

基于神经网络的生鲜水产品货架期预测模型的构建及应用

崔方超¹, 毛智超¹, 李婷婷^{2*}, 励建荣^{1*}

(¹渤海大学食品科学与工程学院 生鲜农产品贮藏加工及安全控制技术国家地方联合工程研究中心

中国轻工业海水鱼加工重点实验室 辽宁锦州 121013

²大连民族大学生命科学院 辽宁大连 116600)

摘要 为建立一种能够同时适用于多种新鲜水产品货架期的预测模型,采用反向传播(BP)神经网络模型、遗传算法(GA)优化的BP神经网络模型(GA-BP)、径向基函数(RBF)神经网络模型、极限学习机(ELM)神经网络模型和支持向量回归机(SVR)模型分别对金枪鱼、三文鱼、大菱鲆和鲷鱼的货架期进行预测,寻找最优的模型预测结果。首先通过试验获得4种水产品产品在0,4,10℃贮藏条件下的感官评分、菌落总数、挥发性盐基氮值、K值、pH值,构建训练样本和测试样本。经相关性分析,选择与水产品货架期相关性较高的感官评分、菌落总数、挥发性盐基氮值、K值作为模型的输入层单元,然后确定各模型的网络拓扑结构以及参数,进行模型的训练,最后使用训练好的5种模型对测试样本的货架期进行预测。结果表明:5种预测模型的预测精度排序为:SVR模型>RBF神经网络模型>GA-BP神经网络模型>ELM神经网络模型>BP神经网络模型,其中BP神经网络模型的预测精度最差,均方误差(MSE)为 9.5127×10^{-4} ,平均绝对误差(MAE)为0.0197,平均绝对百分比误差(MAPE)为0.0825, R^2 为0.9766;SVR模型的预测精度最优,预测误差均在12%以内,MSE为 2.2971×10^{-4} ,MAE为0.0128,MAPE为0.0631, R^2 为0.9944,能够很好地同时预测4种水产品在不同储藏温度下的货架期。本研究为水产品的品质控制提供一定的理论基础。

关键词 BP神经网络; GA-BP神经网络; RBF神经网络; ELM神经网络; SVR模型; 货架期预测模型

文章编号 1009-7848(2023)11-0254-12 **DOI:** 10.16429/j.1009-7848.2023.11.025

水产品营养丰富,含有大量的蛋白质、维生素和矿物质,是保持人体健康的重要营养物质。水产品死后容易受到微生物、内源酶以及周围环境的影响而导致腐败变质^[1]。货架期是消费者判别食品新鲜度和品质安全的重要依据之一^[2],因此构建一个准确的水产品货架期预测模型显得尤为重要。

在构建模型之前,需要选取能够指示水产品新鲜度的指标。在内源酶或细菌降解的作用下,水产品体内的挥发性盐基氮(TVB-N)会不断增加,TVB-N常被作为评价水产品新鲜度的一个重要指标。K值是腺苷三磷酸(ATP)降解产物次黄嘌呤核苷、次黄嘌呤的和与腺苷三磷酸关联化合物总量的百分比,反映ATP降解的整个循环,也是衡量水产品新鲜度的重要指标。菌落总数(TVC)是

从微生物角度评价水产品新鲜度的一个重要指标。感官评分是人们对鱼类新鲜度最直观的打分,也是评价水产品新鲜度不可或缺的一个指标^[1-3]。本研究采用TVC、TVB-N、K值、感官评分等新鲜度指标来预测水产品的剩余货架期。

传统的货架期模型一般是基于动力学方法建立的,包括化学动力学和微生物动力学^[2]。雷志方等^[4]利用动力学模型并结合Arrhenius方程,根据金枪鱼的相关新鲜度指标建立金枪鱼的货架期预测模型,结果表明根据不同的新鲜度指标建立的货架期预测模型的相对误差也不同,误差范围在20%之内。丁婷等^[5]研究了不同储藏温度下三文鱼片中菌落总数、假单胞菌、乳酸菌等微生物的生长情况,利用微生物动力学模型结合Belehradek方程,建立了三文鱼片的货架期预测模型,结果表明根据不同的微生物生长情况建立的货架期预测模型的相对误差是不同的,误差范围在18.9%之内。传统货架期模型是基于单一的新鲜度指标或单一的微生物生长情况来建立货架期模型,这样会导致根据不同新鲜度指标或不同微生物生长情况所

收稿日期: 2022-11-18

基金项目: 国家自然科学基金重点项目(U20A2067)

第一作者: 崔方超,男,博士,讲师

通信作者: 李婷婷 E-mail: tingting780612@163.com

励建荣 E-mail: lijr6491@163.com

建立的货架期模型的预测精度有所差别,从而使模型的预测精度降低,并且只能预测对应的一种水产品,不能够同时对多种水产品的货架期进行预测。因此,研究一种更准确、更快速且能够同时预测多种水产品货架期的预测模型迫在眉睫。

随着机器学习的发展,基于神经网络的预测模型已经应用于化学、生物、天气、工业、食品等领域。Li 等^[6]采用 BP 神经网络模型预测生物气溶胶浓度,结果表明 BP 模型具有较好的预测性能,模型的预测精度为 84.01%。Deng 等^[7]采用粒子群算法优化的 BP 神经网络模型 (Particle swarm optimization-back propagation, PSO-BP)、反向传播 (Back propagation, BP) 模型和遗传算法优化的 BP 神经网络 (Genetic algorithm-back propagation, GA-BP) 模型分别对云南萨饼中大肠菌群的数量进行预测,结果表明 PSO-BP 模型的预测精度最好,PSO-BP 模型的均方误差为 0.0097。Li 等^[8]用储藏温度、相对湿度、果皮硬度等 9 个品质指标来构建鲜食葡萄的货架期预测模型,结果表明优化后的径向基函数 (Radial basis function, RBF) 神经网络模型比 BP 神经网络模型、Arrhenius 模型的预测精度更高,其中 Arrhenius 模型的预测精度是最差的。Jiang 等^[9]利用 BP 模型对羊肉的新鲜度进行分类,结果表明 BP 模型具有很好的适用性,总体预测精度为 93.78%。由此可见,人工神经网络模型在食品的货架期预测领域上具有良好的应用前景。

