基于 ARIMA 与神经网络的备件需求组合预测方法

王　宁[1],李建华[1],王军军[2],李双雪[1],唐　宁[1]

(1.兰州理工大学机电工程学院,甘肃 兰州 730050;2.兰州兰石集团有限公司铸锻分公司,甘肃 兰州 730050)

摘　要:针对备件需求量波动大预测精度不高的问题,提出一种基于差分自回归移动平均(ARIMA)、BP 神经网络、串联的卷积与长短期记忆神经网络(CNN-LSTM)组合模型的备件需求预测方法。该方法能够充分发挥 ARIMA 模型出色的线性拟合能力和神经网络突出的非线性拟合能力,克服了单一方法的局限性,并通过实例分析,验证了该组合预测模型的预测精确度高于单一预测模型。

关键词:ARIMA;BP 神经网络;CNN-LSTM 神经网络;组合预测;备件需求

中图分类号:TP183　F252

备件在保障设备正常使用和维修任务中占据重要地位,备件的消耗受到使用环境、设备维护、备件使用寿命等多种因素影响,预测难度较大。基于时间序列进行的预测容易理解与应用,预测精度较高[1]。精确的备件需求预测能够优化库存结构,降低库存管理难度,减少资金占用,因此科学的预测技术是非常重要的。

现有的时间序列预测技术包括统计方法和机器学习两大类[2],统计方法以差分自回归移动平均(ARIMA)模型[3-5]为代表,而机器学习方法以神经网络、支持向量机等为代表。韩梅丽[6]等以需求量波动较大的备件为研究对象, 采用 ARIMA 时序模型对备件时序消耗做出了预测。丁红卫[7]等通过所需设备的历史数据对构建 BP 神经网络模型进行训练,将训练好的模型用于电网物资的需求预测。有学者将 LSTM 与卷积神经网络融合,并运用于预测、语音识别等领域[8,9],李梅[10]等提出基于注意力机制的 CNN-LSTM 模型, 运用于热电联产供热的预测,对比支持向量机、LSTM 单一预测模型,该组合模型取得了更好效果。

但是 ARIMA 仅适用于线性时间序列的预测,而神经网络适用于非线性系统的预测,基于 ARIMA 和神经网络在时间序列预测方面各自的优劣势,本研究提出一种基于 ARIMA、BP 神经网络和卷积长短期记忆神经网络的组合模型 (ARIMA-BP-CNN),充分提取时间序列数据的线性和非线性特征,应用该模型对备件需求量做预测,并通过电解铝企业天车某备件的消耗情况进行验证。

1　基本理论

1.1　ARIMA 时间序列模型

差分自回归移动平均模型,记作 ARIMA,是一种时间序列预测分析方法。ARIMA(p,d,q)中,AR 为自回归,MA 为移动平均,p 是自回归项数,q 是移动平均项数,d 是保障差分后得到平稳序列数据的差分次数。时间序列模型是基于历史数据建立起来的模型,以 p、d、q 为参数的 ARIMA 模型可表示为:

$$X_t=\varphi_1X_{t-1}+\varphi_2X_{t-2}+\cdots+\varphi_pX_{t-p}+\varepsilon_t+\theta_0+\theta_1\varepsilon_{t-1}+\cdots+\theta_q\varepsilon_{t-q} \quad (1)$$

其中:X_t 为时间序列的样本值,$\varphi_i(i=1,2,\cdots,p)$和 $\theta_i(i=1,2,\cdots,q)$为模型参数,ε_t 为独立正态分布的白噪声。

ARIMA 模型首先要对时间序列做一次或者多次差分, 转换成平稳时间序列, 再进行建模分析。ARIMA 模型对时间序列数据的线性相关性预测精度高,但对分线性关系处理效果欠缺。

1.2　BP 神经网络

BP 神经网络是 20 世纪 80 年代提出的误差反向传播算法,BP 神经网络网络由输入层、隐藏层和输出层组成,隐藏层可以是一层或多层,本文训练的是隐藏层为一层 BP 神经网络, 如图 1 所示。BP 算法分为前向传播和反向传播两个部分,前向传播是输入信息从输入层传入,经中间的隐藏层最终传至输出层,若获得预期的输出结果,则学习过程终止;否则,它将转向反向传播。反向传播是与原始连接路径反方向, 通过误差逐层修改网络权值及阈

