



## 一种多核神经网络集成的地震要素预测方法

张艳霞, 韩莹, 陈丹琪, 杨秋格

引用本文:

张艳霞, 韩莹, 陈丹琪, 杨秋格. 一种多核神经网络集成的地震要素预测方法[J]. 信阳师范学院学报自然科学版, 2021, 34(1): 124–129. doi: 10.3969/j.issn.1003–0972.2021.01.021

ZHANG Yanxia, HAN Ying, CHEN Danqi, YANG Qiuge. A Multi-core Radical Basis Neural Network Integrated Method for the Prediction of Earthquake Elements[J]. Journal of Xinyang Normal University (Natural Science Edition), 2021, 34(1): 124–129. doi: 10.3969/j.issn.1003–0972.2021.01.021

在线阅读 View online: <https://doi.org/10.3969/j.issn.1003–0972.2021.01.021>

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于随机森林算法的混凝土早期抗裂性预测研究

Prediction of Early Crack Resistance of Concrete Based on Random Forest Algorithm

信阳师范学院学报自然科学版, 2021, 34(1): 158–165. <https://doi.org/10.3969/j.issn.1003–0972.2021.01.026>

### 基于BP神经网络的交流输电线路可听噪声预测模型

Audible Noise Prediction Model of AC Power Lines Based on BP Neural Network

信阳师范学院学报自然科学版, 2015(1): 136–140. <https://doi.org/10.3969/j.issn.1003–0972.2015.01.033>

### 一种改进的RBF神经网络对县级政府编制预测

A Prediction for the Preparation of County Government Based on Improved RBF Neural Networks

信阳师范学院学报自然科学版, 2016, 29(2): 265–269. <https://doi.org/10.3969/j.issn.1003–0972.2016.02.027>

### 小数据量情境下的滑坡位移非线性变化预测模型

Prediction Model to the Slope Displacement Nonlinear Changing Under the Small-Data Situation

信阳师范学院学报自然科学版, 2017, 30(4): 521–525. <https://doi.org/10.3969/j.issn.1003–0972.2017.04.002>

### 启发式神经网络在异步电机矢量控制速度估计中的应用

Application of Heuristic Neural Network in Speed Estimation of Induction Motor

信阳师范学院学报自然科学版, 2017, 30(4): 618–622. <https://doi.org/10.3969/j.issn.1003–0972.2017.04.023>

# 一种多核神经网络集成的地震要素预测方法

张艳霞\*, 韩莹, 陈丹琪, 杨秋格

(防灾科技学院 信息工程学院, 河北 三河 065201)

**摘要:**为了提高地震要素的预测准确度,在同一个网络模型中构建多种不同类型的基核函数,对不同种径向基函数构建多核神经网络集成模型,以提高网络的精度.从确定最优径向基神经元数、适当加大训练的目标误差等多个方面加以优化,减小最小训练误差和提高预测精度.采用多元回归分析法,对样本进行拟合得到子预测的多元回归系数,对于预测模型进行多元回归集成,数据反归一化处理,最终得到了经过回归集成的多核RBF预测模型.结果表明,这种多核神经网络集成的地震要素预测方法所建立的多元回归预测集成模型,能够使实际值与预测值的拟合达到最佳,从而获得较高精度的地震要素预测值.

**关键词:**多核径向基;神经网络;地震要素;预测方法

中图分类号:TP183

文献标识码:A

开放科学(资源服务)标识码(OSID):



## A Multi-core Radical Basis Neural Network Integrated Method for the Prediction of Earthquake Elements

ZHANG Yanxia\*, HAN Ying, CHEN Danqi, YANG Qiuge

(School of Information Engineering, Institute of Disaster Prevention, Sanhe 065201, China)

**Abstract:** For the purpose of improving the accuracy of predicting earthquake elements, basic core functions of various types were built on the same network model and multi-core neural network integration models were built for different types of radial basis functions to improve the accuracy of the network. The optimization was conducted from determining the amount of optimal radical basis neurons, increasing the target error of training appropriately and other aspects to reduce the minimum training error and increase the accuracy of prediction. Multiple regression analysis method was adopted to fit the samples so as to obtain the multiple regression coefficients of sub-predictions; the same method was adopted to conduct multiple regression integration on the sub-prediction models and perform anti-normalization treatment on the data, and eventually obtained the regression-integrated multi-core RBF (radical basis function) prediction model. The results indicated that the model of multiple regression prediction integration established by this multi-core neural network integration method for prediction of earthquake elements is capable of achieving the optimal fitting of actual value and predictive value as well as earthquake element predictive values of higher accuracy.