目前对于生鲜水产品货架期的预测模型,国内外的大部分学者还是采用传统的动力学模型进行预测,基于神经网络建立的新鲜水产品货架期模型比较少见。本文中同时采用 BP 神经网络模

型、GA-BP 神经网络模型、RBF 神经网络模型、极限学习机 (Extreme learning machine, ELM) 神经网络模型和支持向量回归机 (Support vector machine for regression, SVR) 模型对不同储藏温度下 4 种水产品的货架期进行同时预测,旨在找到一种能够快速、高精度且同时预测多种水产品货架期的模型,从而为生鲜水产品的品质控制提供一定的理论基础。

1 材料与方法

1.1 材料与试剂

在辽宁省锦州市水产市场挑选新鲜的金枪鱼、三文鱼、大菱鲆和鲷鱼,用带有碎冰块的保温箱低温保存运回实验室,并立即开展试验。将金枪鱼、三文鱼、大菱鲆和鲷鱼分别去皮,取鱼肉切成 (150±5)g 的方块,装入灭菌后的蒸煮袋内封口,于 0, 4, 10 °C 温度下储藏。

氧化镁,河北镁熙生物有限公司;硼酸,济南跃阳化工有限公司;盐酸,上海源叶生物科技有限公司;甲基红,武汉华翔科洁生物技术有限公司。

1.2 仪器与设备

Kjeltec 8400 凯氏氮分析仪,丹麦 Foss 公司, 1260 Infinity II 安捷伦液相色谱仪,美国 Agilent 公司。

1.3 试验方法

1.3.1 理化指标及感官评价 参考国标 GB/T 30762-2018《水产品感官评价指南》对试验水产品的外观、气味、质地 3 方面进行评价^[10],感官评价标准如表 1 所示。选取 15 位实验室成员按照感官评价表对样品进行综合打分,取平均分记为样品的感官评价价值。

表 1 感官评价表

Table 1 Sensory evaluation table

	10~8 分	8~6 分	6~4 分	< 4 分
外观	表面光滑,色泽鲜艳	表面稍暗,呈自然色	表面有血点产生,色泽暗淡	表面发白
气味	具有水产品的鲜香气味	有些许异味产生	鱼腥味浓厚,有些许酸味	有腐臭味产生
质地	肌肉紧实,有弹性	肉质紧绷,有略微弹性	弹性消失,肉质柔软	肉质松散,无弹性

菌落总数参照国标 GB 4789.2-2016《食品安全国家标准 食品微生物学检验 菌落总数测定》的方法进行测定^[11]。

挥发性盐基氮参照国标 GB 5009.228-2016《食品安全国家标准 食品中挥发性盐基氮的测定》的方法进行测定^[12]。

pH 值参考丁婷^[13]的方法进行测定,略有修改。准确称取(5±0.05)g 均匀绞碎的样品,放置于烧杯中。加入 45 mL 蒸馏水,进行均质后静置 30 min。然后进行过滤,弃取初滤液,得到上清液用 pH 计测定。

K 值参考 SC/T 3048-2014《鱼类鲜度指标 K 值的测定 高效液相色谱法》中的方法进行 K 值的测定^[14]。

在不同温度下储藏的 4 种水产品每隔一定时间测定一次理化指标,试验设计如表 2 所示。根据 SC/T 3117-2006《生食金枪鱼》的要求^[15],当菌落总数超过 4 lg(CFU/g),记为金枪鱼货架期的终点。三文鱼和鲷鱼作为海水鱼,常被作为高品质鱼食用,Rosnes 等^[16]在研究中指出高品质鱼类菌落总数以 6 lg(CFU/g)作为人们可接受的限值,因此当菌落总数达到 6 lg(CFU/g)记为三文鱼和鲷鱼的货架期终点。大菱鲆作为淡水鱼,根据国际食品微生物委员会的规定^[17],鱼类的菌落总数可接受最高安全限值为 7 lg(CFU/g),因此当大菱鲆的菌落总数超过 7 lg(CFU/g)记为货架期终点。以上总计共测得 80 组样本,作为训练样本使用。另外在 0,4,10 ℃下,分别随机取 4 种水产品 3 个不同时间段的样本进行理化指标的测定,总计测得 12 组样本,作为测试样本使用。

1.3.2 建模方法

1.3.2.1 BP 神经网络 BP 神经网络是一种多层的前馈型神经网络,其在网络训练的过程中采用误差反向传播不断调整神经元的权值和阈值,从而满足期望值^[18]。BP 神经网络由输入层、隐藏层和输出层构成,层与层之间采用全连接的方式,由传递函数传递层与层之间的结果,而同层之间的神经元互不相连。在隐藏层中,隐藏层的数量可以是一层或者多层^[19],多层隐藏层虽然提高了模型的泛化能力和预测精度,但时间过长。在本文中为了节省训练时间,采用单层的隐藏层,单层前馈型神经网络结构如图 1 所示。

1.3.2.2 GA-BP 神经网络 遗传算法是一种模拟自然界生物进化机制的一种算法,遵循适者生存、优胜劣汰的原则,即在寻优过程中将有用的保留,无用的剔除^[20]。遗传算法将问题参数编码为染色体,利用不断迭代的方式进行选择、交叉和变异等

表 2 试验设计表

Table 2 Experimental design table			
	0 ℃贮藏	4 ℃贮藏	10 ℃贮藏
	时间/h	时间/h	时间/h
金枪鱼	12	12	12
三文鱼	24	24	12
大菱鲆	48	48	24
鲷鱼	24	24	24




图 1 单层前馈型神经网络拓扑图

Fig.1 Single-layer feedforward neural network topology

运算来交换种群中染色体的信息,最终生成符合优化要求的染色体。

由于初始权值和阈值对 BP 神经网络的训练准确度影响很大,本文利用遗传算法的优良特性来不断迭代寻找 BP 神经网络较优的初始权值和阈值,从而提高 BP 神经网络的准确性,构建成 GA-BP 神经网络。

1.3.2.3 RBF 神经网络 RBF 神经网络也是多层前馈型网络的一种,由输入层、隐藏层和输出层构成,其隐藏层只有一层^[21]。RBF 神经网络的原理是将径向基函数作为隐含层神经元的“基”,构成隐含层空间^[22],这样输入层就可以直接映射到隐含层,而不需要“权”的连接。隐含层空间到输出层空间的变换是线性的,即网络的输出是隐含层神经元的线性加权和^[23]。