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

值,再将更新的权值和阈值正向传播,通过正向、反向传播的循环进行得到最优权值和阈值。

隐藏层与输入层关系:

$$net_j = \sum_{i=1}^{n} w_{ij} x_i + \theta_j, i = 1, 2, \cdots, n \tag{2}$$

$$y_j = f(net_j) = \frac{1}{1 + e^{-net_j}}, j = 1, 2, \cdots, m \tag{3}$$

其中,θ_j 为隐藏层第 j 个神经元的阈值,w_{ij} 为输入层和隐藏层的连接权值,net_j 是第 j 个神经元的激活值,y_j 是隐藏层的输出值,f 为激活函数,通常是 Sigmoid 函数。输出层和隐藏层与上述关系类似,激活函数通常为线性函数。

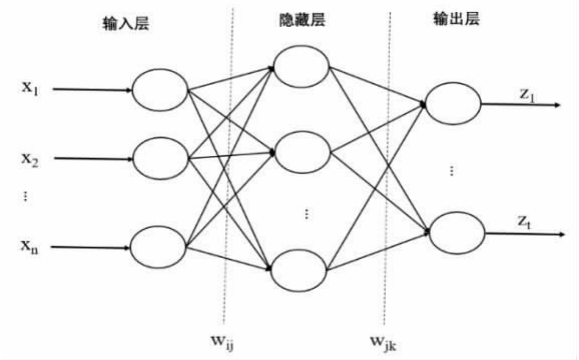

图 1 三层 BP 神经网络结构

1.3 卷积长短期记忆神经网络

1.3.1 卷积神经网络

卷积神经网络 (Convolutional Neural Networks, CNN)是一种具有深度结构的前馈神经网络,由输入层、卷积层、池化层、全连接层以及输出层组成。卷积神经网络可以有多个卷积层与池化层,二者交替使用从原始数据中获得有效表征,提取数据的特征,然后经过全连接层解除多维结构,最后到达输出层,完成分类、预测等任务。

1.3.2 长短期记忆网络

LSTM 是一类特殊的递归神经网络,它克服了传统递归神经网络存在的梯度爆炸和梯度消失的问题,适合处理和预测时间序列事件。如图 2 所示,每个 LSTM 由输入门、忘记门、输出门和细胞状态组成,更新方式如下:

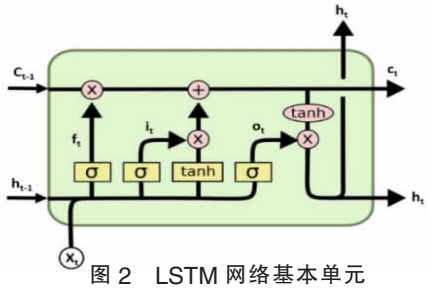

图 2 LSTM 网络基本单元

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{4}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{5}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{6}$$

$$C_t = C_{t-1} \cdot f_t + i_t \cdot \tilde{C}_t \tag{7}$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{8}$$

$$h_t = o_t \cdot \tanh(C_t) \tag{9}$$

其中,f_t、i_t、C_t、o_t 分别表示忘记门、输入门、细胞状态和输出门;b_f、b_i、b_c、b_o 分别表示不同门对应的偏置;W_f、W_i、W_c、W_o 分别表示不同门对应权值;xt 表示当前节点的输入;ht 表示当前节点的输出;σ 表示激励函数 Sigmoid;$\hat{G}t$ 表示计算过程中的候选值向量。

1.3.3 CNN-LSTM 神经网络

CNN-LSTM 神经网络算法由三部分组成。第一层,将原始数据热向量编码,使其映射为 k 维空间,得到新特征。第二层,将新特征输入卷积神经网络,设置若干对卷积层和池化层,提取数据特征。第三层,将 CNN 的输出数据作为 LSTM 神经网络的输入,做时序的预测,如图 3 所示。

