计算机科学 COMPUTER SCIENCE
http://www.jsjkx.com
DOI:10.11896/jsjkx.191000074

基于船舶自动识别系统与人工神经网络的船舶载重预测

王 鹏 苏 伟 张久文 刘映杰 王臻睿
兰州大学信息科学与工程学院 兰州 730030
(yiyao_keji@foxmail.com)

摘 要 传统的船舶载重获取方法多基于人工查表、经验计算和回归分析,这些方法操作麻烦,自动化水平较低,计算过程充斥着大量经验数值和统计公式,而一些统计公式和经验数值随着船型的变化已经过时,需要及时更新。目前,获取全球船舶动态载重是一项困难的工作。文中提出基于船舶自动识别系统和人工神经网络的船舶载重预测方法,该方法分析了船舶长度、宽度、吃水深度、船舶类型与船舶载重的数学关系,建立了 Adam-Dropout 优化的多层人工神经网络,确定了船舶载重预测的最佳输入组合;同时,还探究了该方法适用的船舶类型。实验结果表明,ANN 的输入为船舶长度、宽度、吃水深度、船舶类型时,预测效果最好,*MAPE* 误差为 7.63%,最小 *APE* 误差可达 0.05%;神经网络的隐含层数为 4、神经元个数为 11 时,预测结果最优;该方法适用于原油船、散货船、化学品船、集装箱船、液化天然气船、液化石油气船、成品油船、杂货船、冷冻船,预测 *MAPE* 误差均在 15%以内。

关键词:船舶载重;吃水深度;船舶自动识别系统;人工神经网络;平均绝对百分误差
中图法分类号 TP391

Prediction of Vessel Load Based on Vessel Automatic Identification System and Artificial Neural Network

WANG Peng,SU Wei,ZHANG Jiu-wen,LIU Ying-jie and WANG Zhen-rui
School of Information Science and Engineering,Lanzhou University,Lanzhou 730030,China

Abstract Traditional acquisition methods of vessel load are mostly based on manual observation,empirical calculation and regression analysis. These methods are usually difficult to operate,which may also have a low level of automation. On the other way,the calculation process is full of a large number of outdated empirical values and statistical formulas which sometimes need to be updated timely with the changes of vessel type. At present,it is a difficult task to obtain vessel's dynamic load all around the world. This paper presented a prediction method of vessel load based on vessel automatic identification system and artificial neural network,analyzed the mathematical relationship between vessel's length,breadth,draught,vessel types and vessel load,established a multi-layer artificial neural network with Adam-Dropout optimization,found out the best input types of artificial neural network and its suitable vessel types. Experiments show that the prediction result is the best when the inputs of ANN are length,breadth,draught and vessel type,the MAPE values of ANN can reach to 7.63% while the minimum APE value reaches to 0.05%. The prediction result is the best when the number of hidden layers is 4 and the number of neurons is 11. The method is suitable for crude oil tankers,bulk carriers,chemical tankers,container vessels,liquefied natural gas tankers,liquefied petroleum gas tankers,oil products tankers,grocery cargos and refrigeration vessels. The MAPE values of them are all less than 15%.

Keywords Vessel load,Draught,Vessel automatic identification system,Artificial neural network,Mean absolute percentage error

1 引言

船舶载重指船舶在不同工况下所载的货物、人员、行李、粮食、淡水、燃油等的总重量。目前,获取船舶载重的方法主要有 3 种[1-2]。1)水尺计重法:船员或港口管理人员通过读取船舶的六面水尺并结合《船舶载重与水尺对照表》等资料,得出船舶载重量。该方法需人工操作,操作麻烦且自动化程度较低。2)仪表测量法:利用超声波、压力、激光传感器或摄像头检测出船舶的当前吃水,然后用计算机分析出船舶载重。该方法具有一定的自动化能力,但只能实现本船载重的测量,未能实现全球船舶载重的同时获取。3)经验估算法:船员利用经验数值和公式估算本次航行装载的货物、人员、行李、燃油等的重量,然后累加得到船舶载重。该方法基于经验和繁琐的累加计算,过程中充斥着大量的经验数值,估算结果的误差一般较大。

