

万仕文,冯耀泽,舒国强,等.基于高光谱和多头注意力机制的草鱼鲜味强度检测[J].华中农业大学学报,2025,44(5):280-287.
DOI:10.13300/j.cnki.hnlkxb.2025.05.028

基于高光谱和多头注意力机制的草鱼鲜味强度检测

万仕文^{1,2,3,4},冯耀泽^{2,3,4,5,6},舒国强²,赵名泉²,
王益健²,孔丽琴²,朱明^{2,5,6}

1. 华中农业大学信息学院,武汉 430070; 2. 华中农业大学工学院,武汉 430070;
3. 华中农业大学深圳营养与健康研究院,深圳 518000; 4. 中国农业科学院深圳农业基因组研究所/
岭南现代农业科学与技术广东省实验室深圳分中心,深圳 518120; 5. 农业农村部长江中下游农业装备实验室,
武汉 430070; 6. 农业农村部水产养殖重点实验室,武汉 430070

摘要 针对现有鲜味强度检测方法主观性强、耗时长和样本破坏性等问题,使用深度学习和机器学习算法结合高光谱成像技术构建草鱼鲜味强度快速无损检测方法。采集草鱼高光谱数据后,使用竞争性自适应重加权抽样法选取光谱特征波长,开发高斯加权多头注意力网络(gaussian-weighted multi-head attention network, GMANet)并应用支持向量机回归(support vector machine regression, SVR)、偏最小二乘回归(partial least squares regression, PLSR)、随机森林(random forest, RF)、1D-ResNet等传统算法建立和优化草鱼鲜味检测模型。结果显示,GMANet网络的预测均方根误差RMSEP 和预测决定系数(R_p^2)分别为0.008 2 和0.884 4,优于传统算法中的最优建模方法SVR,其RMSEP 和 R_p^2 分别为0.007 7 和0.818 8。

关键词 草鱼;高光谱;鲜味强度;深度学习;高斯加权多头注意力网络;感官分析

中图分类号 TP391.4 **文献标识码** A **文章编号** 1000-2421(2025)05-0280-08

草鱼是我国主要的商业淡水养殖鱼类,约占全国养殖淡水鱼的21.44%,年养殖量为594万t^[1]。在草鱼高消费量的背景下,其感官品质成为影响市场竞争力的重要因素。鲜味是草鱼肉质品质评价的重要感官指标之一,不仅影响消费者的味觉体验,还关系到草鱼产品的市场竞争力与附加值^[2]。因此,对草鱼鲜味强度进行检测研究具有重大意义。

传统的鲜味强度检测方法主要有仪器分析法和感官评价法,其中仪器分析法通过测定鲜味氨基酸和5'-核苷酸的含量,计算出等效鲜味强度(equivalent umami concentrations, EUC),以此间接推断鲜味强度^[3]。然而,该方法在计算EUC时忽略了除氨基酸和核苷酸之外其他鲜味物质的贡献,这可能导致鲜味强度评估的准确性受到影响^[4-5]。感官评价法则通过专业品评人员的味觉直接评估,可对鲜味属性进行系统的评价^[6]。但是感官评价过程需要大量的时间和人员投入,难以实现高通量的样品分析,无法满足现代化农业快速无损的需求。

高光谱成像技术可以同时获取样本的图像信息与光谱信息,具备快速、无损、准确等特点^[7],近年来被广泛应用于鱼类品质检测^[8]。Cao等^[9]利用高光谱技术结合多种机器学习算法,通过光谱曲线建立模型,成功预测了鲤鱼肌肉中的多不饱和脂肪酸含量。詹白勺等^[10]基于获取的三文鱼光谱曲线,采用偏最小二乘法(partial least squares, PLS)建立了水分含量预测模型,其预测模型的决定系数 R_p^2 为0.904。Sun等^[11]利用高光谱成像技术结合多种特征波长筛选方法,通过光谱曲线建立了测定不同冻融时间鮰鱼EUC的方法。Zhang等^[12]基于大口黑鲈的光谱曲线,采用最小二乘回归算法建立电导率预测模型,其预测模型的决定系数 R_p^2 为0.856 9。这些研究表明,高光谱技术能够实现对鱼类品质的高效、无损且准确的检测。然而,目前鲜有基于高光谱成像技术对草鱼鲜味强度检测的相关研究。此外,传统的高光谱分析方法通常仅利用光谱曲线,未能充分挖掘高光谱图像的空间信息。而深度学习网络能够直接将

收稿日期:2024-12-24

基金项目:湖北省重点研发计划项目(2023BBB038);华中农业大学-深圳营养与健康研究院合作基金项目(SZYJY2021028)

万仕文,E-mail:wsw_2022@webmail.hzau.edu.cn

通信作者:冯耀泽,E-mail:Yaoze.feng@mail.hzau.edu.cn

完整的高光谱图像即光谱矩阵作为输入,通过卷积层自动学习空间特征,不仅能够捕捉高光谱图像中的局部纹理特征,还能提取全局结构信息。通过多层次的特征提取,深度学习网络不仅能够分析每个像素的光谱数据,还能识别空间关系,从而提升检测精度并增强模型的泛化能力。

