

人工神经网络在不同蓄冷剂参数下保温性能评估的应用

杨佳文, 曾台英

(上海理工大学, 上海 200093)

摘要: **目的** 利用不同人工神经网络算法预测不同蓄冷剂参数下冷链保温箱保温时间, 以寻找最适合评估其保温性能的人工神经网络。 **方法** 将实验数据以 4:1 的比例分别随机分配训练、测试的样本, 分别建立 BPNN、RBFNN 与 GRNN 这 3 种人工神经网络模型, 并提出判定系数 (R^2)、平均绝对误差 (MAE) 与均方误差 (MSE) 这 3 个评价标准。通过算法获得保温时间预测值和评价标准具体值, 并且利用随机漫步算法对性能最好的神经网络进行优化。 **结果** 通过 R^2 、MAE 和 MSE 这 3 个神经网络评价标准以及保温时间的实际值与预测值的对比图, 得出 RBFNN 神经网络的性能最佳、精度最准、拟合最好, 它的 R^2 远高于 GRNN 和 BPNN 神经网络的, 并且 MSE 值和 MAE 值远低于 GRNN 和 BPNN 神经网络的, 3 个评价指标分别达到 0.999 93、0.009 63 和 0.062 86。优化后的 Random-Walk-RBFNN 的性能进一步提高, R^2 提升了 0.004%, MSE 值、MAE 值和运行时间分别下降了 60.02%、34.20% 和 5.29%。 **结论** RBFNN 神经网络各方面最为突出, 更适合用于冷链保温箱保温性能评估, 而优化后的 Random-Walk-RBFNN 性能更优, R^2 进一步提升, MSE 值、MAE 值和运行时间进一步下降, 评估性能更好。

关键词: 冷链保温箱; 蓄冷剂; 人工神经网络; 均方误差

中图分类号: TB485.3; TP183 文献标识码: A 文章编号: 1001-3563(2023)15-0175-09

DOI: 10.19554/j.cnki.1001-3563.2023.15.023

Application of Artificial Neural Network in Evaluation of Thermal Insulation Performance under Different Parameters of Cool Storage Agent

YANG Jia-wen, ZENG Tai-ying

(University of Shanghai for Science and Technology, Shanghai 200093, China)

ABSTRACT: The work aims to use different artificial neural network algorithms to predict the holding time of cold chain incubator under different cold storage agent parameters in order to find the most suitable artificial neural network for evaluating the thermal insulation performance. The experimental data were randomly assigned to the training and testing samples in a ratio of 4 : 1, and three artificial neural network models, namely BPNN, RBFNN and GRNN, were established respectively. Three evaluation criteria, namely the decision coefficient R^2 , mean absolute error MAE and mean square error MSE, were proposed. The predicted value of holding time and the specific value of evaluation criteria were obtained by the algorithm, and the neural network with the best performance was optimized by the random walk algorithm. By comparing the three evaluation criteria of R^2 , MAE and MSE and the actual and predicted values of holding time, it was concluded that RBFNN neural network had the best performance, the most accurate precision and the best fitting. Its R^2 was much higher than those of GRNN and BPNN neural networks, and MSE and MAE were much lower than those of GRNN and BPNN neural networks. The three evaluation indicators reached 0.999 93, 0.009 63 and 0.062 86, respectively. The performance of the optimized Random-Walk-RBFNN was further improved, R^2 was increased by 0.004%, and MSE, MAE and running time were decreased by 60.02%, 34.20% and

收稿日期: 2022-10-10

基金项目: 高水平大学学科建设医工交叉创新项目 (10-22-309-501)

作者简介: 杨佳文 (1998—), 男, 硕士生, 主攻计算机技术与冷链物流技术。

通信作者: 曾台英 (1978—), 女, 博士, 讲师, 硕导, 主要研究方向为包装运输动力学和优化设计。

5.29%, respectively. RBFNN neural network is the most outstanding in all aspects, which is more suitable for evaluating the thermal insulation performance of cold chain incubator. The optimized Random-Walk- RBFNN has better performance, improves R^2 , reduces MSE, MAE and running time, and achieves better evaluation performance.

