

DOI:10.3969/j.issn.1001-4551.2023.03.013

# 石墨烯润滑油润滑下摩擦副摩擦 因数预测模型\*

张丽秀<sup>1,2</sup>, 李爽<sup>3</sup>, 魏晓奕<sup>4</sup>, 王俊海<sup>1</sup>, 李颂华<sup>2,3</sup>

(1. 沈阳建筑大学分析与检测技术研究中心, 辽宁 沈阳 110000; 2. 沈阳建筑大学高档石材数控加工装备与技术国家地方联合工程实验室, 辽宁 沈阳 110000; 3. 沈阳建筑大学机械工程学院, 辽宁 沈阳 110000; 4. 沈阳建筑大学材料科学与工程学院, 辽宁 沈阳 110000)

**摘要:** 轴承摩擦状态很复杂, 且以滚动摩擦为主, 滚动摩擦因数的精确计算或者测量都很困难。针对轴承滚动摩擦因数难以测量的问题, 对与滚动摩擦因数密切关联的滑动摩擦因数进行了试验和预测研究, 提出了一种最佳滑动摩擦因数的预测网络模型。首先, 在石墨烯润滑油润滑工况下, 进行了 Si<sub>3</sub>N<sub>4</sub>-GCr15 摩擦副的摩擦磨损试验, 获得了不同工况下石墨烯质量分数下的滑动摩擦因数; 然后, 提出了广义回归神经网络 (GRNN), 并运用遗传算法 (GA) 优化得到了光滑因子 ( $\sigma$ ), 获得了最佳滑动摩擦因数的预测网络模型 GA-GRNN; 最后, 对测试集预测结果与其他预测模型预测结果进行了预测效果验证, 并结合验证集预测结果进行了预测模型的应用验证。研究表明: 与常规 GRNN 模型以及误差反馈 (BP) 神经网络模型相比, GA-GRNN 模型的摩擦因数预测准确度更高, 且其预测误差更小; GA-GRNN 模型的验证集预测值很接近真实值, 预测值平均准确率达到 92.30%, 预测相对误差在 [0.000 990 17, 0.008 324 9] 区间内, 对滑动摩擦因数预测效果良好。该结果可为轴承滚动摩擦因数的预测提供基础。

**关键词:** 轴承; 滚动/滑动摩擦因数; 广义回归神经网络; 遗传算法; 摩擦磨损试验; 预测误差; 预测准确度

中图分类号: TH117.1; F272.1

文献标识码: A

文章编号: 1001-4551(2023)03-0415-07

## Prediction model of friction factor of friction pair lubricated by graphene lubricating oil

ZHANG Li-xiu<sup>1,2</sup>, LI Shuang<sup>3</sup>, WEI Xiao-yi<sup>4</sup>, WANG Jun-hai<sup>1</sup>, LI Song-hua<sup>2,3</sup>

(1. Analysis and Detection Technology Research Center, Shenyang Jianzhu University, Shenyang 110000, China; 2. National and Local Joint Engineering Laboratory for High Grade Stone NC Processing Equipment and Technology, Shenyang Jianzhu University, Shenyang 110000, China; 3. College of Mechanical Engineering, Shenyang Jianzhu University, Shenyang 110000, China; 4. College of Materials Science and Engineering, Shenyang Jianzhu University, Shenyang 110000, China)

**Abstract:** The friction state of bearing is very complex, and the rolling friction is the main one. It is difficult to calculate or measure the rolling friction coefficient accurately. Aiming at the problem that the rolling friction factor of bearing was difficult to be measured, the sliding friction factor which was closely related to the rolling friction factor was measured and predicted. A prediction network model of optimal sliding friction coefficient was proposed. Firstly, the friction and wear tests of Si<sub>3</sub>N<sub>4</sub>-GCr15 friction pair under graphene lubrication were carried out to obtain the sliding friction factor under different graphene mass fraction under different working conditions. Then, the generalized regression neural network (GRNN) was proposed, and the genetic algorithm (GA) was used to optimize the smoothing factor ( $\sigma$ ), and the prediction network model of the best sliding friction factor was obtained. Finally, the prediction results of the test set and the