本研究以微流水处理不同时间的草鱼为研究对象,采集鱼肉高光谱,并通过感官评估分析样品的鲜味强度。在此基础上,分别基于预选波长后的光谱矩阵与光谱曲线,使用高斯加权多头注意力网络以及支持向量机回归(support vector machine regression, SVR)、主成分回归(principal component regression, PCR)、偏最小二乘回归(partial least squares regression, PLSR)、极限学习机回归(extreme learning machine regression, ELMR)、随机森林(random forest, RF)和1D-ResNet等传统算法对草鱼高光谱鲜味强度进行检测,旨在通过高光谱技术与智能算法的融合,克服传统鲜味评价方法效率低、破坏性强的局限,提升水产品鲜味强度无损检测精度,并为水产加工智能化提供理论与技术支撑。

1 材料与方法

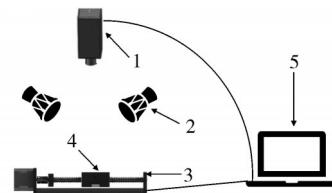
1.1 试验样本

鲜活草鱼微流水处理0、3、6 d,得到不同鲜味强度的草鱼样本^[13],在处理对应时间后,敲击草鱼头部致晕,去除内脏、鳞片和表皮,使用无菌手术刀取鱼背部肌肉,每块鱼肉长、宽均约为5 cm,厚度约为1 cm,获得348份鱼肉样品用于光谱数据采集。

本研究采用的光谱采集系统主要由高光谱成像仪(SPECIM, V10E, Finland)、散热风扇、采集箱、高精度电控移动可升降平台(北京卓立汉光仪器有限公司,HISA-TSA300-IMS,中国)、卤素灯光源和计算机(联想, ThinkPad)等组成。其中,光谱仪可以采集到的波长范围为300~1 100 nm,光谱分辨率为2.8 nm。为减小试验仪器噪声对图像采集结果的影响,在每次打开仪器后,需要对仪器预热0.5 h^[14]。试验时,系统参数为:曝光时间为0.1 s,电控移动平台移动速度为1.8 mm/s,平台移动距离设置为280 mm。在拍摄高光谱时,为避免发生镜面反射,需要用滤纸吸干表面水分,并将样本有序放置在黑色背景板上进行扫描。采集装置如图1所示。

1.2 鲜味强度测定

参照Wang等^[5]开展草鱼鲜味强度的感官评估。



1.高光谱成像仪 Hyperspectral imaging system;2.卤素灯源 Halogen light source;3.电控可移动升降平台 Electronically controlled movable lifting platform;4.载物台 Sample stage;5.计算机 Computer.

图1 高光谱图像采集系统

Fig.1 Hyperspectral image acquisition system

将采集完高光谱图像的鱼肉样本进行真空包装,80 °C水浴加热15 min;通过配对比较法评估样品的相对谷氨酸钠含量,含量梯度设置为0.125 9%、0.141 3%、0.158 5%、0.177 8%和0.199 5%。将待测样品与所有样品进行对比,依据感官评选员的判断结果确定待测样品的相对谷氨酸钠浓度。确定相对浓度后,将其代入公式(1),计算样品的感官鲜味强度值。

$$U_1 = 9.6828 \times \lg C_{MSG} + 34.8 \quad (1)$$

其中, U_1 为鲜味强度, C_{MSG} 为谷氨酸钠浓度。

1.3 黑白校正

由于使用高光谱成像系统收集的原始光谱图像含有较多噪声和冗余信息,因此需要使用黑板和白板作为参考图像对原始图像进行校正。黑白校正能够消除传感器固有误差和环境因素的影响,从而确保数据的准确性。在样本采集完成后,采集白板的全反射校正图像 R_W ,遮住镜头采集全黑校正图像 R_B ,然后根据公式(2)计算得到校正后的图像相对反射率 R 。

$$R = \frac{R_S - R_B}{R_W - R_B} \quad (2)$$

其中, R_S 为采集的原始高光谱图像, R_W 为全白校正图像, R_B 为全黑校正图像, R 为校正后得到的光谱反射率图像。

1.4 图像信息提取

高光谱图像中除了鱼肉样本外还包含大量背景信息,为了减少背景光谱对样品光谱分析的干扰,需要提取感兴趣区域(ROI)。本研究采用大津算法对图像进行阈值分割,通过自动确定阈值来区分鱼肉样本和背景。然后,使用最小外接矩形包围鱼肉样本的区域,最终从矩形内提取光谱数据得到平均光谱数据。

1.5 特征波长选择

竞争性自适应重加权抽样法(competitive adap-

tive reweighted sampling, CARS)通过动态调整波长权重,逐步优化波长选择过程。该方法通过竞争性机制评估每个波长对目标任务的贡献,并自适应调整其权重,从而最终筛选出最重要的波长。为消除光谱中的冗余信息,本研究采用CARS方法选择特征波长,去除不含关键信息的波长,减少建模变量,进而提高建模效率和准确性^[15-16]。