1.3.2.4 ELM 神经网络 ELM 神经网络是单隐含层前馈型神经网络,该网络在运行时随机产生初始权值和阈值,在训练过程中并不需要调整,只需要设置适宜的隐含层神经元数目和隐含层神经元的激活函数即可获得最优解,该神经网络具有学习速度快和泛化性能好的优点^[24]。

1.3.2.5 支持向量回归机 支持向量机(Support

vector machine, SVM)是以 Brasil 等^[25]创建的统计学理论为基础提出的,支持向量回归机是在 SVM 的基础上引入了不敏感损失函数得到的一种回归拟合的方法。SVR 的基本思想是寻找一个最优的平面,使所有训练样本离该平面的误差最小。在 SVR 预测模型的建立中需要确定输入向量、输出向量以及中间层的核函数。SVR 模型可以很好的解决小样本及陷入局部最优的回归问题。

1.4 数据分析

本文中所有模型的建立和数据分析均基于软件 MATLAB 2018b,采用 Origin 2021 软件进行绘图。

2 结果与分析

2.1 数据的收集

通过试验对 4 种水产品的 TVC 值、TVB-N 值、pH 值、K 值和感官评分进行测定,共测得训练样本数据 80 组,测试样本数据 12 组。将所测得 4 种水产品的鲜度指标与各自的剩余货架期指标

进行相关性分析,结果如图 2 所示。从图中可以明显看出,4 种水产品的 TVC 值、TVB-N 值、pH 值和 K 值与剩余货架期呈负相关关系,感官评分与剩余货架期呈正相关关系。4 种水产品的 TVC 值、TVB-N 值、K 值和感官评分 4 个指标与剩余货架期的相关性都比较强,绝对值都在 0.8 以上,最高可达 0.92。因此可以将 TVC 值、TVB-N 值、K 值和感官评分 4 个指标作为模型的输入向量来预测水产品的剩余货架期。然而,4 种水产品的 pH 值指标与剩余货架期的相关性反而比较低,绝对值最低在 0.47,最高在 0.67。原因可能是由于水产品死后,机体在 ATP 酶、乳酸菌等产酸微生物的作用下,乳酸含量增加导致 pH 值降低;贮藏一段时间后,机体内蛋白质在微生物的作用下开始分解为氨、三甲胺等碱性物质,使 pH 值开始上升,这种现象使 pH 值指标与剩余货架期的相关性减弱。因此为了保证模型的准确性,本研究将 pH 值指标剔除,不作为模型的输入向量使用,只将相关性较高的 TVC 值、TVB-N 值、K 值和感官评分 4

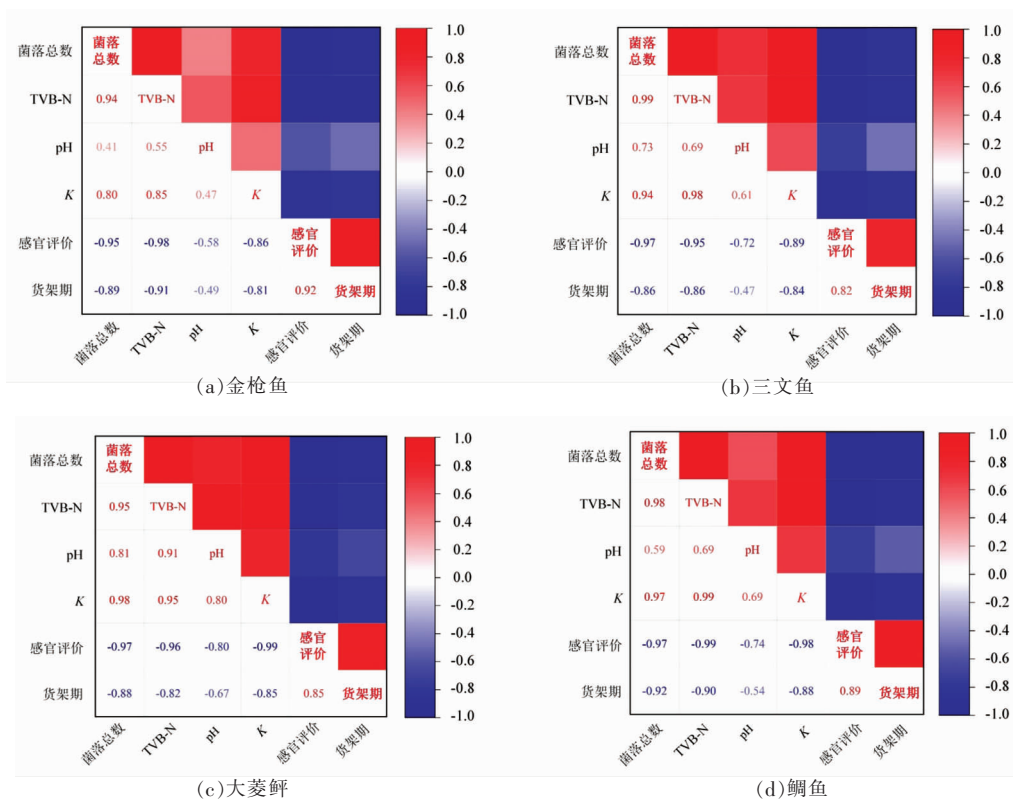


图 2 4 种水产品新鲜度指标的相关性分析图

Fig.2 Correlation analysis chart of four freshness indicators of aquatic products

个指标作为各个模型的输入向量使用。

2.2 数据的归一化

由于各指标的量纲是不同的,为了保证各模型训练的准确性,需要对数据进行量纲统一,即归一化处理。归一化处理的方法见式(1)^[6]。

$$X = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中, X ——归一化后的数据; X_0 ——原数据; X_{\min} ——每一列指标中的最小值; X_{\max} ——每一列指标中的最大值。