**Key words:** multi-core radical basis function; neural network; earthquake elements; predictive method

## 0 引言

径向基神经网络以其良好的自适应学习能力和非线性处理能力,在天气预测、地震要素预测等领域得到广泛应用<sup>[1,2]</sup>.传统的径向基神经网络所采用的核函数基本上都是单核的,即所有核函数共同使用一个固定的尺度(单尺度RBF网络模型),这种网络模型结构相对简单,但其泛化能力却很

差<sup>[3]</sup>.通过实验数据证实,如果研究对象较为复杂,提取到的研究对象数据复杂度较高时,单核RBF网络模型不能较好地反映研究对象数据的分布规律<sup>[4,5]</sup>.而在传统的预测应用领域中,单核径向基神经网络核函数大部分都是采用高斯函数,这种以高斯基为核函数的径向基神经网络在高维空间的拟合过程中,所构建网络的计算精度较低.以薄板样条函数为径向基函数的响应值是无界的,称之为非

收稿日期:2020-07-23;修订日期:2020-09-05;\*.通信联系人,E-mail: cidpzyx@163.com

基金项目:国家自然科学基金项目(31872702);河北省科技计划项目(16210120);中央高校基本科研业务费专项(ZY20180120)

作者简介:张艳霞(1979—),女,河南安阳人,副教授,硕士,主要从事智能算法及应用研究.

局部性函数, 这种具有非局部性函数往往具有更高的拟合精度<sup>[6-8]</sup>. 基于此, 使用多核神经网络集成的方法, 并在此基础上建立了多元回归预测集成模型. 多核函数的使用, 使这种模型能够自适应地选取核函数的尺度与其他参数. 这种多核神经网络集成的方法建立的多元回归预测集成模型, 可以较好地提高预测精度.

## 1 径向基函数神经网络

径向基函数 (Radial Basis Function, RBF) 神经网络是一个 3 层前馈型神经网络, 网络由一个输入层、一个隐藏层和一个输出层组成. 该网络在单核基函数的作用下, 对靠近基函数中央范围的输入信号产生响应, 其结构如图 1 所示<sup>[8]</sup>.




图 1 径向基神经网络的网络结构图

Fig. 1 Network structure diagram of the radial basis neural network

## 2 单核 RBF 子预测模型

为构建多核 RBF 网络集成模型, 需构建单核 RBF 网络模型. 首先, 采用基于模糊等价关系的模糊聚类自动确定隐节点数. 具体方法为建立样本数据矩阵  $X$ ; 数据标准化处理转换到  $[0, 1]$  区间上; 采用夹角余弦法进行相似性度量; 构造模糊相似矩阵; 进行聚类分析, 确定聚类数<sup>[10]</sup>. 其次, 聚类数  $K$  事先无法确定, 为了定好  $K$  值, 采用模糊聚类的方法对输入样本进行聚类确定 RBF 隐节点的数据中心, 然后输出层权值便可以采用最小二乘方法 (LMS) 直接进行计算.

采用不同核函数各自核函数拟合特性以提高所构建的网络预测精度, 使用 6 种形式的核函数, 分别为幂指数核、高斯核、二次有理核、薄板样条核、多二次核、逆多二次核.

以高斯核为例, 构建单核 RBF 网络预测模型

的学习算法.

**步骤 1:** 对地震预测影响因子特征提取降维 (确定高斯核函数参数, 采用 KPCA 的方法).

**步骤 2:** 确定初始隐节点数 (确定  $\lambda$  的水平截值, 采用模糊聚类分析法).

**步骤 3:** 确定 RBF 各隐节点的数据中心 (采用 K-均值聚类方法).

**步骤 4:** 确定各隐节点的扩展常数 (采用最小距离原则).

**步骤 5:** 确定回归系数向量  $B$  的估计 (采用最小二乘法).

## 3 多核 RBF 网络集成模型

在通常的 RBF 网络模型中, 采用的是单一的核函数, 而单一的核函数在各种复杂的应用环境中对不同因子敏感性不能够进行如实客观的响应. 为了解决这个问题, 充分利用不同核函数自身特性, 构建基于幂指数核、高斯核、二次有理核、薄板样条核、多二次核和逆多二次核等不同核函数形式的神经网络模型, 最后采用多元回归方式集成这 6 种单核基函数的神经网络模型. 多核 RBF 网络集成模型如图 2 所示.