1.6 样本集的划分

获取高光谱数据与鲜味强度数据后,为了进行模型训练和测试,需要对样本集进行划分,以便评估模型的性能。在使用传统机器学习算法对鲜味强度进行建模检测时,本研究采用了光谱-理化值共生距离法(sample set partitioning based on joint x-y distance, SPXY)进行样本集的划分,该方法能够有效地

控制样本的多样性和代表性。划分后的样本集分为校正集和预测集,比例为3:1,其中校正集包含261个样本,用于训练和调整模型参数,预测集包含87个样本,用于评估模型的预测性能。在使用深度学习神经网络方法进行鲜味建模检测时,由于深度学习算法具有较强的自适应能力和对大规模数据的处理能力,因此选择随机划分的方法,这种划分方式能够确保训练集和测试集具有较好的数据代表性,校正集与预测集的比例同样为3:1。

1.7 建模方法

本研究为更好地提取光谱的空间信息提出了基于高斯加权的特征标记^[17]与Transformer多头注意力结合的GMANet(gaussian-weighted multi-head attention network)网络,网络结构如图2所示。

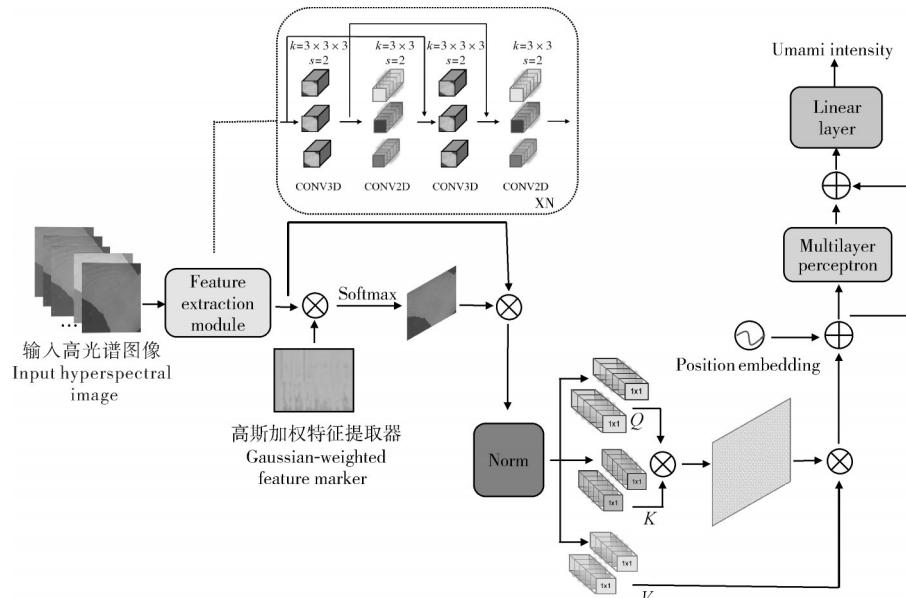


图2 GMANet网络结构图

Fig.2 Structure of deep learning network GMANet

网络主要由特征提取模块(feature extraction module, FEM)、高斯加权特征标记器(gaussian-weighted feature marker, GFM)、多头注意力编码器(multi-head attention encoder, MAE)3个部分组成。

FEM主要由大小为 3×3 的三维卷积核和二维卷积核组成,每个卷积操作的步幅和填充分别设置为2和1。首先,特征提取模块通过8个三维卷积核对输入大小为 $p \times p \times c$ 的光谱块进行卷积操作,提取光谱空间信息,生成8个覆盖光谱空间信息的三维特征图,作为输入传递到下一层的二维卷积。二维卷积主要用于将高维的空间信息压缩至较低的维度,提取出更具辨识度的空间特征,保留重要的局部

空间结构,同时减少冗余信息,两者之间通过残差结构连接。

经过上层卷积处理后,提取的特征包含光谱信息和空间信息,但这些特征仍不足以充分描述鱼肉鲜味强度与光谱之间的复杂关系。因此,使用GFM将特征转换为语义标记,具体操作如公式(3)。

$$T = \text{SoftMax}(XW_a)^TX \quad (3)$$

其中, W_a 表示使用高斯分布初始化的权重矩阵, X 为上层卷积得到的特征。首先,将权重矩阵应用于上层特征进行加权,接着使用SoftMax操作将加权结果转换为概率分布。这样做的目的是通过加权与特征选择,使模型能够自动聚焦于重要的特征

区域。高斯加权通过为每个特征分配一个权重,使得与鱼肉鲜味强度相关的关键区域获得更高的关注度,而不相关或冗余的部分则被削弱^[18]。最后,将特征映射为语义组,并与 X 相乘后得到语义标记。

MAE 用于学习高级语义特征之间的关系,主要是对语义标记之间的深层关系进行建模,其中最重要的部分为多头注意力模块(multi-head self-attention, MSA)^[19]。在鱼肉光谱鲜味强度检测的任务中,鱼肉的光谱数据中丰富的空间和光谱信息对捕捉鲜味强度至关重要。传统的特征提取方法可能无法充分捕捉光谱数据中微小的变化,而多头注意力机制通过并行计算多个注意力头,能够捕捉不同维度的特征之间的复杂关系^[19]。