2.3 货架期预测模型的建立

2.3.1 BP神经网络模型的建立

BP神经网络模型的拓扑结构对于其预测精度起着重要的作用。将种类、温度、感官评分、TVC值、TVB-N值、K值

6个指标作为输入层单元,将剩余货架期作为输出层单元。隐藏层单元数目的不同,模型的预测误差也会随之改变。隐藏层单元数目一般符合式(2)^[20]。

$$n < \sqrt{(M+N)} + a \quad (2)$$

式中, M ——输入层单元数; N ——输出层单元数; n ——隐藏层单元数; a ——1~10的常数。

隐藏层单元数在3~13范围。分别取不同的隐藏层单元数,计算10次模型的决定系数 R^2 ,选择10次决定系数平均值最大的一个隐藏层单元数。如表3所示,隐藏层单元数为9时,平均决定系数最大,为0.9711,因此BP神经网络模型的隐藏层单元数设定为9。

表3 不同隐藏层单元数目对应的BP神经网络决定系数(R^2)

隐藏层单元数	最小决定系数(R^2)	最大决定系数(R^2)	平均决定系数(R^2)
3	0.6429	0.9722	0.9025
4	0.8250	0.9812	0.9371
5	0.7606	0.9927	0.9297
6	0.8073	0.9881	0.9537
7	0.9429	0.9859	0.9647
8	0.9375	0.9933	0.9680
9	0.9273	0.9948	0.9711
10	0.8571	0.9915	0.9613
11	0.9128	0.9798	0.9619
12	0.9451	0.9885	0.9702
13	0.8128	0.9916	0.9503

BP网络参数设置如下:动量设置为0.9,学习速率设置为0.01,网络性能目标误差设置为0.0001,最大训练次数设置为1000,隐藏层传递函数选择logsig函数,输出层的传递函数选择purelin函数,训练函数选择trainlm函数。

2.3.2 GABP神经网络模型

BP神经网络模型每次训练的权值和阈值都是随机选取的,从而导致BP神经网络模型每次预测的结果都是不确定的^[26]。为了提高BP神经网络模型的预测精度,采用遗传算法优化BP神经网络模型的初始权值和阈值,选取BP神经网络模型精度最高时的初始权值和阈值。GABP神经网络模型的流程图如图3所示。

GABP神经网络模型是在BP神经网络模型的拓扑结构和参数的基础上建立的,因此BP神经网络模型的拓扑结构和参数保持不变。GABP神经网络模型的其它参数设置为:群体个体数目为40,最大遗传代数为50,代沟为0.95,交叉概率为0.7,变异概率为0.01,选择算子为轮盘选择函数,交叉算子为单点交叉,变异算子为离散变异函数。

2.3.3 RBF神经网络模型

RBF神经网络模型的拓扑结构如下:同样采用种类、温度、感官评分、TVC值、TVB-N值、K值作为输入层单元,将剩余货架期作为输出层单元。通过不断增加隐藏层单元的数目,直至满足目标误差。如图4所示,当隐藏层单元的数目为35时,网络性能误差为8.6141×

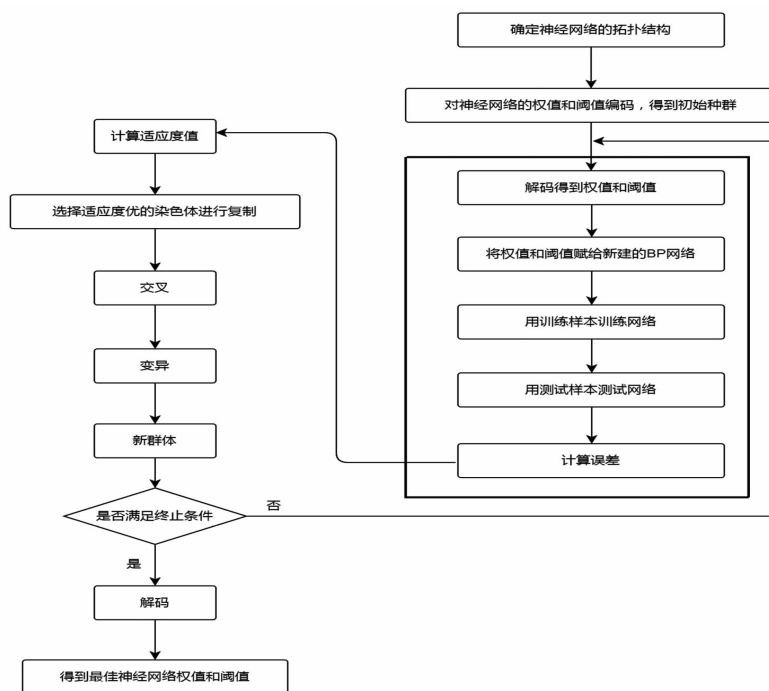


图 3 GABP 神经网络模型的流程图

Fig.3 Flow chart of GABP neural network model

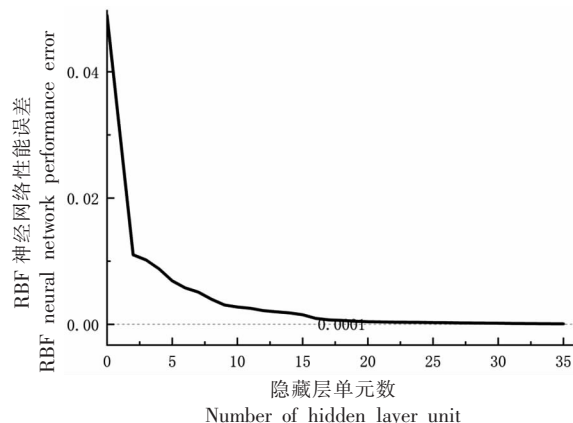


图 4 不同隐藏层单元数目的 RBF 神经网络性能误差

Fig.4 Performance errors of RBF neural networks with different number of hidden layer units

10^{-5} , 满足网络性能误差目标 0.0001。

RBF 神经网络模型的参数设置如下：网络性能误差目标为 0.0001，径向基函数扩展速度 spread 为 1，最大隐藏层神经元数目为 100，每次显示之间所添加的神经元数目为 1，隐藏层的径向基核函数选择高斯函数，输出层函数为线性函数。

2.3.4 ELM 神经网络模型 ELM 神经网络模型的拓扑结构如下：采用种类、温度、感官评分、TVC

值、TVB-N 值、K 值作为输入层单元，将剩余货架期作为输出层单元。ELM 神经网络的隐藏层单元数目一般不大于输入层样本数^[24]，即在 0~80 中间选取。分别选取不同的隐藏层单元数目，计算 10 次该模型的决定系数 R^2 ，选择 10 次决定系数平均值最大的一个隐藏层单元数目。如表 4 所示，当隐藏层单元数目为 60 时，ELM 神经网络模型运行 10 次的平均决定系数最大，为 0.9867，因此该模型的隐藏层单元数目应选取 60。ELM 神经网络模型的参数设置如下：隐含层神经元的激活函数为 S 型函数^[27]。