图 2 多核 RBF 网络集成模型

Fig. 2 Multi-core RBF network integration model

## 4 多元回归分析法建立回归模型

在地震预测这一问题中, 影响地震预测的变量因素非常多, 如地震累计的频度、累计释放的能量、异常地震群数、地震条带数、相关区的震级等, 所以对地震的预测可以通过多元回归分析来实现.

### 4.1 多元回归线性模型

设定因变量  $Y$  为地震预测变量, 影响  $Y$  的自变量个数为  $m$  个, 即:  $X_1, X_2, \dots, X_m$ , 则

$$Y = a + b_1 X_1 + b_2 X_2 + \dots + b_m X_m + \epsilon_i, \quad (1)$$

表示为  $Y$  与  $X_1, X_2, \dots, X_m$  之间存在线性相关关系, 即为  $m$  元线性回归的线性模型. 式(1)中:  $\epsilon_i$  ( $i = 1, 2, \dots, n$ ) 为误差项, 是服从正态分布的随机变量, 即:  $\epsilon_i \in N(0, \sigma^2)$  ( $i = 1, 2, \dots, n$ );  $a$  为截距常数项;  $b_1, b_2, \dots, b_m$  是回归系数,  $b_i$  ( $i = 1, 2, \dots, m$ ) 为“未知参数”.

根据  $n$  组观测数据:

$$\begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1m} & y_1 \\ x_{21} & x_{22} & \cdots & x_{2m} & y_2 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} & y_n \end{pmatrix}, \quad (2)$$

寻找  $Y$  与  $X_1, X_2, \dots, X_m$  之间的线性关系, 最终得到回归系数估计值  $\bar{a}, \bar{b}_1, \bar{b}_2, \dots, \bar{b}_m$ .

根据式(1), 利用地震预测变量的历史数据  $y_1, y_2, \dots, y_n$ ; 自变量  $x_1$  的历史数据  $x_{11}, x_{21}, x_{n1}, \dots$ ; 自变量  $x_m$  的历史数据  $x_{1m}, x_{2m}, \dots, x_{nm}$ , 可得到  $m$  元线性回归模型:

$$\begin{cases} y_1 = a_0 + b_1 x_{11} + b_2 x_{12} + \cdots + b_m x_{1m} + \epsilon_1, \\ y_2 = a_0 + b_1 x_{21} + b_2 x_{22} + \cdots + b_m x_{2m} + \epsilon_2, \\ \cdots \\ y_n = a_0 + b_1 x_{n1} + b_2 x_{n2} + \cdots + b_m x_{nm} + \epsilon_n. \end{cases} \quad (3)$$

此线性方程组可以表示为矩阵形式, 令

$$\mathbf{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1m} \\ 1 & x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix},$$

$$\mathbf{B} = \begin{bmatrix} a \\ b_1 \\ \vdots \\ b_m \end{bmatrix}, \mathbf{U} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}.$$

则可建立线性方程组(3)的矩阵形式为:

$$\mathbf{Y} = \mathbf{XB} + \mathbf{U}, \quad (4)$$

其中:  $\mathbf{Y}$  表示因变量  $y$  的观测值向量;  $\mathbf{B}$  表示回归系数向量;  $\mathbf{X}$  表示自变量观测值的矩阵;  $\mathbf{U}$  表示随机误差向量.

#### 4.2 多元线性回归系数的最小二乘估计

采用最小二乘法进行回归系数向量  $\mathbf{B}$  的估计.

假设  $\beta_1, \beta_2, \dots, \beta_m$  的最小二乘估计值表示为:

$b_1, b_2, \dots, b_m$ , 则  $m$  元线性回归的样本  $y$  的观测值可表示为:

$$y_j = b_1 x_{1j} + b_2 x_{2j} + \cdots + b_m x_{mj} + \epsilon_j, j = 1, 2, \dots, n. \quad (5)$$

式中,  $\epsilon_j$  为误差的估值, 令  $\bar{y}_j$  为  $y_j$  的估值, 那么有:

$$\bar{y}_j = b_1 x_{1j} + b_2 x_{2j} + \cdots + b_m x_{mj}, j = 1, 2, \dots, n, \quad (6)$$

$$\epsilon_j = y_j - \bar{y}_j, j = 1, 2, \dots, n. \quad (7)$$

式中:  $y_j$  代表实际值,  $\bar{y}_j$  代表估计值, 二者之间的偏离水平表示为式(6). 为了提高准确度, 使  $\bar{y}_j$  与  $y_j$  拟合达到最佳, 则残差平方和应达到最小, 即:

$$Q(b_1, \dots, b_m) = \sum_{j=1}^n \epsilon_j^2 = \sum_{j=1}^n (y_j - \bar{y}_j)^2 = \sum_{j=1}^n (y_j - (b_1 x_{1j} + b_2 x_{2j} + \cdots + b_m x_{mj}))^2 \quad (8)$$