收稿日期: 2022-08-11

基金项目: 国家自然科学基金资助项目 (52175107, 51975388); 辽宁省教育厅项目 (LJKZ0599)

作者简介: 张丽秀 (1970-), 女, 辽宁辽中人, 博士, 教授, 主要从事数控机床电主轴关键技术及摩擦磨损理论方面的研究, E-mail: zhanglixu@sjzu.

edu.cn

prediction results of other prediction models were verified, and the application of the prediction model was verified by combining the prediction results of the validation set. The results show that, comparing with the conventional GRNN model and back propagation (BP) neural network model, the GA-GRNN model has significantly higher prediction accuracy and less prediction error. The predicted value of the validation set of GA-GRNN model is very close to the real value, the average accuracy of the predicted value is 92.30%, and the relative error of the prediction is within the range of [0.000 990 17, 0.008 324 9]. The prediction effect of the sliding friction factor is good, which can provide a basis for the prediction of the bearing rolling friction factor.

**Key words:** bearing; rolling/sliding friction factor; generalized regression neural network (GRNN); genetic algorithm (GA); friction and wear test; prediction error; prediction accuracy

## 0 引 言

众所周知,摩擦会导致能量浪费、材料损失以及机械系统中运动部件使用寿命的缩短。已有的相关材料显示,大约 23% 的总燃料能量损失直接归因于摩擦接触<sup>[1,2]</sup>。尤其是高速运转下的轴承,其摩擦会造成许多不利影响,包括摩擦磨损、摩擦生热、摩擦产生噪音等,这些都会影响轴承的使用寿命和使用精度。

轴承智能化运行控制需要获得轴承腔内准确的摩擦因数动态模型。但是轴承摩擦状态很复杂,以滚动摩擦为主,滚动摩擦因数的精确计算或者测量都很困难。

由于滚动摩擦比滑动摩擦至少小 10 倍的关系<sup>[3]</sup>,基于摩擦磨损试验机获得滑动摩擦因数试验数据,建立不同工况下滑动摩擦因数预测模型,进而精准预测滚动摩擦因数,是建立轴承摩擦因数动态模型的解决方案。

影响摩擦因数的因素有很多<sup>[4]</sup>,例如摩擦副的材料、转速、载荷、润滑油黏度等。李男儿等人<sup>[5]</sup>以水润滑轴承为研究对象,研究了不同的载荷和转速对轴承摩擦因数的影响,结果发现,不同的润滑条件对轴承摩擦因数的影响差异性较大,水润滑效果没有油润滑效果好。刘梓屹等人<sup>[6]</sup>采用原位还原的方法,利用基础油自身的还原性将氧化石墨烯直接在基础油中还原,制成了石墨烯发动机机油改进剂,探究了不同比例的石墨烯机油对摩擦因数的影响;但该研究仅就石墨烯机油一个影响因素进行了分析。POLA A 等人<sup>[7]</sup>选取了 3 种载荷和不同的滑动距离,使用轴承钢和铅黄铜进行了销盘试验,得出了不同摩擦副的摩擦因数;但滑动距离对之后所研究的滚动摩擦因数影响较小。

为了预测摩擦因数数值,BAOMING W 等人<sup>[8]</sup>基于灰色系统理论,研究了转速和载荷对滑动轴承摩擦因数的影响,并采用非线性自回归滑动平均法,建立了滑动轴承摩擦因数的非线性模型;但回归方程预测的

精度不是很高,且要处理异常值。席雷等人<sup>[9]</sup>以模化自某涡轮叶片内冷通道的厚壁带肋通道为研究对象,运用 BP 神经网络,以雷诺数、通道宽高比、肋角度为输入,对努塞尔数、综合热力系数、摩擦因数进行了预测,并运用遗传算法,基于努塞尔数和综合热力系数,分别对厚壁带肋通道的结构参数进行了优化;但 BP 神经网络对小数据集预测效果不好。陈忠华等人<sup>[10]</sup>采用数学公式建立了摩擦力的静态模型,并采用非线性拟合软件 1st Opt 对模型进行了辨识,并验证了该方法的可行性;但该研究中依据公式计算出的摩擦力具有一定的误差。战友等人<sup>[11]</sup>采用决策树算法,以不同面积占比下的宏微观纹理特征指标和测试温度为输入,对摩擦因数进行了预测;但是决策树算法会趋向于过拟合,可能陷入局部最小。AN ĐELKOVI Ć B R<sup>[12]</sup>基于模糊神经网络,结合试验数据建立了一个近似摩擦因数数值的模型;但模糊神经网络算法权重比较多,且其计算量也比较大。