具体来说,首先将输入特征 X 映射到查询(Q)、键(K)和值(V)矩阵(公式(4)),并通过计算 Q 和 K 之间的相似度和使用 SoftMax 归一化后得到注意力权重(公式(5))。

$$Q = XW^Q, \quad K = XW^K, \quad V = XW^V \quad (4)$$

$$SA = \text{Attention}(Q, K, V) = \text{SoftMax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

其中, W^Q 、 W^K 、 W^V 是可学习的参数, d_k 是键的维度, SoftMax 函数用于归一化权重。每个注意力头计算得到一个加权的输出。在这个过程中,模型能够捕捉到不同光谱通道之间的相关性,某些光谱通道可能对鱼肉的鲜味强度更为敏感,而其他通道可能代表与空间位置相关的特征。通过并行计算多个注意力头,模型能够同时捕捉来自不同光谱区域和空间区域的信息,从而实现对鲜味强度的多角度分析。这些注意力头的输出结果通过拼接(Concat)和 1 个线性变换矩阵 W_O 的综合处理,得到最终的特征表示 MSA(X):

$$MSA(X) = \text{Concat}(SA_1, SA_2, \dots, SA_n)W_O \quad (6)$$

最后,将学习到的特征表示输入到多层次感知机(multilayer perceptron, MLP)预测鱼肉的鲜味强度,MLP 主要由 2 个全连接层与非线性激活函数 GELU 组成,最后通过线性层进行输出预测。

同时,为验证 GMANet 对草鱼鱼肉光谱鲜味强度检测的有效性,本研究同时使用传统机器学习算法 SVR、PLSR、PCR、ELMR、RF 算法和同样使用一维光谱数据的 1D-ResNet 网络进行建模分析。

1.8 模型的评价

采用校正决定系数(R_C^2)、预测决定系数(R_P^2)和

校正均方根误差(RMSEC)、预测均方根误差(RMSEP)来评价模型对鱼肉鲜味强度预测的准确性和稳定性,决定系数越接近 1、均方根误差越小,说明模型的精度越高。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (8)$$

其中, y_i 是真实鲜味强度, \hat{y}_i 是模型预测鲜味强度, \bar{y} 是真实鲜味强度的平均值, n 是样本集总数。

2 结果与分析

2.1 鱼肉样本的原始光谱特性与波长选择

因光谱在 300~450 nm 和 900~1 100 nm 波段时信噪比不高,故选取 450~900 nm 之间的光谱进行后续分析,微流水处理不同时间的草鱼鱼肉平均光谱及特征波长选择结果如图 3 所示。由图 3 草鱼平均光谱可知,光谱在 550 nm 处存在明显吸收峰,可能与 C=O 键的伸缩振动有关^[20],不同时间样本在 450~900 nm 波段范围内的平均光谱曲线出现较大差异,这可能与鱼的代谢活动相关。在微流水处理的前几天,草鱼体内的糖原和脂肪分解,提供能量支持,同时产生核苷酸,随着处理时间的延长,草鱼开始分解蛋白质,释放氨基酸,尤其是谷氨酸和甘氨酸,这些物质是鲜味的关键成分。谷氨酸和核苷酸中均含有 C=O 键^[21],其在 550 nm 处的振动特征影响了草鱼的光谱反射率。因此使用采集的光谱对不同预处理时间下草鱼的鲜味强度进行区分是具有一定可行性的。

由图 3 可知,所选取的特征波长在 450~900 nm 范围内总体分布较为均匀,在 550 nm 的吸收峰和 650 nm 的吸收谷处,特征波长的选取呈现出一定的聚集趋势,这可能与氨基酸、核苷酸等鲜味物质中的 C=O 键和 NH₂ 键在这个波长的伸缩振动有关。

2.2 鲜味强度检测结果

GMANet、1D-ResNet、ResNet 的所有训练过程均在深度学习服务器上进行。在训练开始时,设置学习率为 4×10^{-4} 。在后续的训练过程中采用余弦退火策略调整学习率,学习率会按照余弦函数的曲线逐渐减小,直到 1×10^{-6} 。训练过程中,损失值随训练轮次(epoch)的变化趋势如图 4 所示。由图 4 可知,在前 200 个 epoch,所有模型的训练损失均在迅速下降,但在第 50~100 个 epoch 时,1D-ResNet 和

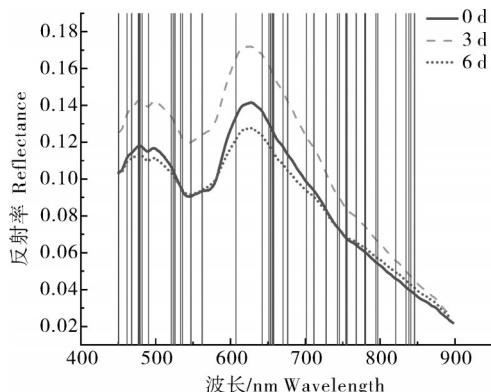


图3 草鱼平均光谱图像及波长选择结果

Fig.3 Average spectral images of grass carp and results of characteristic wavelength selection