达到最小.  $b_1, b_2, \dots, b_m$  可通过微分确定, 即:

$$\begin{cases} \frac{\partial Q}{\partial b_1} = -2 \sum_{j=1}^n (y_j - \bar{y}_j) = 0, \\ \frac{\partial Q}{\partial b_a} = -2 \sum_{j=1}^n (y_j - \bar{y}_j) x_{ja} = 0, \\ \alpha = 1, 2, \dots, m. \end{cases} \quad (9)$$

$$\begin{cases} \sum_{j=1}^n (y_j - b_1 x_{j1} - b_2 x_{j2} - \cdots - b_m x_{jm}) = 0, \\ \sum_{j=1}^n (y_j - b_1 x_{j1} - b_2 x_{j2} - \cdots - b_m x_{jm}) x_{ka} = 0, \\ \alpha = 1, 2, \dots, m. \end{cases} \quad (10)$$

对其进行整理化简后, 可得正规方程组:

$$\begin{cases} nb_1 + (\sum_{j=1}^n x_{j1}) b_2 + (\sum_{j=1}^n x_{j2}) b_3 + \cdots + (\sum_{j=1}^n x_{jm}) b_m = \sum_{j=1}^n y_j, \\ (\sum_{j=1}^n x_{j1}) b_1 + (\sum_{j=1}^n x_{j1}^2) b_2 + (\sum_{j=1}^n x_{j1} x_{j2}) b_3 + \cdots + (\sum_{j=1}^n x_{j1} x_{jm}) b_m = \sum_{j=1}^n x_{j1} y_j, \\ \cdots \\ (\sum_{j=1}^n x_{jm}) b_1 + (\sum_{j=1}^n x_{jm} x_{j1}) b_2 + (\sum_{j=1}^n x_{jm} x_{j2}) b_3 + \cdots + (\sum_{j=1}^n x_{jm}^2) b_m = \sum_{j=1}^n x_{jm} y_j. \end{cases} \quad (11)$$

令  $\mathbf{A}$  表示式(11)的系数矩阵, 则:

$$A = X'X$$

$$\begin{pmatrix} n & \sum_{j=1}^n x_{j1} & \sum_{j=1}^n x_{j2} & \cdots & \sum_{j=1}^n x_{jm} \\ \sum_{j=1}^n x_{j1} & \sum_{j=1}^n x_{j1}^2 & \sum_{j=1}^n x_{j1}x_{j2} & \cdots & \sum_{j=1}^n x_{j1}x_{jm} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \sum_{j=1}^n x_{jm} & \sum_{j=1}^n x_{jm}x_{j1} & \sum_{j=1}^n x_{jm}x_{j2} & \cdots & \sum_{j=1}^n x_{jm}^2 \end{pmatrix} = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ x_{11} & x_{21} & \cdots & x_{n1} \\ x_{12} & x_{22} & \cdots & x_{n2} \\ \cdots & \cdots & \cdots & \cdots \\ x_{1m} & x_{2m} & \cdots & x_{nm} \end{pmatrix} \cdot \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1m} \\ 1 & x_{21} & x_{22} & \cdots & x_{2m} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nm} \end{pmatrix} \quad (12)$$

令  $B$  表示式(11)右端常数项矩阵,则:

$$B = \begin{pmatrix} \sum_{j=1}^n y_j \\ \sum_{j=1}^n x_{j1}y_j \\ \vdots \\ \sum_{j=1}^n x_{jm}y_j \end{pmatrix} = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ x_{11} & x_{21} & \cdots & x_{n1} \\ x_{12} & x_{22} & \cdots & x_{n2} \\ \cdots & \cdots & \cdots & \cdots \\ x_{1m} & x_{2m} & \cdots & x_{nm} \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{pmatrix} = X'y, \quad (13)$$

