropout 降维策略。训练过程中使用 Adam 优化器,初始学习率设为 0.001,并通过 ReduceLRonPlateau 算法动态调整学习率。模型完整结构如图 5 所示。

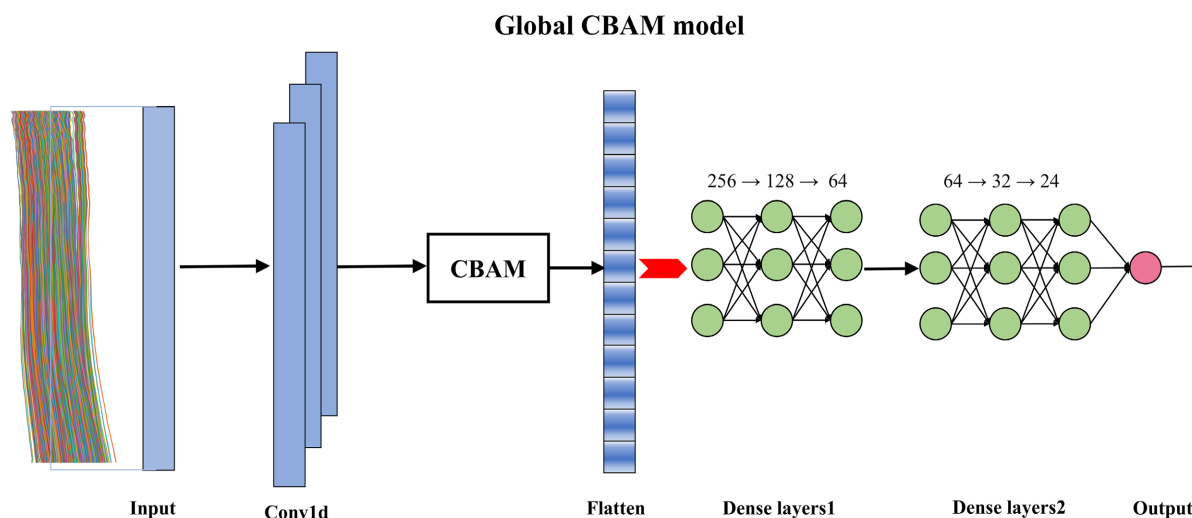


Figure 5. Global CBAM network architecture diagram

图 5. 全局 CBAM 网络结构图

为验证全局 CBAM 模型的优越性,将其与随机森林(RF)、支持向量机(SVM)两类传统分类方法进行对比。RF 模型采用 500 棵决策树,每棵树分裂时随机选择  $\sqrt{331} \approx 18$  个特征;SVM 模型经网格搜索优化,最终确定多项式核函数(degree = 3, C = 1, gamma = scale)取得最佳性能。由表 1 可知,RF 模型在测试集上的准确率仅为 0.3194,交叉验证均值 0.2964,表明其对高维、非线性光谱特征的拟合能力严重不足,难以捕捉大麦 24 个品种间的细微光谱差异。SVM-多项式模型虽通过核技巧将数据映射到高维空间,取得了 0.7194 的准确率与 0.7060 的交叉验证得分,提示模型存在一定程度的过拟合,且其分类性能仍远未达到实用化需求。偏最小二乘判别分析(PLS-DA)的结果与 SVM 相似,其交叉验证为 0.7488,准确率为 0.7278。作为对比,采用与全局 CBAM 类似结构的一维卷积神经网络(1D-CNN)则表现出更优的性能:模型先利用卷积层提取光谱特征,再经三层全连接网络压缩为 64 维关键特征,最终由分类器输出 24 个类别的得分。其交叉验证准确率达 0.7976,测试准确率为 0.7611,已展现出初步有效的分类能力,为后续引入 CBAM

注意力机制奠定了良好基础。

相比之下，全局 CBAM 模型在测试集上达到 0.8 的准确率，交叉验证精度达 0.8214，较 SVM-多项式提升 11.2%，且交叉验证得分高于测试准确率，说明模型具有良好的泛化能力与稳健性。这一显著提升归因于 CBAM 模块的双重注意力机制：通道注意力自适应地强化与品种判别强相关的光谱波段，空间注意力则聚焦于各波段内的局部波形特征，二者协同作用使模型能够从原始光谱中直接学习到更具区分性的特征表示。各方法的具体性能对比详见表 1。