2.3.5 SVR 预测模型 SVR 预测模型的拓扑结构如下：将种类、温度、感官评分、TVC 值、TVB-N 值、K 值作为输入层单元，将剩余货架期作为输出层单元，将高斯函数作为中间层的核函数，高斯函数见公式(3)^[28]。


$$K(x_i, x) = \exp(-\gamma \|x_i - x\|)^2 \tag{3}$$

式中， γ ——RBF 核函数的半径。

高斯核函数中的惩罚因子参数 c 和方差参数 g 影响 SVR 模型的性能，采用交叉验证法寻找最优的参数 c 和 g ^[29]，如图 5 可得，最优的参数 c 为 8，参数 g 为 0.5，此时训练样本的均方误差 MSE

表4 不同隐藏层单元数对应的 ELM 神经网络决定系数 (R^2)

隐藏层单元数	最小决定系数(R^2)	最大决定系数(R^2)	平均决定系数(R^2)
10	0.5234	0.7764	0.6570
20	0.8654	0.9734	0.9227
30	0.9162	0.9914	0.9699
40	0.9347	0.9917	0.9779
50	0.9570	0.9953	0.9861
60	0.9793	0.9944	0.9867
70	0.8629	0.9925	0.9658
80	0.2700	0.7454	0.5116

图5 参数 c 和参数 g 的寻优结果图Fig.5 Optimization result graph of parameter c and parameter g

为 0.004995, 采用最优的参数 c 和 g 构建 SVR 预测模型。

2.4 模型的评价指标

为了更加方便的、全面的观察模型的精确度, 采用了 4 个评价指标来进行描述: 均方误差 (MSE)、平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE)、决定系数 (R^2)。均方误差反映了预测值和实际值之间的差异程度。平均绝对误差是所有单个预测值与算术平均值的偏差的绝对值的平均, 避免了误差相互抵消, 可以更加准确反映实际预测误差的大小。平均绝对百分比误差表示预测值和实际值之间的差异, 值越小越好。决定系数指回归平方和在离差平方和所占的比例, 值越大越好。评价指标的计算公式如下^[30]。

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - y_i)^2 \quad (4)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |Y_i - y_i| \quad (5)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - y_i}{Y_i} \right| \quad (6)$$

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

式中, Y_i ——剩余货架期的实际值, $h; y_i$ ——剩余货架期的预测值, $h; \bar{Y}$ ——剩余货架期实际值的平均数, h 。

2.5 模型的预测结果

将归一化后的训练样本作为 BP 神经网络模型、GA-BP 神经网络模型、RBF 神经网络模型、ELM 神经网络模型和 SVR 模型的训练数据, 将归一化后的测试样本作为各模型的测试数据, 按照已设置好的模型参数进行模型的训练。利用训练好的模型对测试样本进行预测, 结果如图 6 所示。BP 神经网络模型对训练样本和测试样本的预测精度明显要低于其他模型。BP 神经网络模型在对训练样本的预测中, 第 16 号、35 号、62 号和 80 号的训练样本的预测误差比较大; 在对测试样本的预测中, 第 1 号、6 号和 11 号测试样本的预测误差较大。GA-BP 模型很明显在 BP 神经网络模型的基础上提高了对训练样本和测试样本的预测精度, 对测试样本的预测值几乎与真实值重合, 这也满足使用遗传算法来优化 BP 神经网络的期望。ELM 神经网络模型对训练样本和测试样本的预测