KEY WORDS: cold chain incubator; cold storage agent; artificial neural network; mean square error

近年来,随着人们生活水平的改善,对生鲜需求愈来愈大^[1]。为了保证生鲜运输的质量,其短途及小批量的生鲜物流配送,一般运用冷链保温箱。对于冷链保温箱,其关键是利用蓄冷剂的相变吸热保持生鲜食品、医疗药品的质量^[2],有着无须能源、方便小巧等特点^[3],从而可知冷链保温箱的蓄冷剂的选择对整个保温性能极其重要。

考虑整个生鲜物流实验复杂繁琐、研发成本高及误差偏大,国内外诸多学者研究了神经网络技术在冷链物流中的应用。潘珠^[4]利用 BP 神经网络实现了海南省农产品近年来冷链物流配送需求量额度的估算。李敏杰等^[5]比较 RBF、BP 神经网络、MLR、GM 模型对水产品冷链物流配送需求的预测能力,得出 RBF 神经网络预测能力最好。杨玮等^[6]利用 AHP-PSO-SVM 建立了现代化农产品冷链物流服务质量安全性风险预警模式,以避免农产品在冷链物流过程中出现腐败、变质、过期等问题。Chen 等^[7]利用 BP 和 PCA-BP 神经网络模型对 A 市 2010—2018 年果蔬冷链物流所需量进行分析,从而得出更适合预测冷链物流所需量的神经网络是 PCA-BP。Zheng^[8]建立了 BPNN 模型,以有效避免农产品交叉环境污染,确保从农田到饭桌的任何环节的卫生、安全性和产品质量。为了确保生鲜的品质,其保温箱的保温时长是关键参数。虽然国内外在冷链物流上神经网络的研究有很多,但是在冷链保温箱的保温性能方面鲜有研究。

诸多神经网络算法中,涉及到函数逼近、图像识别、语音输入等^[9]多种应用。本文的评估冷链保温箱的保温性能问题属于非线性回归问题,同时无须考虑时序及状态的复杂条件。处理这类问题, BPNN、

RBFNN 及 GRNN 这 3 个神经网络应用相对较为广泛、性能较好、收敛速度快、预测精度高、误差较小。但是,这 3 种算法都需要在构建网络前设定参数, BPNN 需要设定隐藏节点数量, RBFNN 需要设定径向基扩展速度、GRNN 需要设定光滑因子,这些参数设定的好坏直接影响预测的精确性。一般这些参数通过手动试错或者利用 for 循环遍历,这 2 种方法找到的解可能是局部最优解,因此通常采用全局最优算法,诸如全局搜索 GlobalSearch 算法^[10]、GA 遗传算法^[11]、粒子群算法 PSO^[12]、模拟退火算法 SA^[13]、随机漫步算法 Random-Walk^[14]等对其进行进一步优化。

综上,本文通过 BPNN、RBFNN、GRNN 三大常用人工神经网络,对冷链保温箱在不同蓄冷剂参数的条件下的保温时间进行预测,并通过判定系数、均方误差、平均绝对误差等方面进行比较,从而找到最适合对冷链保温箱保温性能进行评估的神经网络,随后对其利用随机漫步算法 Random-Walk 进行优化改进,使其性能进一步提升、预测精度更高、误差更小。

1 数据样本来源

本文所使用的 3 个神经网络的所有训练和测试样本都来源于《基于冷链物流条件下保温箱蓄冷剂的选择分析》^[2]的实验数据。通过表 1 所示的四大参数——相变温度、相变潜热、摆放形式和环境温度的排列组合进行实验,最终得出的 1 440 组保温时长数据,其数据分布直方图如图 1 所示。然后在神经网络中将这实验数据以 4:1 的比例随机分配给训练、测试的样本。




图1 保温时长数据直方图
Fig.1 Histogram of holding time data

表 1 蓄冷剂参数
Tab.1 Parameter of cold storage agent

序号	相变温度/℃	相变潜热/(kJ·kg ⁻¹)	摆放形式	环境温度/℃
1	0	40.0	侧摆	10
2	0	40.0	侧摆	20
3	0	40.0	侧摆	30
4	0	40.0	侧摆	40
5	0	40.0	侧摆	50
6	0	40.0	顶角	10
...	...	...	...	...
11	0	40.0	对角	10
...	...	...	...	...
16	0	40.0	间隔	10
...	...	...	...	...
21	0	80.0	侧摆	10
...	...	...	...	...
160	0	320.0	间隔	50
161	1	40.0	侧摆	10
...	...	...	...	...
1 281	8	40.0	侧摆	10
...	...	...	...	...
1 440	8	320.0	间隔	50

2 神经网络建模

基于上述分析,本文对 BPNN、RBFNN 和 GRNN 神经网络进行建模。

2.1 BPNN 神经网络建模

BPNN 神经网络是一种有着很多层数的,总体由输入、输出及隐藏层等 3 层构成的前馈神经网络,其中隐藏层可以不止一层。本实验的 BPNN 结构如图 2 所示。它有着从输入、隐藏层到输出层的前向传播阶段,以及利用输出值误差反过来更新输出到输入层各




图 2 BPNN 神经网络结构
Fig.2 Structure of BPNN neural network

节点的权重的反向传播这 2 个阶段^[15]。它泛化性强,可以自我学习与自适应,并且有着强大的非线性映射功能,但是它收敛速度较慢,而且容易出现陷入局部最小的不良现象^[16]。该神经网络适用于岩土工程优化^[17]、故障分析^[18]、函数逼近^[19]等。