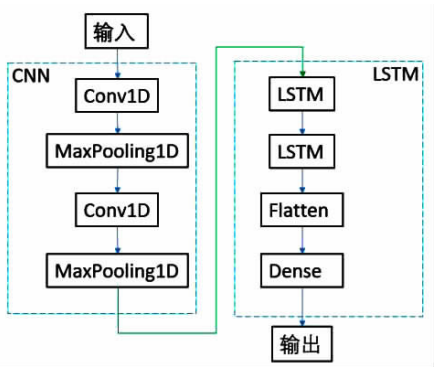

图 3 CNN-LSTM 模型

2 组合预测模型

2.1 ARIMA-BP-CNN 组合预测方法数学模型

传统的预测方法以及机器学习算法均有其局限性,单一的方法不能得到理想的预测结果,文章采用组合预测方法对备件需求进行预测。Armstrong 分析表明,组合预测方法对短期问题的预测更有效,预测结果的精确度更高[11]。组合预测理论中,若存在 n 种解决实际问题的预测方法,那么可以能通过给这 n 种方法分别赋予适当的权重,再将 n 种方法的预测结果分别乘以对应的权重,各项累加,进而得到组合模型的预测结果。

假设某项预测问题在观测时段的实际值为 $y_t(t=$

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

1,2,⋯,m),对于该问题的 n 种预测模型中,各自的预测值为 g_{it}(i=1,2,⋯,n;　t=1,2,⋯,m),各预测模型的权重系数为 w_i(i=1,2,⋯,n)。于是组合模型的预测值 t 表示为:

$$\hat{y}_t = \sum_{i=1}^{n} w_i g_{it}, t = 1, 2, \cdots, m$$

$$\sum_{i=1}^{n} w_i = 1 \tag{10}$$

进而得到组合预测的误差:

$$e_t = y_t - \hat{y}_t = \sum_{i=1}^{n} w_i y_t - \sum_{i=1}^{n} w_i g_{it} = \sum_{i=1}^{n} w_i e_{it} \tag{11}$$

文章结合前面介绍的 ARIMA、BP 神经网络和卷积长短期记忆神经网络,将三种方法结合,组成新组合预测方法(ARIMA-BP-CNN)。于是公式(9)的形式为:

$$\hat{y}_{combined(t)} = w_1 \hat{y}_{ARIMA(t)} + w_2 \hat{y}_{BP(t)} + w_3 \hat{y}_{CNN(t)}, t = 1, 2, \cdots, m \tag{12}$$

其中,$\hat{y}_{ARIMA(t)}$,$\hat{y}_{BP(t)}$和$\hat{y}_{CNN(t)}$分别是 ARIMA、BP 神经网络和 CNN-LSTM 在 t 时刻的预测结果,$\hat{y}_{combined(t)}$是 ARIMA-BP-CNN 在 t 时刻的预测结果,w_i(i=1,2,3)是分配给 ARIMA、BP 神经网络和 CNN-LSTM 的权重系数。

2.2　ARIMA-BP-CNN 方法预测步骤

应用该组合预测方法进行预测,得到较高精度的预测结果,关键是确立各单一模型的权重系数,本文采用遗传算法优化 ARIMA-BP-CNN 模型的权重系数。图 4 是本文提出的 ARIMA-BP-CNN 组合模型流程图,该组合预测方法步骤如下:

步骤 1:分别使用 ARIMA、BP 神经网络和 CNN-LSTM 对原始时间序列数据进行预测,得到单一模型的预测结果。

步骤 2:为各单一模型分配初始权重,分别用步骤 1 各方法的预测结果乘以对应的权重,各项累加,得到 ARIMA-BP-CNN 模型的预测结果。

步骤 3:采用遗传算法优化权重系数。初始权重未必能得到预期的结果,使用遗传算法对组合模型的权重加以优化。

步骤 4:精度的预测。若组合模型得到期望的预测精度,进行步骤 5;否则,返回步骤 2 继续采用遗传算法优化权重系数,直至得到期望的预测精度。

步骤 5:输出组合模型的预测结果,如图 4 所示。

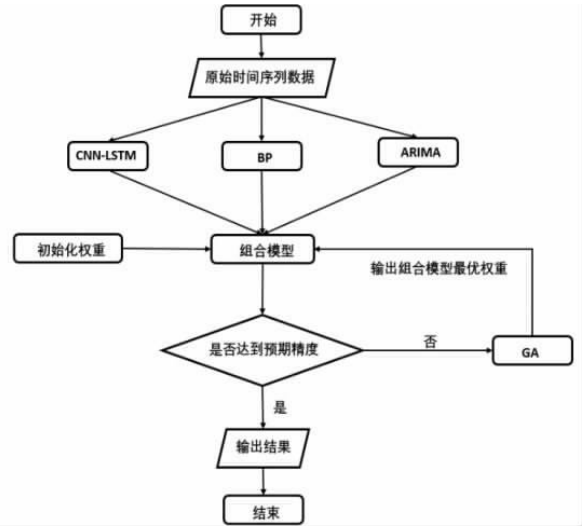

图 4　基于 ARIMA、BP 和 CNN 的组合预测流程图

3　实例分析

现有 2010 年至 2018 年间某电解铝企业天车某备件消耗数据,以季度为时间单位统计了 36 个历史消耗数据,详细见表 1.在这 36 个历史数据中,选择前 32 个作为训练数据,后面 4 个作为检验数据。

表 1　某备件消耗数据

年度	第一季度	第二季度	第三季度	第四季度
2010	26	22	23	21
2011	23	25	28	24
2012	29	28	26	27
2013	31	34	29	28
2014	31	34	29	28
2015	37	34	32	33
2016	34	29	30	36
2017	37	33	32	30
2018	33	29	31	33

3.1　ARIMA 时间序列预测

将 2010 年至 2017 年的 32 个消耗数据作为输入数据,得到 2018 年四个季度该备件消耗的预测结果。

(1)检验序列的平稳性。

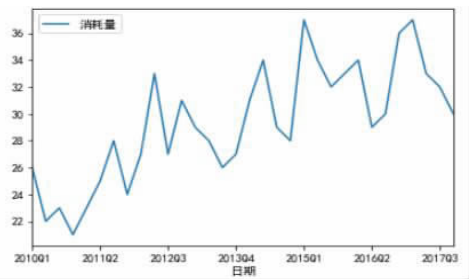

图 5　备件消耗不平稳序列图

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

图 5 时序图显示该序列具有曲折上升的趋势，可以判断为非平稳序列；单位根检验统计量对应的 p 值为 0.11487 显著大于 0.05，最终判断该序列为非平稳序列。

(2)对原始序列一阶差分，并进行平稳性和白噪声检验。

图 6 显示，一阶差分后的序列时序图在均值附近比较平稳的波动；图 7 显示，自相关图有很强的短期相关性；单位根检验 p 值为 0.04 小于 0.05；白噪声检验 p 值为 0.02 小于 0.05，所以一阶差分后的序列为平稳非白噪声序列。

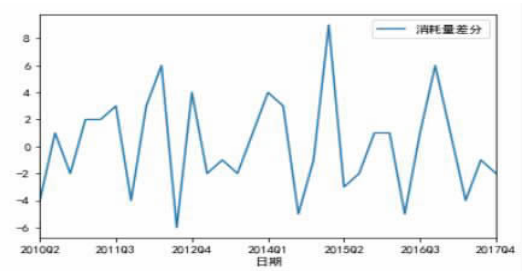

图 6 备件消耗平稳序列图

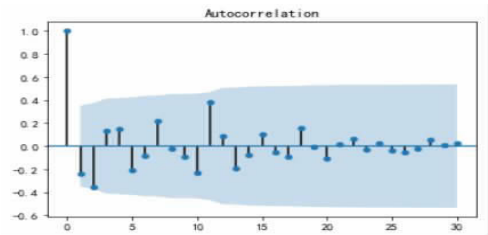

图 7 备件消耗 ACF 图

(3)对差分后的序列拟合 ARIMA 模型。

计算 ARMA(p,q)。计算 p 和 q 均小于等于 3 的所有组合的 BIC 信息量，取其中 BIC 信息量最小的模型阶数。计算结果显示 p 值为 0、q 值为 1 时最小 BIC 值为 166.2731，因此 p、q 定阶 0、1。