**Table 1.** Classification performance of five classification models

**表 1.** 五种分类模型的性能

分类方法	特征数	交叉验证	准确率
随机森林	331	0.2964	0.3194
SVM-多项式	331	0.7060	0.7194
PLS-DA	331	0.7488	0.7278
1D-CNN	64	0.7976	0.7611
全局注意力 CBAM	64	<b>0.8214</b>	<b>0.8000</b>

### 3.2. SI-CBAM 分类性能

尽管全局 CBAM 模型已取得显著性能提升，但其在整个光谱域上统一应用注意力机制，可能忽视不同谱段在物理意义与变化特性上的差异。大麦近红外光谱(740~1070 nm)整体较为平缓，无明显尖锐吸收峰，但不同区域的光谱变化速率存在显著差异(见图 6)。为充分挖掘光谱的局部判别信息，本文进一步提出一种分段独立 CBAM 架构(SI-CBAM)，将光谱分段策略与 CBAM 注意力机制深度融合。

#### 3.2.1. 分段策略设计

本文设计两种分段策略进行对比：

策略 A：光谱平均分段。将 331 个波长点等间隔划分为 k 段(k = 4, 5)，每段长度分别为 83 (末段 82) 或 66 (末段 67)。该策略简单通用，不依赖先验光谱知识，旨在验证分段建模本身的有效性。

策略 B：基于光谱导数的非均匀分段。针对光谱曲线平缓但变化速率非均匀的特点，通过计算一阶导数(变化率)与二阶导数(曲率)，识别光谱变化趋势的突变点，以此作为分段边界。具体步骤如下：


1、边界确定：通过平均光谱求一阶导数，定位导数绝对值由大变小、由正转负或由负转正的转折点；结合二阶导数过零点确认拐点位置，避免噪声干扰。

2、分段结果：综合考虑导数变化显著性与区域连续性，将 331 个波长点划分为 4 个连续子区间：[740, 830)、[830, 910)、[910, 990)、[990, 1070]。

3、区域光谱特性分析：

区域 1 (740~830)：初始响应区，光谱值从约-2.6 单调递增至 0 附近，一阶导数绝对值较大( $\approx 0.02\sim 0.05$ )，为全谱变化最陡峭区域，可能对应样品表面散射或仪器响应起始特征；区域 2 (830~910)：核心稳定区，一阶导数接近零( $|\Delta| < 0.01$ )，光谱起伏最小，体现样品主体成分的稳定吸收；区域 3 (910~990)：过渡变化区，一阶导数由正值转为负值，光谱出现轻微转折，可能 C-H 化学键的弱吸收。区域 4 (990~1070)：尾部特征区，一阶导数负向增大(约-0.04~-0.07)，变化幅度最为剧烈。