本文 BPNN 运行过程(包括原理)如下:

1) 读取样本数据。将保存数据的 Excel 表格进行读取。

2) 将读取的样品数据结果随机分配为训练、测试样本,并使其比例为 4:1(输入参数如表 1 所示,输出是保温时间数据),并且设置输入节点为 3,输出节点为 1,隐藏层节点数则通过 for 循环语句得出。for 语句循环运行 BPNN 神经网络,且每次得出其均方误差,并给隐藏层节点数加 1。当预测结果值的均方误差到达其中最小值的时候,此时的节点数就是最适合进行本实验的 BPNN 隐藏层节点数,这样做不仅减少了误差,还减少了原先人工试错的工作量。

3) 将训练、测试样本进行归一化到[-1,1]。

4) 利用 newff 函数对 BPNN 神经网络进行构建,将输入层到隐藏层的激活函数设定为 tanh 函数,隐藏层到输出层激活函数设置为 purelin 函数,并采用 L-M 优化算法进行训练,设定好各层各节点权重。其中输入层到隐藏层各节点输出结果的运算如式(1)所示,隐藏层到输出层的预测结果运算如式(2)所示。

$$b_j = \tanh\left(\sum_{i=1}^3 v_{ij} \cdot x_i\right) = \frac{e^{\sum_{i=1}^3 v_{ij} \cdot x_i} - e^{-\sum_{i=1}^3 v_{ij} \cdot x_i}}{e^{\sum_{i=1}^3 v_{ij} \cdot x_i} + e^{-\sum_{i=1}^3 v_{ij} \cdot x_i}} \quad (1)$$

式中: b_j 为隐藏层的第 j 个节点的输出结果; x_i 为输入层的第 i 个节点的输入样本; v_{ij} 为输入层的第 i 个节点到隐藏层的第 j 节点的权重数值。

$$y = \text{purelin}\left(\sum_{j=1}^q w_{jl} \cdot b_j\right) = \sum_{j=1}^q w_{jl} \cdot b_j \quad (2)$$

式中: y 为输出层预测结果; w_{jl} 为隐藏层的第 j 个节点到输出层的权重数值。

5) 进行配置网络参数,即训练 1 000 次,训练目标最小偏差为 0.001,终止迭代次数为 60,学习速率为 0.01。

6) 开始 BPNN 神经网络的训练与预测。

7) 将预测结果进行反归一化,并利用最小评分法来进行误差的计算,如式(3)所示。

$$E = \frac{1}{2}(t - y)^2 \quad (3)$$

式中: t 为实验实际值; y 为 BPNN 的预测结果。

8) 根据误差进行反向更新各层权重。

9) 重复步骤 4—8,一直迭代到设定的迭代次数或者达到设定的误差最低界限,最后输出最终的预测结果。

2.2 RBFNN 神经网络建模

RBFNN 神经网络是一个只有输入、输出和隐藏层,且隐藏层只能一层的 3 层的前馈神经网络,本实验的 RBFNN 如图 3 所示。运行过程:输入层到隐藏层通过高斯函数进行计算转为隐藏层到输出层的线性组合计算^[20]。有着强大的非线性映射功能,不会出现局部极小现象且收敛速度相对较快,但是其泛化能力差。由于把所有信息转为数字而易丢失信息,数据样本不充分或者较少会导致其无法良好运行^[21]。该神经网络适于逼近非线性函数^[22]、模式识别^[23]、粮食品质预测^[24]等。




图 3 RBFNN 神经网络结构
Fig.3 Structure of RBFNN neural network

RBFNN 的运行过程与 BPNN 的过程大致相似,不同点(包括原理)如下:

1) BPNN 步骤 2 中设定各层节点数的步骤, RBFNN 不再需要。

2) 相比于 BPNN 的步骤 4, RBFNN 神经网络在构建前需要设定 4 个参数,本文利用 newrb 函数进行构建网络,需要 er(目标均方误差)、mn(神经元个数最大值)、df(每次运行加入输入量个数)和 spread(径向基扩展速度)4 个参数。前 3 个根据输入设置,本文设置 er 为 1×10^{-8} 、mn 为 300、df 为 100。一般 spread 通过人为试错,直到误差最小。本文则采用 for 循环语句,不断迭代重复输入至输出的过程,每次求出均方误差(MSE),并进行 spread 的累加,直到寻找最小 MSE 值,此时的 spread 值作为参数进行构建 RBFNN。

3) 相较于 BPNN 步骤 4 的网络构建, RBFNN 构建方式略有不同,即利用 newrb 及上述所需的 4 个参数进行网络构建。内部过程:从输入层到隐藏层的运算一般利用高斯函数作为基函数,以将输入层的低维度升至隐藏层的高维度,运算如式(4)所示,然后利用隐藏层到输出层的线性求和计算得出预测值,其公式如式(5)所示。RBFNN 神经网络无须 BPNN 步骤 5 的配置网络参数。

$$C_j(x) = e^{-\frac{\|x_i - d_j\|^2}{2\sigma^2}}, \quad \sigma = \frac{1}{3} \|b - d_j y\|^2 \quad (4)$$