ResNet模型的训练损失曲线均产生了较大幅度的震荡,GMANet的震荡幅度则明显更小,表明GMANet在训练过程中具有更好的鲁棒性。在第250个epoch左右时,所有模型的损失曲线均趋于平稳,模型达到收敛,GMANet损失值收敛至接近0.05,1D-ResNet损失值收敛至约0.18,ResNet损失值收敛至约0.16。

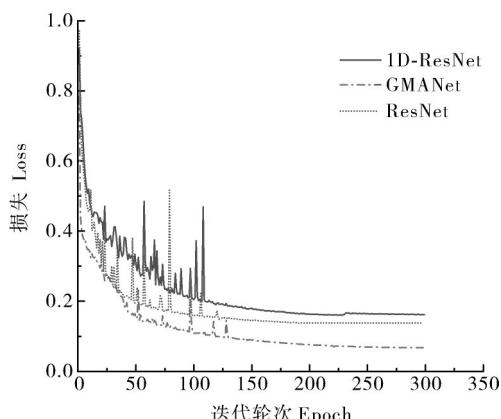


图4 训练过程损失函数变化曲线

Fig.4 Loss function variation curve during training

为检验GMANet网络对鱼肉光谱鲜味强度预测的有效性,将GMANet网络与SVR、ELMR、PCR、PLSR、RF和1D-ResNet算法进行对比,具体结果如表1所示。从表1可以看出,大部分建模方法均取得了较好的检测结果,其中GMANet网络的预测效果最佳,其RMSEC和 R^2_C 为所有建模方法中的最优值,分别为0.005 6和0.921 4,并且在预测集中也保持较好的性能,RMSEP和 R^2_P 分别为0.008 2和0.884 4,表明GMANet网络具有较强的拟合能力与泛化能力。传统算法中最优模型是SVR算法建立的检测模型,具有较好的稳定性,校正集与预测集的RMSE与 R^2 分别仅相差0.000 1、0.002,但与GMANet网络仍

存在一定差距。ELMR方法在校正集中表现较好, RMSEC和 R^2_C 分别为0.006 4和0.867 5,但ELMR方法在预测集中性能略有下降,RMSEP和 R^2_P 分别为0.009 1、0.758 6,表明ELMR方法在泛化能力上不如GMANet网络和SVR。相比之下,PLSR、PCR和RF算法建立的模型则表现较为一般,尤其是PCR,其训练集和测试集的RMSE分别仅为0.010 7和0.011 1, R^2 分别为0.633 1和0.601 5。

表1 鱼肉光谱鲜味检测结果

Table 1 Fish spectrum umami taste test results

方法 Method	校正均方根 误差 RMSEC	校正决定 系数 R^2_C	预测均方根 误差 RMSEP	预测决定 系数 R^2_P
SVR	0.007 6	0.816 8	0.007 7	0.818 8
ELMR	0.006 4	0.867 5	0.009 1	0.758 6
PLSR	0.007 8	0.806 5	0.009 6	0.704 1
PCR	0.010 7	0.633 1	0.011 1	0.601 5
RF	0.008 0	0.716 1	0.008 8	0.633 0
1D-ResNet	0.007 9	0.700 6	0.008 8	0.680 4
GMANet	0.005 6	0.921 4	0.008 2	0.884 4

相较于同样使用一维光谱的SVR、ELMR等方法,1D-ResNet模型检测效果较差, R^2_P 仅为0.680 4,可能是因为1D-ResNet没有较好地捕捉到高光谱数据中的非线性特征,而SVR等方法能够通过核函数更有效地处理高维数据的非线性关系。SVR、ELMR等算法在处理高光谱数据时,可能是因为无法充分利用数据的空间和光谱信息,导致在细节挖掘和规律识别方面有所欠缺,而GMANet模型通过多头注意力机制,在鱼肉高光谱图像中同时关注多个空间区域,从而能够捕捉到图像中的细微变化,尤其是在不同波段的光谱信息与空间特征之间的复杂关系。这种机制能够自适应地学习并挖掘数据中的长距离依赖关系。通过这种方式,GMANet不仅提高了对局部细节(如肌肉纹理、脂肪分布)的敏感度,还能够捕捉跨通道的复杂依赖,自动学习数据的层次特征和非线性关系,从而显著提升预测精度^[18,22]。

2.3 消融实验

为验证提出的基于高斯加权的特征标记与Transformer多头注意力结合的GMANet网络的有效性,进行了一系列消融实验。具体来说,以ResNet50作为基线网络进行对比,在GMANet网络的基础上去除高斯加权特征模块,仅保留Transformer多头注意力模块,记作GMANet-No-GFM,在GMANet网络的基础上去除Transformer多头注意