2009,年 Gong 等[3]应用混合编码免疫辨识算法预测了船舶载重,并将该方法应用于灌装水泥运输船的载重预测;2010 年,丹麦学者 Kristensen[4]用回归分析的方法研究了不

本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。
基金项目:广西科技重大专项(桂科 AA17204096);广西科技基地和人才专项(桂科 AD16380076)
This work was supported by the Science Foundation of Guangxi (AA17204096,AD16380076).
通信作者:苏伟(suwei@lzu.edu.cn)

同类型的船舶的长度、宽度、吃水、船舶质量与最大载重量的关系；2017 年，Ren 等[5]用单层神经网络研究了内河货船的载重量与油耗、主机功率、航速之间的关系，并成功将其应用于船舶载重状态的识别；2017 年，Deng 等[6]研究了超大型集装箱船的长度、宽度与载重量的关系，并分析了集装箱个数与载重量的关系；2018 年，Gurgen 等[7]应用人工神经网络，以船舶最大载重量和设计航速作为输入，预测出了船舶的长度、宽度、吃水深度，结果表明神经网络能够很好地预测船舶的参数；2019 年，波兰学者 Cepowski[8]用回归分析的方法研究了全球 20 万艘船舶的 AIS 数据，建立了船舶的长度、宽度、吃水、船舶质量与载重量的回归公式。

本文提出了基于船舶自动识别系统和人工神经网络的船舶载重预测方法，它将为在岸基大数据平台上实现全球船舶载重监控提供一种高效的方法，同时该方法对全球货物监控、港口吞吐量预报都具有重要的参考价值。

2 船舶载重预测方法

本文提出的船舶载重预测方法可简述为用船舶特征预测船舶载重，如图 1 所示。

图 1 船舶载重预测方法示意图

Fig. 1 Schematic diagram of vessel load forecasting method

2.1 船舶自动识别系统

船舶自动识别系统(Automatic Identification System, AIS)是一种安装在船舶上，用于实时检测船舶位置、速度、航向等参数的设备。船舶 AIS 数据包括船名、呼号、MMSI、船舶类型、长度、宽度、吃水深度、船舶位置、航速、航向、转向率等。

2.2 船舶载重分析

船舶静止在水中(或船速较低)时，在水中处于任意浮态(正浮、横倾、纵倾)下的平衡方程为：

$$\begin{cases} M_{i,t}=\rho_{i,t}\cdot\nabla_{i,t} \\ X_B-X_G=(Z_B-Z_G)\tan\theta \\ Y_B-Y_G=(Z_B-Z_G)\tan\varphi \end{cases} \tag{1}$$

其中，$M_{i,t}$和$\nabla_{i,t}$分别为第 i 条船舶在 t 时刻的排水量(单位为 t)和排水体积(单位为 m^3)，$\rho_{i,t}$表示第 i 条船舶在 t 时刻所在海域的海水密度，(X_B,Y_B,Z_B)为浮心坐标，(X_G,Y_G,Z_G)为重心坐标，θ 为纵倾角，φ 为横倾角。

船舶正常航行时处于正浮状态，此时横倾角和纵倾角为 0。平衡方程化简为：

$$\begin{cases} M_{i,t}=\rho_{i,t}\cdot\nabla_{i,t} \\ X_B=X_G \\ Y_B=Y_G \end{cases} \tag{2}$$

船舶的排水体积$\nabla_{i,t}$由船舶的长度、宽度、吃水深度、船舶的外形结构(方形系数)、附体结构等决定，其计算公式为：

$$\nabla_{i,t}=\gamma_i\cdot C_{bi,t}\cdot L_i\cdot B_i\cdot T_{i,t} \tag{3}$$

其中，L_i 和 B_i 为船舶的长度和宽度(单位为 m)，$T_{i,t}$为船舶在 t 时刻的吃水深度(单位为 m)，γ_i 为附属体系数(与船舶附属体：船桨、球鼻艏等有关)，$C_{b,i}$为船舶的方形系数(与船体的肥瘦有关)。由式(2)和式(3)可得船舶当前排水量与船型参数的关系为：

$$M_{i,t}=\rho_{i,t}\cdot\gamma_i\cdot C_{b,i}\cdot L_i\cdot B_i\cdot T_{i,t} \tag{4}$$