精度也要优于 BP 神经网络模型,对测试样本的预测中除了 10 号样本与真实值误差稍大外,其它样本的预测值与真实值几乎重合,预测精度较高。

RBF 神经网络模型和 SVR 模型对训练样本、测试样本的预测精度都很高,能够很好的同时预测不同温度下 4 种水产品的货架期。

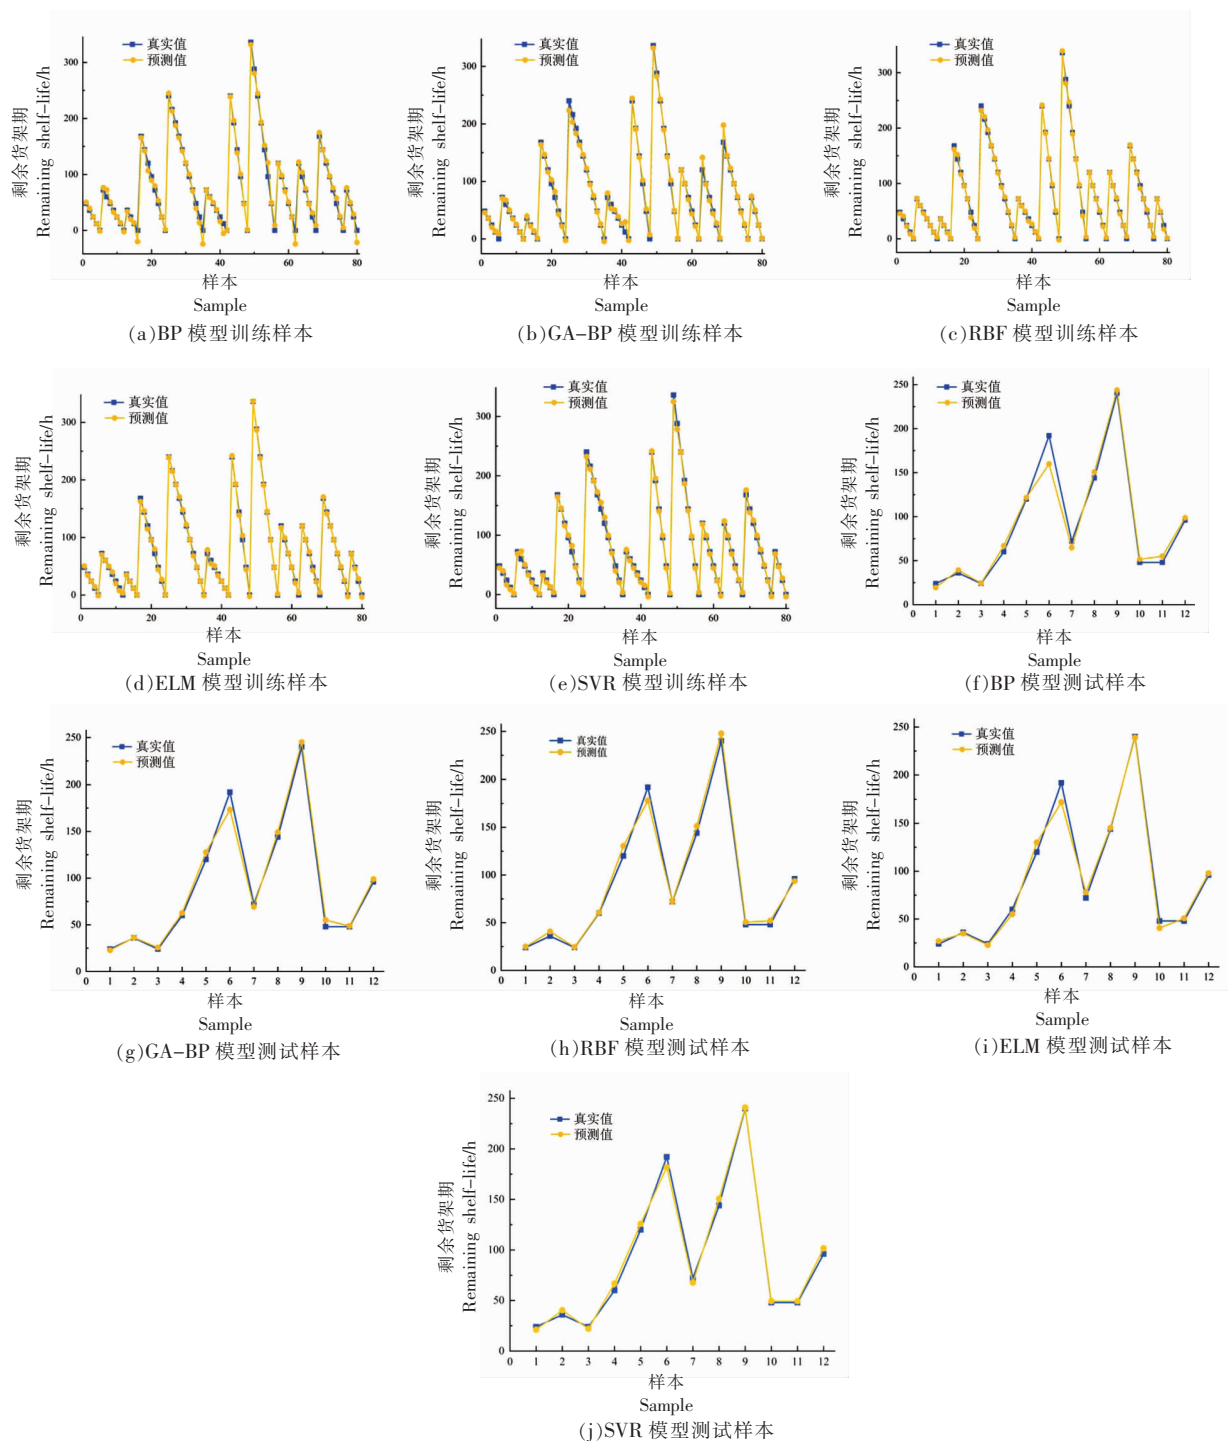


图 6 各模型对训练样本和测试样本的预测结果

Fig.6 The prediction results of each model for training samples and test samples

从图7中可以清楚的看到各个模型对测试样本的预测误差。BP神经网络模型的最大误差为18.43%,即第1号样本、4号样本的误差为11.37%,6号样本的误差为16.72%,11号样本的误差为14.63%,这符合图6的结果,其它样本的预测误差均在10%以内。GA-BP神经网络模型的最大误差为第10号样本14.63%,其它样本均在10%以内。与BP神经网络模型相比,GA-BP神经网络模型的预测精度总体上要更为精确。ELM神经网络模型的最大误差为第10号样本15.33%,1号样本的误差为11.98%,6号样本的误差均为10.41%,其它样本的误差均在9%以内,总体上略次于GA-BP神经网络模型,而优于BP神经网络模型,这与图6中的信息相吻合。SVR模型对测试样本的预测中,1号样本和2号样本的预测误差为12%,4号样本的预测误差为11.34%,其它样本的预测误差均在8%以内,总体上要优于ELM神经网络模型,这也很好地体现了SVR模型在小样本预测时的优势。RBF神经网络模型对测试样本的预测中,除了第2号样本的预测误差为13%,其它样本的预测误差均在9%以内,总体上要优于GA-BP神经网络模型和ELM神经网络模型。

为了能够更加准确地评价各个模型的优劣,根据2.5节的模型评价指标公式,用MATLAB软件计算得到各个模型的评价指标,如表5所示。各




图7 各模型对测试样本的预测误差率

Fig.7 The prediction error rate of each model for test samples

模型MSE、MAE的大小排列顺序为:BP模型>ELM模型>GA-BP模型>RBF模型>SVR模型;MAPE的大小排列顺序为:BP模型>ELM模型>SVR模型>GA-BP模型>RBF模型; R^2 的大小排列顺序为:SVR模型>RBF模型>GA-BP模型>ELM模型>BP模型。因此,综合考虑SVR模型对4种水产品货架期的预测精度最好,RBF神经网络模型略微次之,BP神经网络模型的预测精度最差。

表5 各模型的评价指标

Table 5 Evaluation metrics for each model

模型	评价指标			
	MSE	MAE	MAPE	R^2
BP神经网络模型	9.5127×10^{-4}	0.0197	0.0825	0.9766
GA-BP神经网络模型	3.9559×10^{-4}	0.0137	0.0502	0.9902
RBF神经网络模型	3.4789×10^{-4}	0.0136	0.0491	0.9919
ELM神经网络模型	4.9983×10^{-4}	0.0179	0.0784	0.9884
SVR预测模型	2.2971×10^{-4}	0.0128	0.0631	0.9944

3 结论

通过对试验获得的训练样本进行相关性分析表明,TVC值、TVB-N值、K值和感官评分4个指标与水产品货架期的相关性较强,绝对值均在0.8以上,因此可以将以上指标作为BP神经网络模型、GA-BP神经网络模型、RBF神经网络模型、