结合国内外对摩擦因数和预测算法的研究,笔者首先利用摩擦磨损试验机获取不同工况下的 Si<sub>3</sub>N<sub>4</sub>-GCr15 摩擦副摩擦因数(石墨烯参与润滑),基于遗传算法优化广义回归神经网络,建立不同工况在 Si<sub>3</sub>N<sub>4</sub>-GCr15 摩擦副中的滑动摩擦因数预测模型,并将所得预测结果(采用上述模型)分别与优化前的基于广义回归神经网络、BP 神经网络的预测结果进行对比,并结合验证集预测结果对该模型的效果进行验证<sup>[13,14]</sup>。

## 1 试验测试

### 1.1 润滑油制备

为研究不同工况下,在 Si<sub>3</sub>N<sub>4</sub>-GCr15 摩擦副中的滑动摩擦因数变化情况,笔者开展了摩擦磨损试验。

笔者选取美孚 DTE-涡轮机/循环系统油作为基础润滑油,其倾点为 -18 ℃,闪点为 218 ℃,密度为 0.85 kg/m<sup>3</sup>,在 40 ℃ 时的运动黏度为 29.77 mm<sup>2</sup>/s,在 100 ℃ 时的运动黏度为 5.34 mm<sup>2</sup>/s;

石墨烯由中国青岛德通纳米科技有限公司生产,其面密度为  $0.77 \text{ mg/m}^2$ ,比表面积为  $887.9 \text{ m}^2/\text{g}$ ,孔容为  $0.22 \text{ cm}^3/\text{g}$ 。

笔者为得到目标质量分数的石墨烯润滑油,通过电子天平量取  $0.05 \text{ g}$ 、 $0.1 \text{ g}$  的石墨烯放入到润滑油中,使石墨烯润滑油的质量为  $100 \text{ g}$ ,可得到质量分数为  $0.05\%$ 、 $0.1\%$  的石墨烯润滑油。

笔者将石墨烯润滑油先磁力搅拌  $10 \text{ min}$ ,然后放入超声波清洗机中,设置超声时间  $30 \text{ min}$ ,确保石墨烯均匀分散在润滑油中<sup>[15]</sup>。

## 1.2 试验机及其配副形式

笔者的试验采用美国 Rtec 多功能摩擦磨损试验机。该试验设备包括旋转试验台、样品圆盘夹具、样品圆盘、样品球夹具以及样品球。

试验设备如图 1 所示。




图 1 试验设备

笔者选取  $\text{Si}_3\text{N}_4$ -GCr15 摩擦副为研究对象。 $\text{Si}_3\text{N}_4$  球与 GCr15 圆盘均为定制。 $\text{Si}_3\text{N}_4$  球与 GCr15 圆盘之间为点接触摩擦;

样品球直径为  $9.525 \text{ mm}$ ,表面粗糙度为  $Ra 0.012 \mu\text{m}$ ,硬度  $\geq 91 \text{ HRC}$ ;

样品圆盘直径为  $50 \text{ mm}$ ,厚度为  $5 \text{ mm}$ ,表面粗糙度选取平均值为  $Ra 0.75 \mu\text{m} \sim Ra 0.85 \mu\text{m}$ ,硬度为  $45 \text{ HRC} \sim 60 \text{ HRC}$ 。

试验样品如图 2 所示。




图 2 试验样品

## 1.3 润滑方式

在试验过程中, $\text{Si}_3\text{N}_4$  球由夹具固定,GCr15 圆盘由夹具固定,并绕固定轴线旋转。

为了实现  $\text{Si}_3\text{N}_4$  球与 GCr15 圆盘的滑动摩擦,笔者设置样品球夹具中心与工作台回转中心的偏移量为  $5 \text{ mm}$ 。笔者通过计算机设置不同的转速、载荷与试验时间等参数,所设置的载荷由上方夹具通过样品球施加。