(4)ARIMA 模型预测。

应用 ARIMA(0,1,1)对该备件 2018 年四个季度(Q1-Q4)需求量做预测，预测结果见表 2。

表 2 备件实际消耗量与各模型的预测值

消耗量	2018Q1	2018Q2	2018Q3	2018Q4
实际值	33	29	31	33
ARIMA	35.2765	35.6267	35.9770	36.3272
BP	35.2392	34.5380	27.9609	37.5096
CNN	30.2459	30.3496	30.1152	30.2302
ARIMA-BP-CNN	31.7339	31.7394	30.5496	32.2338
ARIMA-BP	35.2525	34.9256	30.8149	37.0887
ARIMA-CNN	31.4331	31.5950	31.4986	31.6691
BP-CNN	31.5442	31.4396	29.5551	32.1229

3.2 BP 神经网络预测

将该备件的历史消耗数据，依次从第 1 个数据开始，紧邻的 8 个作为神经网络的输入，第 9 个数据作为待预测的消耗值，即神经网络的输出，将这 9 个相邻的历史数据作为 1 个样本。将前 32 个数据作为训练数据集，按此方法得到 24 个样本，用来训练 BP 神经网络。输入层有 8 个单元，输出层有 1 个单元，取隐藏层 8 个单元，relu 作为激活函数，训练该 BP 神经网络，学习 5000 次后，用这个训练好的 BP 神经网络模型对 2018 年四个季度该备件的消耗量做预测，预测结果见表 2。

3.3 CNN-LSTM 神经网络预测

将该备件的历史消耗数据，依次从第 1 个数据开始，紧邻的 4 个作为神经网络的输入，第 5 个数据作为待预测的消耗值，即神经网络的输出，将这 5 个相邻的历史数据作为 1 个样本。将前 32 个数据作为训练数据集，按此方法得到 28 个样本，以此训练深度学习神经网络。输入层为 4 个单元，依次通过卷积、池化、LSTM 层、Flatten 等过程，输出层为 1 个单元，relu 作为激活函数，mae 作为损失函数，对神经网络进行训练，学习 1000 次后，用这个训练好的 CNN-LSTM 模型对该备件 2018 年四个季度的消耗量做预测，预测结果见表 2。

3.4 组合预测

(1)确定权系数

以误差平方和最小作为模型组合的最优准则，建立如下广义误差最小的组合预测权重确定模型：

$$\min\sum_{t=1}^{n}e_t^2=\sum_{t=1}^{n}[y_t-\hat{y}_t]^2=\sum_{t=1}^{n}[y_t-\sum_{i=1}^{m}w_ig_{it}]^2$$
$$s.t.\begin{cases}\sum_{i=1}^{m}w_i=1\\ w_i>0\end{cases} \tag{13}$$

运用遗传算法确定该非线性问题的权重，将目标函数作为遗传算法的适应度计算值，使用 MATLAB 中的 GA 工具箱调用该函数进行计算，通过反复实验，得到三种方法对应的权值：

$w_1=0.134, w_2=0.163, w_3=0.703$

(2)组合模型做预测

通过公式(14)计算得到组合模型预测值，结果见表 2。

$$\hat{y}_{combined(t)}=w_1\hat{y}_{ARIMA(t)}+w_2\hat{y}_{BP(t)}+w_3\hat{y}_{CNN(t)},t=1,2,\cdots,m \tag{14}$$

另外，为进一步比较三种方法组合模型的预测

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

精确度，同样计算了单一方法的两两组合预测结果，以误差平方和最小作为模型组合的最优准则，使用相同方法计算得到 ARIMA-BP 的组合权重为：w_1=0.356，w_2=0.644；ARIMA-CNN 的组合权重为：w_1=0.236，w_2=0.764；BP-CNN 的组合权重为：w_1=0.26，w_2=0.74。两两组合方法的预测结果见表 2。

3.5　结果分析

文章提出的 ARIMA-BP-CNN 方法是综合三种不同方法的新方法，结合三种方法的过程中，对每一种方法进行加权，其中 CNN 的权重系数最高，对组合方法的贡献最大。

为了直观显示单一方法和组合方法的预测精度，将备件消耗的实际值减去各方法的预测值，得到图 8 的误差曲线图。从图中可以看出 ARIMA-BP-CNN 方法的整体误差最接近于零，其他三种方法只有第二季度 CNN 有较小的误差，其他季度里三种单一的方法都具有较大的误差。