该非均匀分段策略使分段边界与光谱自身物理变化规律高度契合，为后续注意力模块提供了更具解释性的结构化先验。大麦光谱曲线图如图 6 所示。

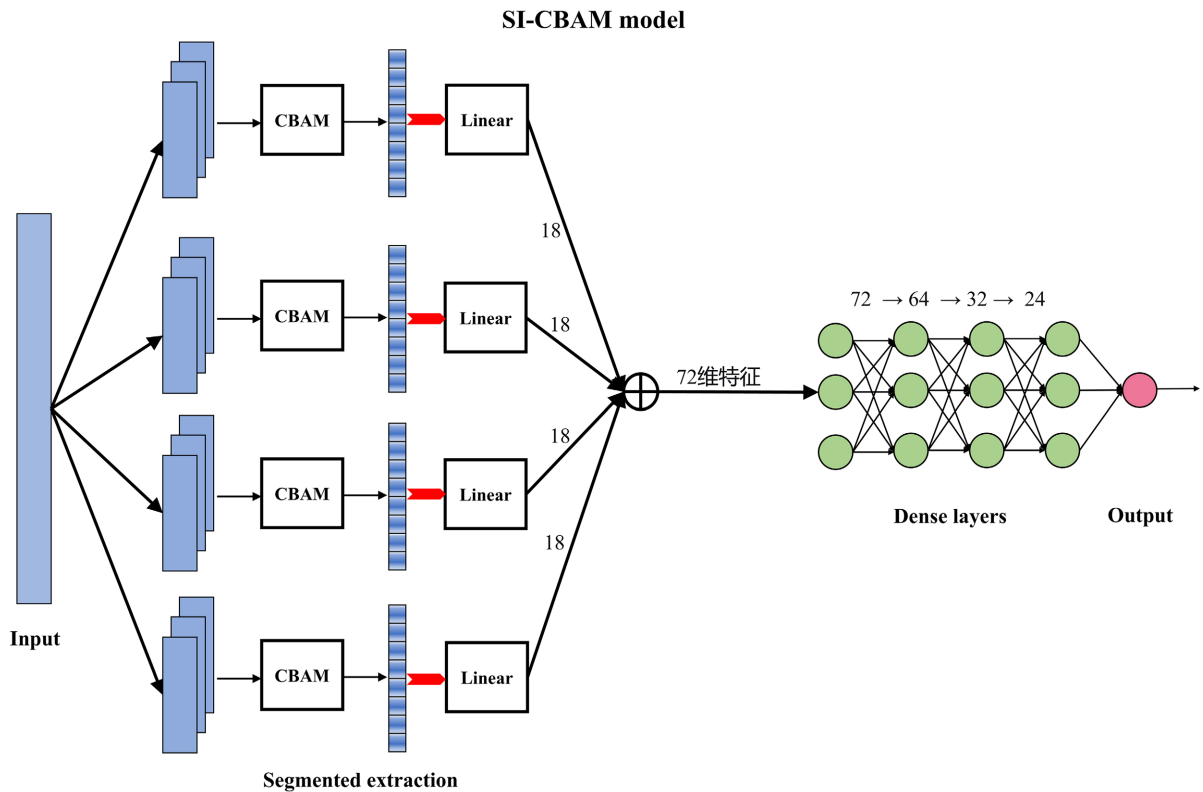


**Figure 6.** Spectral curve diagram of barley. (A), (B), and (C) respectively display the raw average spectrum, the first derivative (reflecting the rate of change), and the second derivative (reflecting curvature)

**图 6.** 大麦光谱曲线图。(A)、(B)、(C)分别展示了原始平均光谱、一阶导数(反映变化率)和二阶导数(反映曲率)

### 3.2.2. SI-CBAM 网络结构

首先将原始光谱按预设边界划分为多个连续的子区间(例如四个分段)，每个光谱子区间通过一个一维卷积层来提取该区域的局部特征，生成对应的特征图，再将特征图输入 CBAM 模块，依次执行通道注意力和空间注意力操作，以对特征进行加权增强。然后，将特征图展平为一维向量，并通过一个线性层得到 18 个局部特征。所有分段的 18 维特征向量按序拼接，形成 72 维的融合特征向量，最终送入分类器完成品种分类。其中，每个分段的处理流程可概括为： $\text{Conv1d}(1 \rightarrow 32) \rightarrow \text{CBAM} \rightarrow \text{展平} \rightarrow \text{Linear}(18)$ 。分类器由三层全连接网络构成，维度变换路径为  $72 \rightarrow 64 \rightarrow 32 \rightarrow 24$ ；为缓解过拟合，全连接层之间引入了概率为 0.2 的 Dropout 操作。训练过程中使用 Adam 优化器，初始学习率设为 0.001，并通过 ReduceLROnPlateau 算法动态调整学习率。SI-CBAM 的整体结构示意图如图 7 所示。



**Figure 7.** Schematic diagram of the overall structure of SI-CBAM  
**图 7.** SI-CBAM 的整体结构示意图

### 3.2.3. 实验结果分析

由表 2 可知,四段非平均 SI-CBAM 取得了最佳性能:交叉验证准确率 0.8452,测试集准确率 0.8333,较全局 CBAM 提升 4.2%,较 SVM-多项式提升 15.8%。这一结果表明,在光谱曲线平缓且无明显吸收峰的情况下,基于光谱变化规律的自适应分段策略能够引导注意力模块聚焦于不同谱段内的局部细微变化,从而提取到比全局模型更具判别性的特征。