ELM神经网络模型和SVR预测模型的输入层单元。5种模型的预测结果表明,BP神经网络模型的预测精度最差,其MSE为 9.5127×10^{-4} ,MAE为0.0197,MAPE为0.0825,均是5种模型中最高的;其 R^2 为0.9766,是5种模型中最低的。总体上,GA-BP神经网络模型的性能较BP神经网络模型

有全面的提高。ELM 神经网络模型的预测精度虽优于 BP 神经网络模型,但次于 GA-BP 神经网络模型。RBF 神经网络模型的预测精度要优于 GA-BP 神经网络模型,略微低于 SVR 模型,然而当样本数量较大时依然可以考虑使用 RBF 模型。在本次研究中,SVR 模型的总体性能是最优的,其 MSE 为 2.2971×10^{-4} ,MAE 为 0.0128,MAPE 为 0.0631, R^2 为 0.9944,能够很好的同时预测金枪鱼、三文鱼、大菱鲂和鲷鱼 4 种水产品,在 0,4,10 °C 下的货架期,为水产品的品质控制提供了一定的理论基础。

参 考 文 献

- [1] PRABHAKAR P K, VATSA S, SRIVASTAV P P, et al. A comprehensive review on freshness of fish and assessment: Analytical methods and recent innovations[J]. Food research international, 2020, 133: 109157.
- [2] 黄幸幸, 陈明, 葛艳, 等. 南美白对虾货架期预测指标选择及模型研究[J]. 食品与机械, 2017, 33(4): 105-109, 116.
HUANG X X, CHEN M, GE Y, et al. The prediction index and model of the shelf-life of *Penaeus vannamei* [J]. Food and Machinery, 2017, 33(4): 105-109, 116.
- [3] TSIRONI T, HOUHOULA D, TAOUKIS P. Hurdle technology for fish preservation[J]. Aquaculture and Fisheries, 2020, 5(2): 65-71.
- [4] 雷志方, 谢晶. 金枪鱼基于理化指标的货架期预测模型的建立[J]. 食品与发酵工业, 2015, 41(11): 185-191.
LEI Z F, XIE J. Establishment of a prediction model for the shelf life of tuna based on physical and chemical indicators[J]. Food and Fermentation Industries, 2015, 41(11): 185-191.
- [5] 丁婷, 李婷婷, 励建荣, 等. 冷藏三文鱼片微生物生长动力学模型适用性分析及货架期模型的建立[J]. 中国食品学报, 2015, 15(5): 63-73.
DING T, LI T T, LI J R, et al. Applicability analysis of microbial growth dynamics models and establishment of shelf-life model for salmon slices during the cold storage[J]. Journal of Chinese Institute of Food Science and Technology, 2015, 15(5): 63-73.
- [6] LI X N, WU W J, WANG Q H, et al. Forecasting of bioaerosol concentration by a back propagation neural network model[J]. Science of the Total Environment, 2020, 698: 134315.
- [7] DENG Y, XIAO H J, XU J X, et al. Prediction model of PSO-BP neural network on coliform amount in special food[J]. Saudi J Biol Sci, 2019, 26(6): 1154-1160.
- [8] LI Y, CHU X Q, FU Z T, et al. Shelf life prediction model of postharvest table grape using optimized radial basis function (RBF) neural network[J]. British Food Journal, 2019, 121(11): 2919-2936.
- [9] JIANG X H, HERU X, LINA Z, et al. Nondestructive detection of chilled mutton freshness based on multi-label information fusion and adaptive BP neural network[J]. Computers and Electronics in Agriculture, 2018, 155: 371-377.
- [10] 中国水产科学研究院黄海水产研究所, 国家水产品质量监督检验中心. 水产品感官评价指南: GB/T 37062-2018[S]. 北京: 中国标准出版社, 2018: 16.
Yellow Sea Fisheries Research Institute, Chinese Academy of Fishery Sciences, National Aquatic Product Quality Supervision and Inspection Center. Guidelines for sensory evaluation of aquatic products: GB/T 37062-2018[S]. Beijing: Standards Press of China, 2018: 16.
- [11] 中华人民共和国国家卫生和计划生育委员会, 国家食品药品监督管理总局. 食品安全国家标准 食品微生物学检验 菌落总数测定: GB 4789.2-2016[S]. 北京: 中国标准出版社, 2016: 12.
National Health and Family Planning Commission of the People's Republic of China, State Food and Drug Administration. National food safety standards, food microbiology testing, total colony determination: GB 4789.2-2016[S]. Beijing: Standards Press of China, 2016: 12.
- [12] 中华人民共和国国家卫生和计划生育委员会. 食品安全国家标准 食品中挥发性盐基氮的测定: GB 5009.228-2016[S]. 北京: 中国标准出版社, 2016: 12.
National Health and Family Planning Commission of the People's Republic of China. National food safety standards, determination of volatile basic nitrogen in food: GB 5009.228-2016[S]. Beijing: Standards Press of China, 2016: 12.