那么正规方程式(11)的矩阵形式为:

$$Ab = B, \quad (14)$$

$b = (b_1, b_2, \dots, b_m)'$  为式(11)中待定的未知实数向量。

若  $A$  满秩,则  $A^{-1}$  存在,可得:

$$b = A^{-1}B = (X'X)^{-1}X'y, \quad (15)$$

即为多元回归模型中参数的最小二乘估计。

### 5 实验及实验结果分析

从历史地震资料中提取候选因子、建立 6 个子预测模型、多元回归集成,其具体过程如图 3 所示。

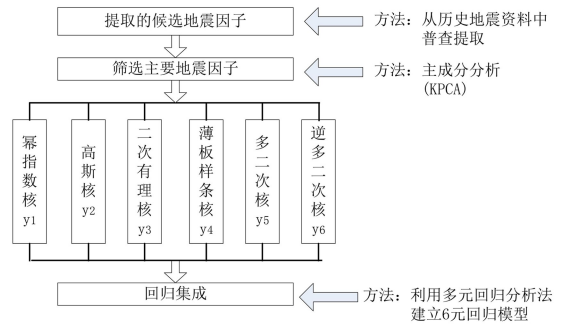


图 3 多核神经网络多元回归集成模型

Fig. 3 Multi-core neural network multiple regression ensemble model

本文的样本数据来自互联网共享的《中国震例》<sup>[11]</sup>,对数据进行归一化后,如表 1 所示。

从这些归一化处理后的数据中,提取出“地震累计的频度”“累计释放的能量”“ $b$  值”“异常地震条带数”“活动的周期”“相关区的震级”等 7 个预测因子设定为输入向量,实际震级  $M$  设定为目标向量,选择后 4 个样本做预测试验。

表 1 数据归一化后的震例参数表

Tab. 1 Parameter table of earthquake cases after data normalization

地震累计的频度	累计释放的能量	$b$ 值	异常地震群数	地震条带数	活动的周期	相关区的震级	实际的震级
0	0	0.65	0	0	0	0	0
0.3922	0.4852	0.75	0.5	0.5	1	0.4130	0.5468
0.2743	0.4523	0.67	0	0.5	1	0.4130	0.5880
0.6302	1.0010	0.65	1	0.5	1	1.0010	0.9423
0.4171	0.4211	0.66	0.5	0	1	0.8123	0.4455
0.2221	0.5012	0.72	0	0	1	0.2502	0.4896
0.9669	0.0236	0.74	0.5	1	1	0.8981	1.0000
0.5822	0.4901	0.72	0	0	0	0.3755	0.3832
0.0733	0.0701	0.75	0	0	0	0.0611	0.3255
0.4001	0.1299	0.96	0.5	0	0	0.7933	0.5660

在 MATLAB R2006a 软件环境下,采用 Intel®Core™ i5-6500CPU@3.2 的主处理器并拥有 4GB 内存的 PC 机,采用 Matlab 专有工具包 newrb 函数对径向基函数网络进行训练.由于影响网络仿真的主要因素有径向基函数的分布密度 spread 值、隐层神经元个数以及训练样本的选择,又由于 spread 的取值对网络性能有较大的影响,所以要注意该分布密度的取值,在该实验中,测试当 spread 选取为 1.5~5.5 时相应的预测标准差及训练时间,训练结果如图 4 所示.




图 4 不同 spread 取值的训练结果

Fig. 4 Training results of different spread values

从图 4 可以看到,当 spread 取 2.5 时网络误差最小,所以将 spread 的值取 2.5 进行下一步的仿真实验.

从 0 个神经元开始循环训练,直到达到误差要求或最大径向基神经元数为止,以获得最小训练误差和最大预测精度,最终确定最优径向基神经元数.

为提高预测模型精度,需科学确定训练目标误差.本文取步长为 0.01,设定目标误差 0.01~0.15 训练.当 goal 取为 0.09、隐层结点数为 7 时,取得标准差为 0.0022 和训练时间 0.62 s 的最优参数.

对 6 个自变量取样本拟合,得到多元回归系数,如表 2 所示.

在确定了回归系数后,对子预测模型进行多元回归集成:

$$Y_2 = \varphi(y_{RBF1}, y_{RBF2}, y_{RBF3}, y_{RBF4}, y_{RBF5}, y_{RBF6}). \quad (15)$$

数据反归一化处理,最终得到了经过回归集成的多核 RBF 与 RBF1、RBF2、RBF3、RBF4、RBF5、RBF6,结果对比如表 3 所示.从表 3 中看出,集成的多核 RBF 网络模型的预测精度远高于任何单核 RBF 网络模型的预测精度.