**Table 2.** Classification performance of the Segment-Independent CBAM model  
**表 2.** SI-CBAM 模型的分类性能

分类方法	特征数	交叉验证	准确率
全局 CBAM	64	0.8214	0.8000
4 段平均 SI-CBAM	18 × 4	0.8274	0.8139
5 段平均 SI-CBAM	14 × 5	0.8274	0.8000
4 段非平均 SI-CBAM	18 × 4	<b>0.8452</b>	<b>0.8333</b>

值得注意的是,四段平均 SI-CBAM (等间隔分段)的性能(交叉验证 0.8274,准确率 0.8139)略低于四段非均匀策略,但仍优于全局 CBAM 模型。这表明,即使是无物理先验的均匀分段,也能通过“分而治之”的方式缓解全局建模的压力,验证了分段策略本身的普适价值。然而,其性能不及非均匀分段,进

一步说明在分段设计中融入光谱物理特征能够带来额外的增益。这一对比启示我们：分段策略的设计需同时兼顾光谱物理意义与数据驱动需求——既要尊重光谱本身的变化规律，也要保证各子区间具有足够的信息容量以支持局部特征学习。二者并非互斥，而应在具体任务中动态平衡，方能充分发挥分段注意力架构的建模优势。

#### 4. 总结

综合上述实验结果，本文所提出的全局注意力 CBAM 模型在近红外光谱分类任务上优于 RF 与 SVM 等传统方法，验证了通道-空间双重注意力机制在光谱特征提取中的有效性与鲁棒性。在此基础上，进一步设计的 SI-CBAM 通过引入光谱分段策略，使模型能够针对不同谱段的局部变化特性进行精细化特征学习。实验结果表明，四段非平均分段策略与光谱平缓变化规律高度契合，取得了最佳性能(准确率 0.8333, 交叉验证 0.8452)。同时，四段与五段平均分段策略的性能提升有限，亦从反面说明分段数量与边界选择需与光谱本身的结构特征相匹配，盲目增加分段或采用固定规则并非总是有效。综上，CBAM 及其分段变体不仅提升了近红外光谱的分类精度，也为光谱深度学习模型的轻量化与可解释性提供了新思路。

#### 致 谢

作者感谢研究生培养经费的资助。

#### 参考文献

- [1] Courand, A., Metz, M., Héran, D., Feilhes, C., Preznan, F., Serrano, E., *et al.* (2022) Evaluation of a Robust Regression Method (RoBoost-PLSR) to Predict Biochemical Variables for Agronomic Applications: Case Study of Grape Berry Maturity Monitoring. *Chemometrics and Intelligent Laboratory Systems*, **221**, Article ID: 104485. <https://doi.org/10.1016/j.chemolab.2021.104485>
- [2] Huang, Y., Dong, W., Chen, Y., Wang, X., Luo, W., Zhan, B., *et al.* (2021) Online Detection of Soluble Solids Content and Maturity of Tomatoes Using Vis/NIR Full Transmittance Spectra. *Chemometrics and Intelligent Laboratory Systems*, **210**, Article ID: 104243. <https://doi.org/10.1016/j.chemolab.2021.104243>
- [3] Gomez, J., Barquero-Pérez, O., Gonzalo, J., Salgüero, S., Riado, D., Luisa Casas, M., *et al.* (2024) Near Infrared Spectroscopy (NIRS) and Machine Learning as a Promising Tandem for Fast Viral Detection in Serum Microsamples: A Preclinical Proof of Concept. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, **322**, Article ID: 124819. <https://doi.org/10.1016/j.saa.2024.124819>
- [4] 花锦, 赵悠悠, 高媛惠, 等. 基于近红外技术快速测定不同鲜肉中脂肪含量[J]. 光谱学与光谱分析, 2017, 37(11): 3424-3429.
- [5] 杨逍, 陈世国, 许鑫. 基于支持向量机混合遗传算法的分类模型[J]. 电脑编程技巧与维护, 2025(8): 41-43.
- [6] 宋小东, 戴希红, 宗成明, 等. 基于支持向量机技术识别降雨图像[J]. 航海技术, 2025(6): 13-17.
- [7] Nikitin, N.Y. and Stepashkin, A.A. (2025) Classification of Tensile Test Results of Unidirectional Carbon Fiber-Poly-sulfone Composite Material Based on Random Forest, KNN and CNN Methods. *Results in Materials*, **28**, Article ID: 100788. <https://doi.org/10.1016/j.rinma.2025.100788>
- [8] Mohamed Sabri, A.A., Tomy, S. and Za'in, C. (2025) Comparative Machine Learning Analysis for Gold Mineral Prediction Using Random Forest and XGBoost: A Data-Driven Study of the Greater Bendigo Region, Victoria. *Geomatica*, **77**, Article ID: 100066. <https://doi.org/10.1016/j.geomat.2025.100066>
- [9] 张宸嘉, 朱磊, 俞璐. 卷积神经网络中的注意力机制综述[J]. 计算机工程与应用, 2021, 57(20): 64-72.
- [10] 任欢, 王旭光. 注意力机制综述[J]. 计算机应用, 2021, 41(S1): 1-6.
- [11] 杜俊, 吕浩音, 姚云霞. 基于 YOLOv5n 和 CBAM 注意力机制的农作物病虫害检测方法研究[J]. 电脑知识与技术, 2025, 21(29): 1-6.
- [12] 王美华, 吴振鑫, 周祖光. 基于注意力改进 CBAM 的农作物病虫害细粒度识别研究[J]. 农业机械学报, 2021, 52(4): 239-247.