在试验过程中,笔者定时向摩擦副之间添加石墨烯润滑油,以确保试验过程中供油量充分,实现油润滑的目的。

## 1.4 试验结果

笔者选取摩擦副材料为 GCr15- $\text{Si}_3\text{N}_4$ ,不同转速、载荷及润滑油中石墨烯质量分数来进行摩擦磨损试验,共进行 60 组试验。

通过试验得到了各个工况下的滑动摩擦因数数据,如表 1 所示。

表 1 试验数据

序号	载荷/ N	转速/ ( $\text{r} \cdot \text{min}^{-1}$ )	石墨烯质量 分数/%	滑动摩擦 因数
1	40	1 000	0	0.123 18
2	40	1 000	0.05	0.124 27
3	40	1 000	0.1	0.119 2
⋮	⋮	⋮	⋮	⋮
58	120	2 500	0	0.098 36
59	120	2 500	0.05	0.090 21
60	120	2 500	0.1	0.093 29

## 2 GA-GRNN 预测模型建模

### 2.1 数据采集与处理

笔者采取遗传算法优化广义回归神经网络算法,对摩擦磨损试验机的滑动摩擦因数进行预测。

笔者将上述试验数据划分为 3 部分,分别为训练集、测试集和验证集;并选取 5 组为验证集,其余 55 组为训练集和测试集。

一般情况下,训练集占比  $75\% \sim 90\%$ ,测试集占比  $10\% \sim 25\%$ <sup>[16]</sup>。故笔者选取 50 组试验数据为训练集,5 组为测试集。

### 2.2 GA-GRNN 预测模型的提出

目前,主要的函数拟合方法是统计方法和神经网络,但统计方法在应用中有许多严格的限制,而广泛使用的 BP 神经网络需要大量的数据样本进行训练,且优化参数过多。

广义回归神经网络具有良好的抗干扰性能、良好的逼近能力、较快的收敛速度和自主学习能力。此外,在处理小样本或不稳定数据时,广义回归神经网络 (GRNN) 有更好的效果<sup>[17-19]</sup>。

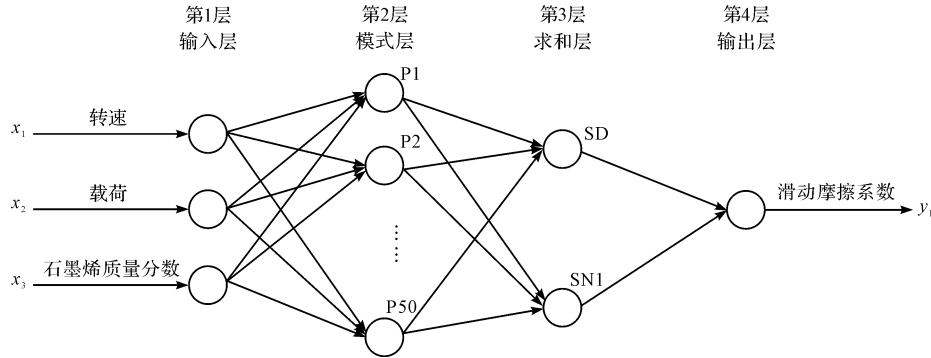


图3 预测滑动摩擦因数的广义回归神经网络结构图

第1层中的神经元个数等于学习样本输入向量的维数,为  $m=3$ ,直接将输入变量传递给模式层<sup>[20]</sup>;

第2层中的神经元数目与学习样本的数目相同,为  $n=50$ 。

每个神经元代表一个样本,神经元  $i$  的输出为输入变量与对应样本之间的 Euclid 距离平方的指数平方,其神经元传递函数表达式为:

$$p_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right], \quad i = 1, 2, \dots, n \quad (1)$$

式中:  $X$ —网络输入变量;  $X_i$ —第  $i$  个神经元对应的学习样本;  $\sigma$ —光滑因子。

第3层有两个神经元,分别是:(1)未加权输出的和,即直接对所有模式层神经元的输出进行算术求和;(2)加权输出的和,模式层中第  $i$  个神经元与求和层第  $j$  个分子求和,神经元之间的连接权值  $y_{ij}$  为第  $i$  输出样本中的第  $j$  个元素。

这两种求和计算公式为:

$$\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad (2)$$

$$\sum_{i=1}^n Y_i \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad (3)$$