式中: C_j 为隐藏层的第 j 个节点的输出结果; $x_i (i=1, 2, 3)$ 为输入层的第 i 个节点的输入样本值; d_j 为隐藏层的第 j 个基函数中心; σ 为损失函数; b 为实验实际值; y 为输出层的预测结果。

$$y = \sum_{j=1}^q w_{j1} \cdot c_j \quad (5)$$

式中: c_j 为隐藏层的第 j 个节点的输出结果; y 为输出层的预测结果; w_{j1} 为隐藏层的第 j 个节点到输出层的权重数值。

4) 与 BPNN 的步骤 8 相比, RBFNN 的反归一化略有不同,即 RBFNN 神经网络利用误差更新隐藏层各节点到输出层之间的每个权重,以更新输出层预测结果,到达设定值(MSE 值为 1×10^{-8})则停止。

2.3 GRNN 神经网络建模

GRNN 神经网络是一种有着输入、模式、求和以及模式层的 4 层前馈神经网络,可以使用密度函数的“非参数估计器”来预测连续变量^[25],本实验的 GRNN 结构如图 4 所示。GRNN 神经网络运行过程如下:首先,输入层到模式层的过程通过线性组合计算;然后利用求和层通过权重为 1 的神经元和权重为 y 的神经元这 2 种方式对模式层求和,得到 2 个结果;最后输出权重为 y 的神经元的结果除以权重为 1 的神经元的结果的商。GRNN 神经网络只需调整参数 spread,在样本少或数据精度不高的时候具有优势^[26],是一次学习的算法^[27],并且收敛快、非线性函数逼近优秀。但是,存在计算和空间复杂的缺点。该神经网络适用于函数逼近^[28],以及预测地震震级^[29]和物流运输风险^[30]。




图 4 GRNN 神经网络结构
Fig.4 Structure of GRNN neural network

GRNN 运行过程与 BPNN 的相似,不同点(包括原理)如下:

1) BPNN 步骤 2 中的设定各层节点数, GRNN 神经网络无须设定。

2) 相较于 BPNN 的步骤 4, GRNN 网络在构建

前只需设定 spread 光滑因子, 利用 crossvalind 函数对输入样本进行 k 倍交叉验证。将样本中作为训练集的样本个数作为 crossvalind 函数的 N (观察样本数量), 设定 K (平均的子集数量) 为 5, 则每次都会选 1 个来验证, 剩下 4 个来训练, 并循环重复 5 次。嵌套 spread 的 for 语句循环, 不断重复输入至输出的过程, 输出此时的均方误差。当 MSE 值达到其中最小的时, 将此时的最佳 spread 值作为参数来构建网络。

3) 相较于 BPNN 步骤 4 的网络构建略有不同, GRNN 利用函数 newgrnn 得出的最佳 spread 值进行构建神经网络。其内部的过程: 样本进入输入层, 然后通过式 (6) 得到模式层各节点值。求和层有 S_D 和 S_N 2 种, 模式层各节点到 S_D 节点的权重为 1, 模式层各节点到 S_N 节点的权重为 y , 它们的值由式 (7) 计算可得。最后通过式 (8) 得到输出层的预测值。

$$P_i = e^{-\frac{(x_k - x_i)^T (x_k - x_i)}{2\sigma^2}}, \quad x_k = [x_1, x_2, x_3], \quad i = 1, 2, \dots, q \quad (6)$$

式中: P_i 为模式层的第 i 个节点的输出结果; x_k 为此时所以输入样本值组成的向量; x_i 为输入层的第 i 个输入样本值; σ 为参数光滑因子。

$$S_D = \sum_{i=1}^q P_i, \quad S_N = \sum_{i=1}^q y_{i1} \cdot P_i \quad (7)$$

式中: S_N 和 S_D 分别为求和层的 2 种神经元 (权重为 1 的神经元和权重为 y 的神经元) 的输出结果; y_{i1} 为模式层的第 i 个节点与求和层的 S_D 神经元之间的权重数值。

$$y = \frac{S_D}{S_N} \quad (8)$$

式中: y 为输出层结果的预测值。

4) 相较于 BPNN 步骤, GRNN 第 1 次反归一化就结束, 无须更新权重的反向传播。

3 神经网络评价标准

本文对 BPNN、RBFNN 和 GRNN 这 3 种神经网络的评价标准为判定系数 R^2 、均方误差 (MSE) 以及平均绝对误差 (MAE)。

判定系数 R^2 可以用来度量所使用的网络模型的拟合优度是否足够好。当它的值越接近于 1, 就说明本模型的回归直线对实验的实际值拟合得越好, 拟合优度越好^[31]。由于本文数据属于样本数据, 所以运算方式如式 (9) 所示。

$$R^2 = \frac{\left[N \sum_{i=1}^N f(x_i) y_i - \sum_{i=1}^N f(x_i) \sum_{i=1}^N y_i \right]^2}{\left\{ N \sum_{i=1}^N f^2(x_i) - \left[\sum_{i=1}^N f(x_i) \right]^2 \right\} \times \left[N \sum_{i=1}^N y_i^2 - \left(\sum_{i=1}^N y_i \right)^2 \right]} \quad (9)$$