表 2 6 个子预测多元回归系数

Tab. 2 Six sub-predictive multiple regression coefficients

常项	A(RBF1)	B(RBF2)	C(RBF3)	D(RBF4)	D(RBF5)	E(RBF6)
3.356 804	5.952 385	1.398 560	-4.296 384	0.796 256	3.768 149	-7.394 287

表 3 预测结果对比表

Tab. 3 The comparison table of forecast results

多核 RBF 得到的震级	多核 RBF 相对误差/%	RBF1 得到的震级	RBF2 得到的震级	RBF3 得到的震级	RBF4 得到的震级	RBF5 得到的震级	RBF6 得到的震级	实际值
0.4067	0.3455	0.3865	0.2865	0.3283	0.6972	0.4526	0.3555	0.4063
0.3639	15.7800	0.3572	0.3201	0.3605	0.5604	0.4832	0.3572	0.4374
0.5344	7.8976	0.5443	0.3527	0.3685	0.6856	0.5412	0.5443	0.5983
0.6555	4.7886	0.6625	0.4586	0.5726	0.6994	0.5721	0.6852	0.6251

## 6 结论

以 6 种径向基核函数自身的优点构建了多核神经网络集成模型,采用多元回归分析方法获得集成神经网络模型的参数.在集成神经网络模型参数的确定过程中,径向基函数的分布密度 spread 值

对网络性能影响较大,通过实验对比可知,在本研究中 spread 值取 2.5 时能最大限度地减少对网络性能的影响.同时,影响集成神经网络模型预测精度还有各单核隐层神经元个数的多少、整个网络训练样本的选择等因素,这也是下一步即将开展的工作.

参考文献:

- [1] CHERNOVA O O. Hypothesis testing in the cox proportional hazards model with measurement errors[J]. Theor Probability and Math Statist,2020, 100(8): 215-225.
- [2] ANOUSSIS M, OZAWA N, TODOROV I G. Norms of vector functionals[J]. Proceedings of the American Mathematical Society, 2019, 147(5): 2057-2068.
- [3] 赵勇, 苏丹, 邹丽, 等. 基于 LSTM 神经网络的畸形波预测[J]. 华中科技大学学报(自然科学版), 2020, 48(7): 47-52.  
ZHAO Yong, SU Dan, ZOU Li, et al. Rogue wave prediction based on LSTM neural network[J]. Huazhong University of Science & Technology(Natural Science Edition). 2020, 48(7): 47-52.
- [4] 朱文峰. 基于支持向量机与神经网络的文本分类算法研究[D]. 南京: 南京邮电大学, 2019.  
ZHU Wenfeng. Research on text classification algorithm based on support vector machine and neural network[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019.
- [5] 李正明, 梁彩霞, 王满商. 基于 PSO-DBN 神经网络的光伏短期发电出力预测[J]. 电力系统保护与控制, 2020, 48(8): 149-154.  
LI Zhengming, LIANG Caixia, WANG Manshang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48(8): 149-154.
- [6] HOJOO L. Uniqueness of minimal surfaces, jacobi fields, and flat structures[J]. Proceedings of the American Mathematical Society, 2020, 148(7): 3059-3071.
- [7] DOSI A. Noncommutative holomorphic functional calculus, affine and projective spaces from nc-complete algebras[J]. St Petersburg Math J, 2020, 31(4): 607-656.
- [8] KIM D K, BYUNGHWEE L, DANIEL K. Multi-label classification of historical documents by using hierarchical attention networks [J]. Journal of the Korean Physical Society, 2020, 76(5): 368-377.
- [9] 徐向艺, 柴俊霞, 姚兰. 一种基于进化计算的高斯径向基网络模型构建方法[J]. 信阳师范学院学报(自然科学版), 2014, 27(3): 425-428.  
XU Xiangyi, CHAI Junxia, YAO Lan. A model of gaussian radial basis function networks based on evolutionary computation[J]. Journal of Xinyang Normal University(Natural Science Edition), 2014, 27(3): 425-428.
- [10] SANDELI P K, TIMOTHY K S, NOORKHOLIS L H. Modelling a spatial-motion deep learning framework to classify dynamic patterns of videos[J]. Appl Sci, 2020(2): 2-24.
- [11] 吕坚, 宋美琴, 周龙泉, 等. 基于《中国震例》的地震空区和地震条带统计特征[J]. 地震, 2016, 36(4): 22-34.  
LYU Jian, SONG Meiqin, ZHOU Longquan, et al. Statistical characteristics of seismic gaps and seismic belts based on earthquake cases in China[J]. Earthquake, 2016, 36(4): 22-34.

责任编辑:任长江