式中:  $Y_i$ —第  $i$  个输出样本。

传递函数为:

$$S_D = \sum_{i=1}^n P_i \quad (4)$$

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i \quad j = 1, 2, \dots, k \quad (5)$$

第4层中的神经元数目等于学习样本中输出向量

GRNN 网络主要由4层结构组成,分别是输入层 (input layer)、模式层 (pattern layer)、求和层 (summation layer) 以及输出层 (output layer)。

GRNN 结构图如图3所示。

的维数  $k=1$ ,即滑动摩擦因数;各神经元将求和层的输出相除,神经元的输出就是预测结果<sup>[21]</sup>,即:

$$y = \frac{S_{Nj}}{S_D}, j = 1, 2, \dots, k \quad (6)$$

从式(1~6)可以看出:影响 GRNN 输出的唯一参数为光滑因子。所以,决定 GRNN 预测模型准确性的关键是寻求最优的光滑因子。

通常情况下,光滑因子的取值采用设定光滑因子的范围的方法,即光滑因子以一定间隔取值,然后将其代入训练过程中进行计算,选取均方误差最小的光滑因子值作为最佳值。

然而,这种寻找光滑因子值的方法计算过程复杂,如果设定间隔值过大时,则难以确定最优的光滑因子值;如果设定间隔值过小,就会导致计算量大,预测所需时间过长。所以,笔者提出一种利用遗传算法的全局寻优能力寻找光滑因子最优值的方法,使得所建立的 GRNN 模型预测效果最好。

预测滑动摩擦因数的 GA-GRNN 流程图如图4所示。

### 2.3 滑动摩擦因数的优化仿真

采用遗传算法寻找最优光滑因子的优化步骤如下:

(1)首先对训练集进行归一化处理;

(2)随机初始化种群,遗传算法中的染色体为 GRNN 中的光滑因子,其取值范围为  $0 \sim 2$ ,设置种群规模为 50,交叉和变异概率分别设置为 0.6 和 0.01,迭代次数设置为 100;

(3)计算个体适应度值,即 GRNN 模型预测的摩擦因数和实际摩擦因数的最大均方误差值;

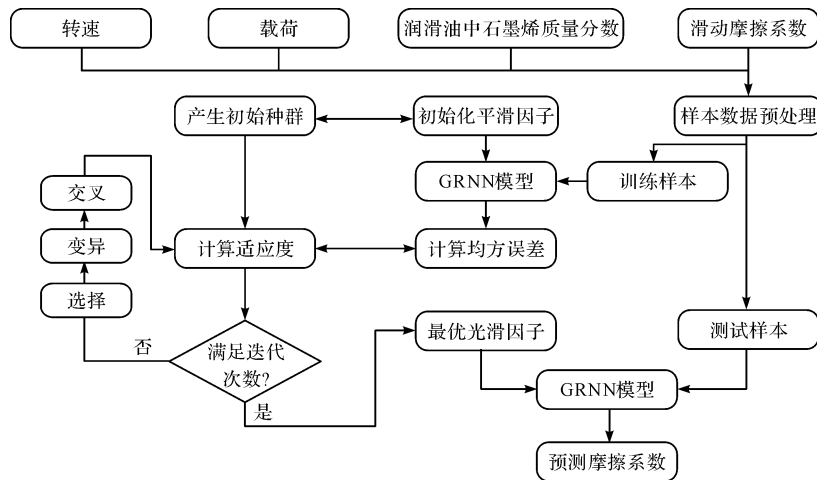


图 4 预测滑动摩擦因数的 GA-GRNN 流程图

(4) 判断是否达到最大迭代次数, 如果已达到, 则输出最优的光滑因子; 如果没达到, 对每个个体的适应度进行选择、交叉和变异操作, 得到新的种群, 直达到最大迭代次数;

(5) 采用最优的光滑因子建立 GRNN 模型, 对测试集进行预测, 并对预测结果采用均方误差 ( $MSE = \frac{1}{N} \sum_{i=1}^N \delta_i^2$ ) 进行评价。