式中: N 为实验样本总数; y_i 为实验实际值;

$f(x_i)$ 为神经网络所预测的结果。

均方误差 (σ_{MSE}) 是预测结果值与实验实际值之差的平方期望概率, 一般是用来度量平均值偏差和变量精度。它用于反映各种数据样本的变化程度的大小。值越小, 说明所使用的神经网络模型能够更强地将实验实际值进行拟合, 拥有更高的精确度, 公式如式 (10) 所示。

$$\sigma_{MSE} = \frac{\sum_{i=1}^N (f(x_i) - y_i)^2}{N} \quad (10)$$

平均绝对误差 (σ_{MAE}) 是因为每个样本所产生的绝对误差都有上下的波动, 不是固定的数值, 所以将其绝对误差求均值。它能把神经网络预测结果的误差的实际情况更好地表现出来^[32], 公式如式 (11) 所示。

$$\sigma_{MAE} = \frac{\sum_{i=1}^N |f(x_i) - y_i|}{N} \quad (11)$$

4 预测结果和分析

将 1 440 组实验实际数据分别输入构建完成的 BPNN、RBFNN、GRNN 的神经网络中。以 4:1 的比例随机分到训练、测试样本中。然后分别将训练、测试样本输入到 BPNN、RBFNN、GRNN 这 3 种神经网络中以预测保温时间。针对输出的数据, 通过式 (9) — (11) 分别对 3 个神经网络计算 3 个评价标准, 并以折线方式呈现预测值与实验实际值的关系, 以数字的形式呈现 3 个评价标准的值, 见图 5—7 和表 2。

由图 5—7 和表 2 可知, 3 种神经网络的估计保温时间与实验实际值都非常接近, 基本呈现拟合的状态。其中 RBFNN 神经网络预测值最接近真实值, 其次 BPNN 神经网络、GRNN 神经网络的预测值偏离稍大。在 R^2 方面, RBFNN 神经网络模型回归直线拟合实验实际值的程度最优, 可达到 0.999 93; BPNN 神经网络拟合优度稍差, 为 0.999 26; GRNN 神经网络拟合优度最差, 但其拟合优度较为准确, 为 0.996 15。在 MSE 和 MAE 方面, 神经网络 RBFNN 的 MSE 值和 MAE 值最小, 分别达到 0.009 63 和 0.062 86; 神经网络 BPNN 的 MSE 值和 MAE 值其次, 分别达到 0.103 63 和 0.224 53; 神经网络 GRNN 的 MSE 值和 MAE 值稍大, 分别为 0.633 59 和 0.555 65。

另外, 由表 2 可知, BPNN、RBFNN 和 GRNN 这 3 个神经网络的运行时间基本差距不大, 相较而言, RBFNN 用时最短, BPNN 用时次之, GRNN 用时稍长。总体而言, 3 个神经网络的运行时间都较短。




图 5 BPNN 神经网络预测结果值与实验实际值的对比

Fig.5 Comparison between prediction results of BPNN neural network and experimental actual values




图 6 RBFNN 神经网络预测结果值与实验实际值的对比

Fig.6 Comparison between prediction results of RBFNN neural network and experimental actual values




图 7 GRNN 神经网络预测结果值与实验实际值的对比

Fig.7 Comparison between prediction results of GRNN neural network and experimental actual values

表 2 3 种神经网络的评价标准及运行时间
Tab.2 Evaluation criteria and running time of three neural networks

神经网络	判定系数	均方误差	平均绝对误差	运行时间/s
BPNN	0.999 26	0.103 63	0.224 53	50.324 48
RBFNN	0.999 93	0.009 63	0.062 86	49.929 93
GRNN	0.996 15	0.633 59	0.555 65	52.631 91

上述分析可知,在不同蓄冷剂参数条件下,3 种人工神经网络对冷链保温箱的保温时长的预测性能都很优秀,运行用时都较短,实际应用都十分广泛。其中神经网络 RBFNN 最为突出,在各个方面都显著优于 BPNN 神经网络和 GRNN 神经网络。因此可以得出神经网络 RBFNN 最适用于不同蓄冷剂参数条件下冷链保温箱保温性能的评估。