- 
- [13] 付国栋, 黄进, 杨涛, 等. 改进 CBAM 的轻量级注意力模型[J]. 计算机工程与应用, 2021, 57(20): 150-156.
- [14] Zhang, J., Bai, X., Wu, J. and Zhou, B. (2025) Nondestructive Detection Method for Soluble Solids Content and Titratable Acidity Content in Pepino Melons Based on Vis/NIR Spectroscopy and Dual-Attention Enhanced 1D-CNN. *Journal of Food Composition and Analysis*, **148**, Article ID: 108232. <https://doi.org/10.1016/j.jfca.2025.108232>
- [15] Kosmowski, F. and Worku, T. (2018) Evaluation of a Miniaturized NIR Spectrometer for Cultivar Identification: The Case of Barley, Chickpea and Sorghum in Ethiopia. *PLOS ONE*, **13**, e0193620. <https://doi.org/10.1371/journal.pone.0193620>
- [16] 陈嘉, 高丽, 叶发银, 等. 基于近红外光谱与支持向量机的甘薯粉丝掺假快速检测[J]. 食品与发酵工业, 2019, 45(11): 211-218.
- [17] Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5-32. <https://doi.org/10.1023/a:1010933404324>
- [18] Cortes, C. and Vapnik, V. (1995) Support-Vector Networks. *Machine Learning*, **20**, 273-297. <https://doi.org/10.1023/a:1022627411411>
- [19] Wu, H., Wang, D., Huang, Q. and Gao, L. (2018) Real-Time Continuous Recognition of Knee Motion Using Multi-Channel Mechanomyography Signals Detected on Clothes. *Journal of Electromyography and Kinesiology*, **38**, 94-102. <https://doi.org/10.1016/j.jelekin.2017.10.010>
- [20] Liu, Z., Wang, L., Zhang, Y. and Chen, C.L.P. (2016) A SVM Controller for the Stable Walking of Biped Robots Based on Small Sample Sizes. *Applied Soft Computing*, **38**, 738-753. <https://doi.org/10.1016/j.asoc.2015.10.029>
- [21] Yin, H.-P. and Ren, H.-P. (2021) Direct Symbol Decoding Using GA-SVM in Chaotic Baseband Wireless Communication System. *Journal of the Franklin Institute*, **358**, 6348-6367. <https://doi.org/10.1016/j.jfranklin.2021.06.012>
- [22] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. In: Ferrari, V., et al., Eds., *Computer Vision—ECCV 2018*, Springer International Publishing, 3-19. [https://doi.org/10.1007/978-3-030-01234-2\\_1](https://doi.org/10.1007/978-3-030-01234-2_1)