### 3 预测与结果分析

#### 3.1 模型验证

笔者将选择的 5 组测试集代入滑动摩擦因数预测模型(基于遗传算法优化的广义回归神经网络的)中。GA-GRNN 测试集预测结果包括测试集所得滑动摩擦因数预测数据和试验数据。

GA-GRNN 测试集预测结果如图 5 所示。




图 5 GA-GRNN 测试集预测滑动摩擦因数的结果

根据图 5 可知:GA-GRNN 模型测试集预测值与实际值变化规律基本一致, 预测值平均准确率为 92.49% (其中,最大差值为 0.007 001 6,最小差值为 0.000 579 48)。

笔者将测试集代入滑动摩擦因数预测模型(基于未优化的广义回归神经网络的)中,GRNN 预测结果包括测试集所得滑动摩擦因数预测数据和试验数据。

GRNN 预测结果如图 6 所示。




图 6 GRNN 预测滑动摩擦因数的结果

根据图 6 可知:GRNN 模型测试集预测值与实际值变化规律虽然基本一致,但误差值过大,预测值平均准确率为 72.42% (其中,最大差值为 0.024 878,最小差值为 0.001 682 3)。

笔者建立 BP 神经网络滑动摩擦因数预测模型,设置隐含层层数为 5 层时误差最小,BP 神经网络预测结果包括测试集所得滑动摩擦因数预测数据和试验数据。

BP 神经网络预测结果如图 7 所示。




图 7 BP 神经网络预测滑动摩擦因数的结果

根据图 7 可知:BP 神经网络模型测试集预测值与实际值变化规律基本一致,预测值平均准确率为 87.54%

(其中,最大差值为 0.012 263,最小差值为 0.002 350 8)。

结合以上预测结果,笔者采用 GA-GRNN、GRNN 和 BP 神经网络预测结果得到了误差,如图 8 所示。

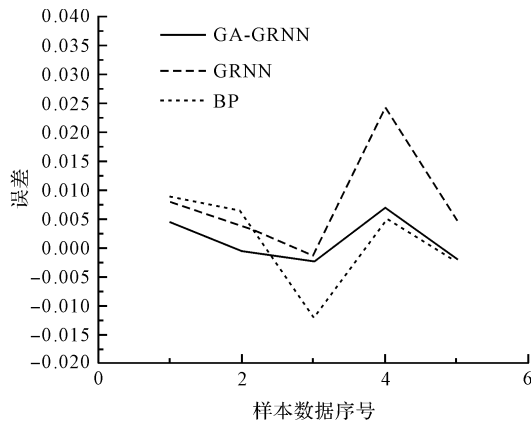


图 8 GA-GRNN、GRNN 和 BP 神经网络预测滑动摩擦因数的结果误差

从图 8 可知:滑动摩擦因数与转速、载荷、润滑油中,石墨烯质量分数之间的关系方程用 GA-GRNN 模型预测,预测结果与 GRNN 和 BP 神经网络模型预测结果相比误差更小,其预测准确度最高。

所以 GA-GRNN 模型有较好的预测性能。

### 3.2 模型应用验证

笔者将选择的 5 组验证集代入所构建的 GA-GRNN 预测模型中,GA-GRNN 验证集预测结果包括验证集所得滑动摩擦因数预测数据和试验数据<sup>[22]</sup>。

GA-GRNN 验证集预测结果如图 9 所示。




图 9 GA-GRNN 验证集预测滑动摩擦因数的结果

根据图 9 可知:GA-GRNN 预测值与实际值变化规律基本一致,预测值平均准确率为 92.30% (其中,最大差值为 0.008 324 9,最小差值为 0.000 990 17)。

所以 GA-GRNN 模型适用于滑动摩擦因数的预测。

## 4 结束语

针对轴承滚动摩擦因数难以测量的问题,笔者对与滚动摩擦因数密切关联的滑动摩擦因数进行了试验

和预测研究。首先,在石墨烯润滑油润滑工况下,进行了 Si<sub>3</sub>N<sub>4</sub>-GCr15 摩擦副的摩擦磨损试验,获得了不同工况下石墨烯质量分数下的滑动摩擦因数;然后,提出了最佳滑动摩擦因数的预测网络模型;最后,对测试集预测结果与其他预测模型预测结果进行了预测效果验证,并结合验证集预测结果进行了预测模型的应用验证。