力模块,仅保留高斯加权特征模块,记作GMANet-No-MAE。消融实验结果如表2所示。

表2 消融实验结果

Table 2 Results of ablation experiments

模型 Method	校正均方 根误差 RMSEC	校正决定 系数 R_c^2	预测均方 根误差 RMSEP	预测决定 系数 R_p^2
ResNet50	0.013 2	0.665 4	0.015 9	0.632 6
GMANet-No-GFM	0.010 0	0.747 8	0.010 3	0.720 2
GMANet-No-MAE	0.013 3	0.686 8	0.016 3	0.668 5
GMANet	0.005 6	0.921 4	0.008 2	0.884 4
ResNet50	0.013 2	0.665 4	0.015 9	0.632 6

由表2可知,基线模型ResNet50仅通过深度残差结构提取光谱信息,而GMANet则在此基础上引入了高斯加权模块,对提取的特征进行加权,并通过多头注意力机制对特征进行深度建模。与基线网络相比,GMANet在各项评估指标上表现出显著优势,进一步验证了GMANet在高光谱图像处理中的有效性。由GMANet-No-GFM的实验结果可知,GMANet-No-GFM相对于GMANet在RMSE和 R^2 指标上均有所下降,其中RMSEC从0.005 6降至0.010 0, R_c^2 从0.921 4下降至0.747 8,RMSEP从0.008 2降至0.010 3, R_p^2 从0.884 4下降至0.720 2,说明高斯加权模块可以有效去除鱼肉光谱信息中的噪声与伪影,缺失该模块时,模型在处理光谱数据过程中未能有效区分有用信息和噪声,导致特征提取的精度降低,从而引发了性能的下降。同时,去除Transformer多头注意力模块的GMANet-No-MAE性能下降更为明显,校正集和预测集的 R^2 分别下降了0.234 6和0.215 9,这表明Transformer多头注意力模块通过自注意力机制有效捕捉鱼肉高光谱数据中的全局依赖关系,增强信息的整合与传递^[23],进而提升模型对鲜味强度预测的能力,尤其在处理复杂特征之间的关联时表现出显著优势。缺少这一模块时,模型在特征提取和信息整合方面的能力受到较大影响,从而导致性能大幅下降。

3 讨论

本研究针对草鱼鲜味强度检测主观性强、耗时长和样本破坏性等问题,以微流水处理不同时间的草鱼为对象,采集其高光谱图像,同时为充分利用草鱼高光谱空间图像信息,提出了一种基于高斯加权的特征标记与Transformer多头注意力结合的GMANet网络模型预测草鱼鲜味强度,并与SVR、ELMR、

1D-ResNet等传统建模算法对比其检测效果。

目前,鲜味品质在鱼类高光谱品质研究中的关注较为有限,本研究首次结合感官鲜味评估与深度学习方法,针对草鱼的高光谱鲜味强度进行检测。试验结果表明,GMANet网络的草鱼鲜味强度预测效果要优于传统算法最优模型SVR的预测效果, R_p^2 和RMSEP分别为0.884 4和0.008 2,相比SVR的预测集预测结果分别提升了6.49%和8.01%,在校正集和预测集上均取得更高的准确率。与使用一维光谱数据的1D-ResNet相比,GMANet也取得了较明显优势,GMANet网络的 R_p^2 较1D-ResNet提升了30.27%,RMSEP降低了7.31%。以上结果表明GMANet可以充分利用高光谱图像空间信息,与其它方法相比更适用于高光谱图像鲜味强度检测。同时,通过消融实验证明了高斯加权的特征标记模块与Transformer多头注意力模块对模型的贡献度。试验结果表明,在去除高斯加权的特征标记模块时,模型无法正确区别噪声伪影与有效光谱信息,导致特征提取的精度降低,在去除多头注意力模块时,模型特征提取能力降低、信息整合效果偏差,只有当2个模块同时使用时,模型的性能才得到显著提升。

本研究设计的GMANet网络实现了对草鱼鲜味强度的无损高精度预测,表明GMANet网络可以充分利用草鱼高光谱的空间图像与频谱信息进行鲜味强度检测,可作为一种新的方法在后续基于高光谱的品质检测研究中进行应用。本研究目前仅使用了优选特征波长的光谱数据,并聚焦于草鱼鲜味强度的单一指标检测。未来研究将基于全波长鱼肉光谱数据,同时联合检测脂肪含量、水分等多维参数,构建多任务学习框架,以实现鱼肉产品的综合性品质评估。

参考文献 References

- [1] 中华人民共和国农业农村部渔业渔政管理局,全国水产技术推广总站,中国水产学会.中国渔业统计年鉴[M].北京:中国农业出版社,2024. Fishery Administration Bureau of the Ministry of Agriculture and Rural Affairs of the People's Republic of China, National Aquaculture Technology Promotion Station, China Fisheries Society. China. Fisheries statistical yearbook [M]. Beijing: China Agricultural Press, 2024(in Chinese).
- [2] 阮秋凤,安琪琦,陈周,等.短时间微流水处理对草鱼肉风味品质的影响[J].食品科学技术学报,2021,39(3):30-42. RUAN Q F, AN Y Q, CHEN Z, et al. Effect of short-time micro-flow water treatment on flavor quality of grass carp fish