- [13] 丁婷. 三文鱼新鲜度综合评价和货架期模型的建立 [D]. 锦州: 渤海大学, 2015.
DING T. Comprehensive evaluation on freshness and establishment of the shelf-life model of salmon[D]. Jinzhou: Bohai University, 2015.
- [14] 福建省水产研究所, 南海水产研究所, 农业部渔业产品质量监督检验测试中心(厦门), 北京市水产技术推广站. 鱼类鲜度指标 K 值的测定 高效液相色谱法: SC/T 3048-2014[S]. 北京: 中国标准出版社, 2014: 3.
Fujian Fisheries Research Institute, South China Sea Fisheries Research Institute, Fishery Product Quality Supervision, Inspection and Testing Center of the Ministry of Agriculture (Xiamen), Beijing Aquatic Products Technology Promotion Station. Determination of K value as fishery freshness index High performance liquid chromatography: SC/T 3048-2014[S]. Beijing: Standards Press of China, 2014: 3.
- [15] 上海水产大学, 中国渔业协会远洋渔业分会, 上海出入境检验检疫局. 生食金枪鱼: SC/T 3117-2006 [S]. 北京: 中国标准出版社, 2006: 13.
Shanghai Fisheries University, China Fisheries Association Pelagic Fisheries Branch, Shanghai Entry-Exit Inspection and Quarantine Bureau. Tunas for raw consumption: SC/T 3117-2006[S]. Beijing: Standards Press of China, 2006: 13.
- [16] ROSNES J, KLEIBERG G, SIVERTSVIK M, et al. Effect of modified atmosphere packaging and super-chilled storage on the shelf-life of farmed ready-to-cook spotted wolf-fish (*Anarhichas minor*) [J]. Packaging Technology and Science: An International Journal, 2006, 19(6): 325-333.
- [17] WU T, WU C H, FANG Z X, et al. Effect of chitosan microcapsules loaded with nisin on the preservation of small yellow croaker[J]. Food Control, 2017, 79: 317-324.
- [18] ABROUGUI K, GABSI K, MERCATORIS B, et al. Prediction of organic potato yield using tillage systems and soil properties by artificial neural network (ANN) and multiple linear regressions (MLR) [J]. Soil and Tillage Research, 2019, 190: 202-208.
- [19] WANG J, YUE H L, ZHOU Z N. An improved traceability system for food quality assurance and evaluation based on fuzzy classification and neural network[J]. Food Control, 2017, 79: 363-370.
- [20] JIANYING F, BIANYU Y, XIN L, et al. Evaluation on risks of sustainable supply chain based on optimized BP neural networks in fresh grape industry [J]. Computers and Electronics in Agriculture, 2021, 183: 105988.
- [21] GENG Z Q, LIU F F, SHANG D, et al. Early warning and control of food safety risk using an improved AHC-RBF neural network integrating AHP-EW [J]. Journal of Food Engineering, 2021, 292: 110239.
- [22] GENG Z Q, SHANG D, HAN Y M, et al. Early warning modeling and analysis based on a deep radial basis function neural network integrating an analytic hierarchy process: A case study for food safety[J]. Food Control, 2019, 96: 329-342.
- [23] WANG X J, SONG M, LIU S T, et al. Analysis of phthalate plasticizer migration from PVDC packaging materials to food simulants using molecular dynamics simulations and artificial neural network [J]. Food Chemistry, 2020, 317: 126465.
- [24] WANG H P, CHU X L, CHEN P, et al. Partial least squares regression residual extreme learning machine (PLSRR-ELM) calibration algorithm applied in fast determination of gasoline octane number with near-infrared spectroscopy[J]. Fuel, 2022, 309: 122224.
- [25] BRASIL Y L, CRUZ-TIRADO J P, BARBIN D F. Fast online estimation of quail eggs freshness using portable NIR spectrometer and machine learning[J]. Food Control, 2022, 131: 108418.
- [26] SUN Q, ZHANG M, YANG P Q. Combination of LF-NMR and BP-ANN to monitor water states of typical fruits and vegetables during microwave vacuum drying[J]. LWT, 2019, 116: 108548.
- [27] 吴伟杰, 吴杰康, 李红玲, 等. 基于智能极限学习机的珠三角地区电力需求预测模型[J]. 供用电, 2022, 39(4): 77-83.
WU W J, WU J K, LI H L, et al. Power demand forecasting model in Pearl River Delta region based on intelligent limit learning machine[J]. Distribution & Utilization, 2022, 39(4): 77-83.
- [28] DA SILVA COTRIM W, FELIX L B, MINIM V P R, et al. Development of a hybrid system based on convolutional neural networks and support vector machines for recognition and tracking color changes in food during thermal processing[J]. Chemical Engineering Science, 2021, 240: 116679.

- [29] 陈婉娇, 龙卫江. 支持向量机在葡萄酒识别上的应用[J]. 电脑知识与技术, 2019, 15(4): 154–156.
CHEN W J, LONG W J. Application of support vector machine in wine recognition [J]. Computer Knowledge and Technology, 2019, 15(4): 154–156.
- [30] VAEZI S S, POORAZIZI E, TAHMOURESPOUR A, et al. Application of artificial neural networks to describe the combined effect of pH, time, NaCl and ethanol concentrations on the biofilm formation of *Staphylococcus aureus*[J]. Microb Pathog, 2020, 141: 103986.

Construction and Application of Fresh Aquatic Product Shelf Life Prediction Model Based on Neural Network

Cui Fangchao¹, Mao Zhichao¹, Li Tingting^{2*}, Li Jianrong^{1*}

(¹College of Food Science and Technology, Bohai University, National & Local Joint Engineering Research Center of Storage, Processing and Safety Control Technology for Fresh Agricultural and Aquatic Products, China Light Industry Key Laboratory of Marine Fish Processing, Jinzhou 121013, Liaoning

²College of Life Science, Dalian Minzu University, Dalian 116600, Liaoning)

Abstract In order to establish a shelf-life prediction model that can be applied to a variety of fresh aquatic products at the same time. Using back propagation (BP) neural network model, genetic algorithm-back propagation(GA-BP) neural network model, radial basis function(RBF) neural network model, extreme learning machine (ELM) neural network model and support vector machine for regression (SVR) model to predict the remaining shelf life of four aquatic products respectively. First measure 4 indicators of tuna, salmon, turbot and sea bream at 0, 4 °C and 10 °C, in order to construct training samples and test samples. Including sensory score, total number of colonies, TVB-N value, K value, pH value. After correlation analysis, the pH indicator with the lowest correlation was eliminated, and other indicators were selected as input indicators for each model. Then, determine the network topology and parameters of each model, and train each model. Finally, this study used each model trained to predict the remaining shelf life of the test sample. The result showed that the order of model prediction accuracy was: SVR prediction model > RBF neural network model > GA-BP neural network model > ELM neural network model > BP neural network model. The prediction accuracy of the BP neural network model was the worst, mean square error (MSE) was 9.5127×10^{-4} , mean absolute error (MAE) was 0.0197, mean absolute percentage error (MAPE) was 0.0825, R^2 was 0.9766. The prediction accuracy of the SVR prediction model was the best, its prediction error was within 12%, MSE= 2.2971×10^{-4} , MAE=0.0128, MAPE=0.0631, $R^2=0.9944$, it could well predict the remaining shelf life of 4 aquatic products. This study provides a theoretical basis for the quality control of aquatic products.

Keywords BP neural network; GA-BP neural network; RBF neural network; ELM neural network; SVR model; shelf-life prediction model