研究表明:

(1)与 GRNN 神经网络相比,采用 GA-GRNN 的最大误差降低了 0.017 876 4,相对误差精度提高了 20.07% ;

(2)与 BP 神经网络相比,GA-GRNN 最大误差降低了 0.005 261 4,但相对误差精度提高了 4.95% ;

(3)GA-GRNN 预测模型预测结果和试验结果准确率达到 92.30% ,最大误差下降到 0.008 324 9 以下。

在今后的研究中,笔者将结合精准预测出的滑动摩擦因数数值,大致预测出轴承的滚动摩擦因数,再与 COMSOL 轴承温度场有限元模型相结合,以精确辨识出轴承的滚动摩擦因数。

### 参考文献 (References) :

- [1] WANG Jun-hai, ZHANG Wei-peng, LIANG Wen-Feng, et al. Inorganic nanomaterial lubricant additives for base fluids, to improve tribological performance: recent developments [J]. *Friction*, 20220, 10(5) :645-676.
- [2] HOLMBERG K, ERDEMIR A. Influence of tribology on global energy consumption, costs and emissions [J]. *Friction*, 2017, 5(3) :263-284.
- [3] 王成彪,刘家浚,韦淡平,等. 摩擦学材料及表面工程 [M]. 北京:国防工业出版社,2012.
- [4] 刘雪萌,谢英柏. 长输供热管网摩擦阻力系数的计算方法研究[J]. *流体机械*, 2022, 50(1) :100-104.
- [5] 李男儿,王琳. 不同含量盐水介质中丁腈橡胶水润滑轴承材料摩擦学特性分析[J]. *润滑与密封*, 2019, 44(7) : 46-50, 62.
- [6] 刘梓屹,马国政,肖逸锋,等. 石墨烯减摩抗磨涂层技术研究现状[J/OL]. *表面技术*: 1-20. [2022-09-19]. <http://kns.cnki.net/kcms/detail/50.1083.tg.20220409.2012.004.html>
- [7] POLA A, MONTESANO L, GELFI M, et al. Comparison of the sliding wear of a novel Zn alloy with that of two commercial Zn alloys against bearing steel and leaded brass [J]. *Wear*, 2016, 368-369(12) :445-452.
- [8] BAOMING W, JINXIN X, FEI Z, et al. Analysis and models for the friction coefficient of a sliding bearing[J]. *Applied Mechanics and Materials*, 2013, 2659(395-396) : 826-830.
- [9] 席雷,高建民,徐亮,等. 涡轮叶片厚壁带肋通道流动与传热性能的预测和优化[J]. *西安交通大学学报*,

- 2021,55(12):25-34.
- [10] 陈忠华,贾利明,时光,等. 波动载荷下弓网载流动态摩擦力模型[J]. 辽宁工程技术大学学报:自然科学版, 2021,40(1):48-55.
- [11] 战友,邓强胜,罗志伟,等. 基于GBDT的沥青路面抗滑性能感知模型研究[J/OL]. 土木工程学报:1-14. [2022-09-19]. <http://doi.org/DOI:10.15951/j.tmgxcb.21111144>.
- [12] AN ĐELKOVIĆ B R, SAMMARRAIE A A, MIL ĆI Ć D, et al. Consideration of the use of artificial intelligence methods for determining the friction coefficient of lubricated sliding bearings[J]. **IOP. Conference Series: Materials Science and Engineering**,2018,393(1):012-063.
- [13] 陈荟多,周东一,肖湘华. 基于广义回归神经网络的地铁屏蔽门通风量预测研究[J]. 中阿科技论坛:中英文, 2021(9):101-103.
- [14] 周敏,李世玲. 广义回归神经网络在非线性系统建模中的应用[J]. 计算机测量与控制,2007,108(9):1189-1191.
- [15] 吴玉厚,张珈翊,张丽秀,等. 旋转滑动摩擦副摩擦噪声影响因素实验研究[J]. 中国机械工程,2020,31(23):2814-2821.
- [16] 卢黎明,李夫,李中豪. 基于ADAMS的滚滑轴承摩擦转矩研究[J]. 机电工程,2020,37(9):1026-1031.
- [17] LUO W, FU Z. Application of generalized regression neural network to the agricultural machinery demand forecasting [J]. **Applied Mechanics and Materials**, 2013,278(1):2177-2182.
- [18] RUI H, SHIPING W, ZHIGANG Z, et al. A short-term power load forecasting model based on the generalized regression neural network with decreasing step fruit fly optimization algorithm [J]. **Neurocomputing**, 2017, 221(19):24-31.
- [19] YONGLI Z, JIANGUANG N, SANGGYUN N. A novel nonlinear function fitting model based on FOA and GRNN [J]. **Mathematical Problems in Engineering**,2019,201(3):1-10.
- [20] 谈智玲,陈才明,徐胜朝,等. 基于振动信号分析的滚动轴承寿命预测方法研究[J]. 华电技术,2021,43(5):36-44.
- [21] 朱正林,刘权,张欢. 基于优化广义回归神经网络的碟式太阳能温度预测研究[J]. 南京工程学院学报:自然科学版,2020,18(1):1-5.
- [22] 贾谦,阮琪,刘朝丰,等. 涡轮泵机械密封摩擦学性能的计算和试验研究[J]. 流体机械,2022,50(2):1-7.