- meat[J].Journal of food science and technology,2021,39(3):30-42(in Chinese with English abstract).
- [3] ZHU Y W, WANG J, WANG W L, et al. The evaluation of overall umami intensity in *Takifugu obscurus* and *Ctenopharyngodon idella* based on the Steven's law [J]. Journal of food measurement and characterization, 2020, 14(1):527-534.
- [4] DONG F J, NIU Y H, BI Y Z, et al. Fusion of spectra and texture features of hyperspectral imaging for quantification and visualization of characteristic amino acid contents in beef[J/OL]. LWT, 2024, 206: 116576 [2024-12-24]. <https://doi.org/10.1016/j.lwt.2024.116576>.
- [5] WANG Y J, WAN S W, PAN S, et al. A quantitative equation for umami evaluation of food and condiments based on the Weber-Fechner law [J/OL]. Food quality and preference, 2025, 123: 105347 [2024-12-24]. <https://doi.org/10.1016/j.foodqual.2024.105347>.
- [6] PHAT C, MOON B, LEE C. Evaluation of umami taste in mushroom extracts by chemical analysis, sensory evaluation, and an electronic tongue system [J]. Food chemistry, 2016, 192:1068-1077.
- [7] 丁子予,岳学军,曾凡国,等.基于机器学习和深度学习的玉米种子活力光谱检测[J].华中农业大学学报,2023,42(3):230-240.DING Z Y, YUE X J, ZENG F G, et al. Spectral detection of maize seed vigor based on machine learning and deep learning[J]. Journal of Huazhong Agricultural University, 2023, 42(3):230-240(in Chinese with English abstract).
- [8] ZOU Z Y, LI M H, WANG Q L, et al. A non-destructive detection method of protein and TVB-N content changes in refrigerated and frozen-thawed salmon fillets using fluorescence hyperspectral technology [J/OL]. Journal of food composition and analysis, 2024, 133: 106435 [2024-12-24]. <https://doi.org/10.1016/j.jfca.2024.106435>.
- [9] CAO Y M, ZHANG Y, WANG Q, et al. Skin hyperspectral imaging and machine learning to accurately predict the muscular poly-unsaturated fatty acids contents in fish [J/OL]. Current research in food science, 2024, 9: 100929 [2024-12-24]. <https://doi.org/10.1016/j.crefs.2024.100929>.
- [10] 詹白勺,章海亮,杨建国.基于高光谱成像技术的三文鱼肉水分含量的可视化研究[J].光谱学与光谱分析,2017,37(4):1232-1236.ZHAN B S, ZHANG H L, YANG J G. Visualization of the water content for salmon fish fillets based on hyperspectral imaging technique[J]. Spectroscopy and spectral analysis, 2017, 37 (4) : 1232-1236 (in Chinese with English abstract).
- [11] SUN Z B, PAN H D, ZUO M, et al. Non-destructive assessment of equivalent umami concentrations in salmon using hyperspectral imaging technology combined with multivariate algorithms [J/OL]. Spectrochimica acta part A: molecular and biomolecular spectroscopy, 2023, 285: 121890 [2024-12-24]. <https://doi.org/10.1016/j.saa.2022.121890>.
- [12] ZHANG W D, CAO A L, SHI P Y, et al. Rapid evaluation of freshness of largemouth bass under different thawing methods using hyperspectral imaging[J/OL]. Food control, 2021, 125: 108023 [2024-12-24]. <https://doi.org/10.1016/j.foodcont.2021.108023>.
- [13] 陈周,胡杨,安玥琦,等.短时间微流水处理对池塘养殖草鱼肉品质的提升作用[J].水产学报,2020,44(7):1198-1210.CHEN Z, HU Y, AN Y Q, et al. Quality improvement of short-time micro-flow water treatment on the flesh of grass carp (*Ctenopharyngodon idella*) cultured in a pond [J]. Journal of fisheries of China, 2020, 44(7) : 1198-1210 (in Chinese with English abstract).
- [14] 孙宗保,王天真,李君奎,等.高光谱成像的牛肉丸掺假检测[J].光谱学与光谱分析,2020,40(7):2208-2214.SUN Z B, WANG T Z, LI J K, et al. Detecting adulterated beef meatball using hyperspectral imaging technology [J]. Spectroscopy and spectral analysis, 2020, 40 (7) : 2208-2214 (in Chinese with English abstract).
- [15] 孔丽琴,牛晓虎,王程磊,等.高光谱技术在牛肉丸复合掺假类型鉴别中的应用[J].光谱学与光谱分析,2024,44(8):2183-2191.KONG L Q, NIU X H, WANG C L, et al. Application of hyperspectral imaging technology in the identification of composite adulteration type in beef balls [J]. Spectroscopy and spectral analysis, 2024, 44 (8) : 2183-2191 (in Chinese with English abstract).
- [16] 牛晓虎,冯耀泽,鲍雪,等.基于高光谱技术的细菌生物被膜分类检测[J].华中农业大学学报,2023,42(3):241-249.NIU X H, FENG Y Z, BAO X, et al. Classification and detection of bacterial biofilms based on hyperspectral fluorescence imaging [J]. Journal of Huazhong Agricultural University, 2023, 42 (3):241-249(in Chinese with English abstract).
- [17] SUN L, ZHAO G R, ZHENG Y H, et al. Spectral-spatial feature tokenization transformer for hyperspectral image classification[J/OL]. IEEE transactions on geoscience and remote sensing, 2022, 60:3144158[2024-12-24].<https://doi.org/10.1109/TGRS.2022.3144158>.
- [18] SHENG H M, LIU X, BAI L B, et al. Small sample state of health estimation based on weighted Gaussian process regression [J/OL]. Journal of energy storage, 2021, 41: 102816 [2024-12-24].<https://doi.org/10.1016/j.est.2021.102816>.
- [19] VASWANI A. Attention is all you need [DB/OL]. arXiv, 2017, 1706.03762 [2024-12-24]. <https://doi.org/10.48550/arXiv.1706.03762>.
- [20] 黄华成,吴雪梅,张珍,等.基于高光谱技术的绿色辣椒识别研究[J].计算机与数字工程,2024,52(8):2473-2478.HUANG H C, WU X M, ZHANG Z, et al. Research on recognition of green pepper based on hyperspectral technology [J]. Computer & digital engineering, 2024, 52(8) : 2473-2478 (in Chinese with English abstract).