5 优化改进

对于神经网络 RBFNN,利用逐个试错或者 for 循环去寻找最优 spread,寻找到的很有可能仅仅是局部最优值。因此,利用全局最优算法进一步对 RBFNN 改进,使其性能更优、预测更精确、误差更小。

Random-Walk 是概率论中经典的模型之一,每一步都是随机的,每一步前进的距离取决于前一步的状态,可以很快就找到最优值。Random-Walk 广泛应用于金融、生物学和物理学等各个领域^[33],因此利用这个全局最优算法对 RBFNN 进行优化。

总体步骤与 RBFNN 的步骤基本相同,将其步骤 2 改为以下步骤,其余步骤不变。

- 1) 设置参数 er 、 mn 、 df 的值不变,并加入总迭代数 N 为 100、步长 p 为 0.5、径向基扩展速度 s 初值为 1、误差初值 E 为 1×10^{20} 以及步长下限 ε 为 0.000 01。
- 2) 当前迭代数 k 初值设为 1。
- 3) 生成(0,1)的随机数 u ,并利用式(12)将其标准化,并由式(13)得出 $spread1$,这就是下一步漫步。

$$u' = \frac{u}{\sqrt{\sum_{i=1}^n u_i^2}}, u = (u_1, u_2, \dots, u_n), 0 < u < 1$$

(12)

式中: u' 为生成的随机数 u 之一; u 为生成的随机数。

$$s_1 = s + p \times u'$$

(13)

式中: s_1 为下一步漫步; p 为步长。

- 4) 训练 RBF 网络从输入到预测输出,并输出当前均方误差,如果误差小于 E ,则新均方误差值赋值给 E , $spread1$ 赋值给 $spread$;如果误差大于等于 E ,则 k 累加 1,步长减半,步数累加 1。
- 5) 回到步骤 3,继续进行计算。
- 6) 当 $k \geq N$ 时, k 重新置 1,继续从步骤 3 开始继续进行计算。
- 7) 当步数低于 ε ,则输出最终 s 。

如图 8 和表 2 可知,经过随机漫步优化后,神经网络 RBFNN 各项性能都优化了,其中 R^2 提升了 0.004%, MSE 值、MAE 值和运行时间分别下降了 60.02%、34.20%和 5.29%。这是由于通过这个算法优化后,寻找到了全局最优的 $spread$ 值,并且以步长每次减半的方式进行迭代,提高了寻找的效率。




图 8 Random-Walk-RBFNN 神经网络预测结果与实验实际值的对比
Fig.8 Comparison between prediction results of Random-Walk-RBFNN neural network and experimental actual values

表 3 RBFNN 和 Random-Walk-RBFNN 的评价标准及运行时间
Tab.3 Evaluation criteria and running time of RBFNN and Random-Walk-RBFNN

神经网络	判定系数	均方误差	平均绝对误差	运行时间/s
RBFNN(A)	0.999 93	0.009 63	0.062 86	49.929 93
Random-Walk-RBFNN(B)	0.999 97	0.003 85	0.041 36	47.288 67
$\frac{ B-A }{A} \times 100\%$	0.00%	60.02%	34.20%	5.29%

6 结语

构建了 BPNN、RBFNN 和 GRNN 这 3 种人工神经网络,对冷链保温箱的保温时间进行了预测,以评估其保温性能。用神经网络预测的保温时间与实验值的对比折线图和判定系数 (R^2)、均方误差 (MSE)、平均绝对误差 (MAE) 这 3 个评价标准值分别对 3 种神经网络的性能进行了分析。最终得到 3 种神经网络的预测都很理想,尤其 RBFNN 神经网络的预测值与实验值最接近,其判定系数远高于 GRNN 和 BPNN 神经网络,均方误差和平均绝对误差远低于 GRNN 和 BPNN 神经网络。3 个评价指标分别为 0.999 93、0.009 63 和 0.062 86,说明 RBFNN 神经网络对不同蓄冷剂参数条件下的冷链保温箱的保温性能评估最优。最后进一步利用随机漫步算法 Random-Walk 对其进行优化,其优化后 R^2 提升了 0.004%, MSE 值、MAE 值和运行时间分别下降了 60.02%、34.20%和 5.29%。

参考文献:

- [1] 张庆霞. 植物源防腐剂的抑菌机理及其在生鲜湿面保鲜中的应用[J]. 食品与发酵工业, 2020, 46(21): 310-316.
- [2] 江海林, 曾台英, 丁逸秋. 基于冷链物流条件下保温箱蓄冷剂的选择分析[J]. 包装工程, 2021, 42(7): 168-174.
- [3] 张莉伟, 付志强, 张蕾, 等. 环境温度和导热系数条件下保温箱壁厚分析[J]. 包装工程, 2020, 41(5): 97-102.
- [4] 潘珠. 基于 BP 神经网络的海南省农产品冷链物流需求预测分析[J]. 物流技术, 2020, 39(11): 69-72.
- [5] 李敏杰, 王健. 基于 RBF 神经网络的水产品冷链物流需求预测研究[J]. 中国农业资源与区划, 2020, 41(6): 100-109.
- [6] 杨玮, 偶雅楠, 岳婷, 等. 基于 AHPSO-SVM 的农产品冷链物流质量安全预警模型[J]. 包装工程, 2018, 39(5): 71-76.
- [7] CHEN Ying, WU Qiu-ming, SHAO Li-jin. Urban Cold-Chain Logistics Demand Predicting Model Based on Improved Neural Network Model[J]. International Journal of Metrology and Quality Engineering, 2020, 11: 5.
- [8] ZHENG Liu. Research on the Performance Evaluation Method for Cold Chain Logistics of Agriculture Products Based on BP Neural Network Model[J]. The Open Cybernetics & Systemics Journal, 2015, 9(1): 2168-2172.
- [9] 汤素丽, 罗宇锋. 人工神经网络技术的发展与应用[J]. 电脑开发与应用, 2009, 22(10): 59-61.
- [10] LIU X, WEI F, ZHANG G. Uncertainty Optimization Design of Airfoil Based on Adaptive Point Adding Strategy[J]. Aerospace Science and Technology, 2022, 130: 107875.
- [11] LI H, SHI N. Application of Genetic Optimization Algorithm in Financial Portfolio Problem Neurosci[J]. Computational Intelligence, 2022: 5246309.
- [12] RAUF H T, SHOAIB U, LALI M I, et al. Particle Swarm Optimization with Probability Sequence for Global Optimization[J]. IEEE Access, 2020, 99: 110535-110549.
- [13] JIAO Shan-shan, PAN Zhi-song, CHEN Yu-tian, et al. Cloud Annealing: A Novel Simulated Annealing Algorithm Based on Cloud Model[J]. IEICE Transactions on Information and Systems, 2020, 103(1): 85-92.
- [14] HAO J, YANG X, WANG C, et al. An Improved NSGA-II Algorithm Based on Adaptive Weighting and Searching Strategy[J]. Applied Sciences, 2022, 12(22): 11573.
- [15] ZHANG Y G, TANG J, LIAO R P, et al. Application of an Enhanced BP Neural Network Model with Water Cycle Algorithm on Landslide Prediction[J]. Stoch Environ Res Risk Assess, 2021, 35: 1273-1291.
- [16] 王海军, 金涛, 门克内木乐. BCC-BP 算法在 RGB 值到 LAB 值色彩空间转换中的应用[J]. 包装工程, 2021, 42(15): 269-274.
- LI Min-jie, WANG Jian. Prediction of Demand for cold-Chain Logistics of Aquatic Products Based on Rbf Neural Network[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2020, 41(6): 100-109.
- YANG Wei, OU Ya-nan, YUE Ting, et al. Quality and Safety Early Warning Model of Agricultural Products Cold Chain Logistics Based on AHPSO-SVM[J]. Packaging Engineering, 2018, 39(5): 71-76.
- TANG Su-li, LUO Yu-feng. Development and Application of Artificial Neural Network Technology[J]. Computer Development & Applications, 2009, 22(10): 59-61.
- WANG Hai-jun, JIN Tao, MEN K. Application of BCC-BP Algorithm in Color Space Conversion from RGB Value to LAB Value[J]. Packaging Engineering, 2021, 42(15): 269-274.