[编辑:李辉]

#### 本文引用格式:

张丽秀,李爽,魏晓奕,等. 石墨烯润滑油润滑下摩擦副摩擦因数预测模型[J]. 机电工程,2023,40(3):415-421.

ZHANG Li-xiu, LI Shuang, WEI Xiao-yi, et al. Prediction model of friction factor of friction pair lubricated by graphene lubricating oil [J]. *Journal of Mechanical & Electrical Engineering*, 2023,40(3):415-421. [《机电工程》杂志: <http://www.meem.com.cn>](http://www.meem.com.cn)

(上接第376页)

- [3] KREJCI P, KUHNEN K. Inverse control of systems with hysteresis and creep [J]. **IEEE. Proceedings Control Theory and Applications**,2001,148(3):185-192.
- [4] FUKUTA M, SOTANIT, MOTOZAWA M. Leakage and friction characteristics at sliding surface of tip seal in scroll compressors[J]. **International Journal of Refrigeration**, 2021,125(5):104-112.
- [5] CREUX L. Rotary Engineer: US,801,182[P]. 1905-06-26.
- [6] 窦汝桐. 无油涡旋压缩机关键技术研究[D]. 沈阳:沈阳工业大学机械工程学院,2017.
- [7] 颜禧龙,蔡炯炯,蒋加祯,等. 直驱控制涡旋压缩机位置识别方法研究[J]. 机电工程,2022,39(8):1145-1151.
- [8] 孙尚传,童恩东. 一种涡旋压缩机及其动静涡旋盘:中国, CN101691866B[P]. 2012-05-23.
- [9] 陈彦康. 无油涡旋压缩机几个关键技术难题分析[C]//上海市制冷学会2017年学术年会. 上海:上海制冷学会, 2017:166-169.
- [10] 李连生. 线段渐开线涡旋压缩机的几何理论[J]. 流体机械,1994,22(12):22-28.
- [11] 刘振全. 涡旋式流体机械与涡旋压缩机[M]. 北京:机械工业出版社,2009.
- [12] ZHENG S Y, WEI M S, ZHOU Y, et al. Tangential leakage flow control with seal-grooves on the static scroll of a CO<sub>2</sub> scroll compressor [J]. **Applied Thermal Engineering**,2022,208(5):118213.
- [13] 张国进. 涡旋式压缩机通用涡旋型线性控制系数研究[D]. 重庆:重庆理工大学机械工程学院,2015.
- [14] GE Ping, MUSA J. Tracking control of a piezoceramic actuator [J]. **IEEE. Transactions on Control Systems Technology**,1996,4(3):209-216.
- [15] 薛丽,王训杰. 涡旋压缩机传动系统的动静态特性研究[J]. 机电工程,2021,38(6):792-796.
- [16] 陈永平,朱建清. 基于外接圆半径差损失的实时安全帽检测算法[J]. 计算机科学,2022,49(S1):424-428.
- [17] 汤文亮,周琳颖. 基于三角形外接圆覆盖的改进APIT定位算法[J]. 传感技术学报,2015,28(1):121-125.

[编辑:李辉]