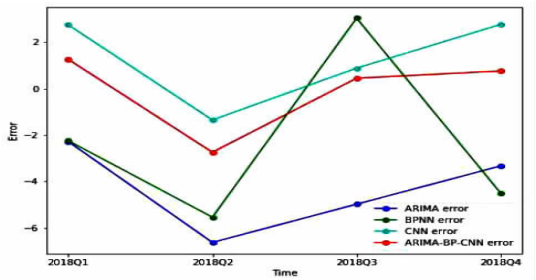

图 8　四种预测方法的误差曲线

为进一步说明预测结果的有效性以及改进后组合模型的提升效果，从均方根误差(RMSE)，平均绝对误差(MAE)，平均绝对百分比误差(MAPE)这 3 个方面进行对比分析，具体见表 3。

表 3　预测效果评价表

评价指标	RMSE	MAE	MAPE
ARIMA	4.608	4.302	13.972
BP	4.039	3.831	12.338
CNN	2.113	1.94	6.062
ARIMA-BP-CNN	1.573	1.306	4.265
ARIMA-BP	3.773	3.113	10.062
ARIMA-CNN	1.674	1.498	4.834
BP-CNN	1.653	1.554	5.035

从表 3 可以看出，ARIMA-BP-CNN 方法的评价指标均低于三种单一方法的评价指标，其中，相比于 ARIMA 方法，ARIMA-BP-CNN 将 RMSE 降低了 65.9%，将 MAE 降低了 69.6%，将 MAPE 降低了 69.5%，预测精度取得了较大提升。

两两组合模型中，ARIMA-BP 方法的预测精度相对偏低，ARIMA-CNN 和 BP-CNN 的预测精度相对较高，但仍低于组合预测模型 ARIMA-BP-CNN 的预测精度。

综上所述，ARIMA-BP-CNN 组合预测模型的预测精度最高，优于三种单一预测方法。

4　结束语

针对电解铝企业的备件需求预测问题，构建了基于 ARIMA、BP 神经网络和深度学习 CNN-LSTM 神经网络三种方法的组合预测模型，解决了备件消耗的预测问题，充分发挥了 ARIMA 解决线性问题的能力和神经网络解决非线性问题的能力，摆脱了单一预测方法的弊端，通过电解铝企业天车某备件为实例，验证了该组合模型在备件需求预测中的可行性与精确性。

参考文献：

[1] 段军,郭颖.煤矿企业备件储备定额的研究[J].煤矿机械,2011,32(11):70-72.

[2] Weigend A S. Time series prediction: forecasting the future and understanding the past[M]. Routledge, 2018.

[3] Martin L ngkvist, Lars Karlsson, Amy Loutfi. A review of unsu pervised feature learning and deep learning for time-series modeling[J]. Pattern Recognition Letters,2014, 42: 11-24.

[4] Yadav R K , Balakrishnan M . Comparative evaluation of ARI MA and ANFIS for modeling of wireles s network traffic time series[J]. EURASIP Journal on Wireless Com munications and Networking, 2014, 2014(1):15.

[5] Wang Jin. A process level network traffic prediction algo rithm based on ARIMA model in smart substation[C].// IEEE Inter national Conference on Signal Processing. IEEE, 2013:1-5.

[6] 韩梅丽,李霖.基于 ARIMA 的不稳定需求备件预测模型研究[J].物流工程与管理,2016,38(02):48-50.

[7] 丁红卫,王文果,万良,等.基于 BP 神经网络的电网物资需求预测研究[J].计算机技术与发展,2019,29(06):138-142.

[8] 邓烜堃,万良,丁红卫,等.基于深度学习的交通流量预测研究[J].计算机工程与应用,2019,55(02):228-235.

[9] Ordó ez Francisco Javier, Roggen Daniel. Deep Convolu tional and LSTM Recurrent Neural Networks for Multi modal Wear able Activity Recognition.[J]. Sensors (Basel, Switzerland),2016,16(1): 115.

[10] 李梅,宁德军,郭佳程.基于注意力机制的 CNN-LSTM 模型及其应用[J].计算机工程与应用,2019(13):20-27.

[11] Yi Yang, Yanhua Chen, Yachen Wang, Caihong Li, Lian Li. Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short term electricity demand forecasting[J]. Applied Soft Computing,2016,49: 663-675.

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net