- [17] 黄永恒, 曹平, 汪亦显. 基于BP神经网络的岩土工程预测模型研究[J]. 科技导报, 2009, 27(6): 61-64.
HUANG Yong-heng, CAO Ping, WANG Yi-xian. A Model for Geotechnical Engineering Monitoring Based on BP Neural Networks[J]. Science & Technology Review, 2009, 27(6): 61-64.
- [18] 邵建浩, 张婷. 基于BP神经网络的SCARA机器人故障诊断[J]. 机床与液压, 2022, 50(14): 166-170.
SHAO Jian-hao, ZHANG Ting. Fault Diagnosis of SCARA Robot Based on BP Neural Network[J]. Machine Tool & Hydraulics, 2022, 50(14): 166-170.
- [19] 张婷. 神经网络算法在函数逼近中的应用[J]. 山西电子技术, 2021(1): 60-63.
ZHANG Ting. Application of Neural Network Algorithm in Function Approximation[J]. Shanxi Electronic Technology, 2021(1): 60-63.
- [20] ZHAO Y, HUANG Z, XIN F, et al. Kick Prediction Method Based on Artificial Neural Network Model[J]. Energies, 2022, 15(16): 5912.
- [21] YANG Y, WANG P, GAO X. A Novel Radial Basis Function Neural Network with High Generalization Performance for Nonlinear Process Modelling[J]. Processes, 2022, 10(1): 140.
- [22] 王丽丽. 基于RBF神经网络函数拟合方法的仿真与研究[J]. 河北农机, 2016(11): 61.
WANG Li-li. Simulation and Research of Function Fitting Method Based on RBF Neural Network[J]. Hebei Agricultural Machinery, 2016(11): 61.
- [23] 王卓, 朱宁宁, 郑祥. 基于LDA和RBF神经网络的开关柜局部放电模式识别方法研究[J]. 电子测量技术, 2021, 44(14): 148-152.
WANG Zhuo, ZHU Ning-ning, ZHENG Xiang. Research on Partial Discharge Pattern Recognition Method of Switchgear Based on LDA and RBF Neural Network[J]. Electronic Measurement Technology, 2021, 44(14): 148-152.
- [24] 郭利进, 惠培奇, 许瑞伟. MI-PSO-RBF算法在稻谷存储品质预测的应用研究[J/OL]. 中国粮油学报: 1-8[2023-07-12]. <https://doi.org/10.20048/j.cnki.issn.1003-0174.000083>.
GUO Li-jin, HUI Pei-qi, XU Rui-wei. Application of MI-PSO-RBF Algorithm in Rice Storage Quality Prediction[J/OL]. Chinese Journal of Grain and Oil: 1-8 [2023-07-12]. <https://doi.org/10.20048/j.cnki.issn.1003-0174.000083>.
- [25] MA H, LIANG S. Development of the GLASS 250-m Leaf Area Index Product (Version 6) from MODIS Data Using the Bidirectional LSTM Deep Learning Model[J]. Remote Sensing of Environment, 2022, 273: 112985.
- [26] 段梦楠, 刘泽功. 基于神经网络的煤与瓦斯突出规模预测研究[J]. 淮阴工学院学报, 2021, 30(1): 33-39.
DUAN Meng-nan, LIU Ze-gong. Research of Prediction of Coal and Gas Outburst Scale Based on Neural Networks[J]. Journal of Huaiyin Institute of Technology, 2021, 30(1): 33-39.
- [27] 张鹏, 张铖, 毛功平. 基于不同人工神经网络的CNG发动机排气温度预测模型研究[J]. 内燃机, 2020(2): 19-24.
ZHANG Peng, ZHANG Cheng, MAO Gong-ping. Research on Prediction Model of Exhaust Temperature of CNG Engine Based on Different Artificial Neural Networks[J]. Internal Combustion Engines, 2020(2): 19-24.
- [28] 丁硕, 常晓恒, 巫庆辉. GRNN与BPNN的函数逼近性能对比研究[J]. 现代电子技术, 2014, 37(7): 114-117.
DING Shuo, CHANG Xiao-heng, WU Qing-hui. Comparative Study on Function Approximation Performances of GRNN and BPNN[J]. Modern Electronics Technique, 2014, 37(7): 114-117.
- [29] 王晨晖, 袁颖, 刘立申, 等. 基于主成分分析法优化广义回归神经网络的地震震级预测[J]. 科学技术与工程, 2022, 22(29): 12733-12738.
WANG Chen-hui, YUAN Ying, LIU Li-shen, et al. Earthquake Magnitude Prediction Based on Generalized Regression Neural Network Optimized by Principal Component Analysis[J]. Science Technology and Engineering, 2022, 22(29): 12733-12738.
- [30] 赵晨阳, 何守慧. 基于PSO-GRNN算法的物流运输风险预测[J]. 物流技术, 2023, 42(2): 49-53.
ZHAO Chen-yang, HE Shou-hui. Prediction of Logistics Transportation Risk Based on PSO-GRNN[J]. Logistics Technology, 2019, 42(2): 49-53.
- [31] 王子旋, 黎向锋, 张宇翔, 等. 基于DNN的舵机用永磁式线性力电机驱动力预测模型[J]. 电机与控制应用, 2021, 48(9): 72-80.
WANG Zi-xuan, LI Xiang-feng, ZHANG Yu-xiang, et al. Prediction Model of Permanent Magnet Linear Force Motor Driving Force Used by Actuator Based on Deep Neural Network[J]. Electric Machines & Control Application, 2021, 48(9): 72-80.
- [32] 张洁, 郝倩男. 基于烟花算法优化BP神经网络的光伏功率预测[J]. 计算机技术与发展, 2021, 31(10): 146-153.
ZHANG Jie, HAO Qian-nan. Forecast of Photovoltaic Power Generation Based on Firework Algorithm Optimized BP Neural Network[J]. Computer Technology and Development, 2021, 31(10): 146-153.
- [33] CHEN Tian-yao, CHENG Xue, YANG Jing-ping. Decomposing Correlated Random Walks on Common and Counter Movements[J]. Statistics & Probability Letters, 2019, 158(3): 108616.