- Chinese with English abstract).
- [21] 黄华丹, 邓健豪, 曹庸, 等. 基于近红外光谱技术快速检测广式酱油发酵过程中主要理化指标的含量[J]. 现代食品科技, 2024, 40(12): 386-401. HUANG H D, DENG J H, CAO Y, et al. Rapid determination of main physicochemical indexes of Cantonese soy sauce in the fermentation process based on near-infrared spectroscopy[J]. Modern food science and technology, 2024, 40(12): 386-401(in Chinese with English abstract).
- [22] LI Z Y, WANG D Y, ZHU T T, et al. Review of deep learning-based methods for non-destructive evaluation of agricultural products[J]. Biosystems engineering, 2024, 245: 56-83.
- [23] YU Z J, XIE T Y, ZHU Q B, et al. Aquatic plants detection in crab ponds using UAV hyperspectral imagery combined with transformer-based semantic segmentation model[J/OL]. Computers and electronics in agriculture, 2024, 227: 109656[2024-12-24]. <https://doi.org/10.1016/j.compag.2024.109656>.

Detection of umami intensity in grass carp based on hyper-spectrum and multi-attention mechanisms

WAN Shiwen^{1,2,3,4}, FENG Yaoze^{2,3,4,5,6}, SHU Guoqiang², ZHAO Mingquan²,
WANG Yijian², KONG Liqin², ZHU Ming^{2,5,6}

1. College of Informatics, Huazhong Agricultural University, Wuhan 430070, China;
2. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China;
3. Huazhong Agricultural University Shenzhen Institute of Nutrition and Health, Shenzhen 518000, China;
4. Shenzhen Branch of Guangdong Laboratory for Lingnan Modern Agriculture/Institute of Agricultural Genomics at Shenzhen, Chinese Academy of Agricultural Sciences, Shenzhen 518120, China;
5. Ministry of Agriculture and Rural Affairs Key Laboratory of Agricultural Equipment in Mid-Lower Yangtze River, Huazhong Agricultural University, Wuhan 430070, China; 6. Ministry of Agriculture and Rural Affairs Key Laboratory of Aquaculture Facilities Engineering, Huazhong Agricultural University, Wuhan 430070, China

Abstract Deep learning and machine learning algorithms combined with hyperspectral imaging technology were used to establish a fast and nondestructive method for detecting umami intensity in grass carp to solve the problems of strong subjectivity, long time-consumption and sample destructiveness in the current detection methods of umami intensity. The competitive adaptive reweighted sampling method was used to select the feature wavelengths of spectrum after collecting the hyperspectral data in grass carp. The Gaussian-weighted multi-head attention network (GMANet) was developed. The model of detecting umami intensity in grass carp was established and optimized with the support vector machine regression (SVR), partial least squares regression (PLSR) random forest (RF), 1D-ResNet and other algorithms. The results showed that the root mean square error of prediction (RMSEP) and the coefficient of determination of prediction (R_p^2) of GMANet network was 0.008 2 and 0.884 4, better than the RMSEP and R_p^2 of 0.007 7 and 0.818 8 in the optimal modeling method SVR in traditional algorithms. It is indicated that hyperspectral technology has a large application prospect in the detection of umami intensity and the GMANet network can make full use of the spatial image and spectral information of the samples. It will provide a new method for the further application of detection with hyperspectral image.

Keywords grass carp; hyper-spectrum; umami intensity; deep learning; gaussian-weighted multi-head attention network; sensory analysis

(责任编辑:陆文昌)