由式(4)可以看出，不同工况下，船舶 i 的吃水深度 $T_{i,t}$与排水量 $M_{i,t}$一一对应。当船舶空载时，吃水深度 $T_{i,\min}$与排水量 $M_{i,\min}$的对应关系为：

$$M_{i,\min}=\rho_{i,t}\cdot\gamma_i\cdot C_{b,i}\cdot L_i\cdot B_i\cdot T_{i,\min} \tag{5}$$

船舶当前载重量 $\Delta M_{i,t}$等于当前总排水量与空载排水量的差，即：

$$\Delta M_{i,t}=M_{i,t}-M_{i,\min} \tag{6}$$

船舶空载时的吃水深度可写成船长的函数，国际海事组织给出的典型公式如式(7)所示[9]，该公式为统计公式；为了一般化，将船舶空载吃水公式转换为式(8)：

$$T_{i,\min}=0.02\cdot L_i+2.0 \tag{7}$$

$$T_{i,\min}=\alpha_i\cdot L_i+\beta_i \tag{8}$$

联立式(4)－式(6)、式(8)，可得船舶载重计算公式为：

$$\Delta M_{i,t}=\rho_{i,t}\gamma_i C_{b,i}L_iB_i(T_{i,t}-\alpha_iL_i-\beta_i) \tag{9}$$

由式(9)可以看出，船舶在 t 时刻的载重量与 t 时刻的海水密度、船舶长度、船舶宽度、吃水深度直接相关；而船舶的附属体系数 γ_i、方形系数 $C_{b,i}$，α_i 和 β_i 与船舶类型有关，即：

$$VesselType_i \xrightarrow{\text{间接影响}} (\gamma_i,C_{b,i},\alpha_i,\beta_i) \tag{10}$$

因此，船舶载重可表示为船舶长度、宽度、吃水深度、船舶类型的函数：

$$\Delta M_{i,t}=f(L_i,B_i,T_{i,t},VesselType_i) \tag{11}$$

2.3 人工神经网络和船舶载重预测模型

人工神经网络在多维复杂函数拟合和非线性映射方面具有较强的能力。本文将 Adam-Dropout[10]优化的多层人工神经网络作为训练网络，其结构如图 2 所示，由 1 个输入层、1 个输出层和多个隐含层组成。

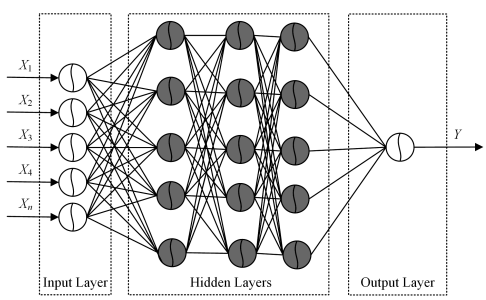

图 2 人工神经网络的结构

Fig. 2 Structure of artificial neural network

图 2 中，输入层的输入向量为船舶特征(长度、宽度、吃水深度、船舶类型)组成的 4 维向量$\vec{X}=(L_i,B_i,T_{i,t},VesselType_i)$，输出层的监督向量 Y 为船舶载重 $\Delta M_{i,t}$。隐含层由一层或多层网络组成，每层又包括若干个神经元。隐含层的神经元个数的经验公式为：

$$l=\sqrt{n+m}+c,c\in[0,10] \tag{12}$$

其中，l 为隐含层神经元个数，n 为输入向量的维数，m 为输出向量的维数，c 为 0～10 的一个常数。

用反向传播算法对模型进行训练，训练时输入向量$\vec{X}$先经过隐含层的神经元。根据式(13)，船舶特征与权重参数线 ω_{ij} 性叠加，经过激活函数 f 后产生隐含层的非线性输出 H_j。

$$H_j=f(\sum_{i=1}^{n}\omega_{ij}x_i-a_j),j=1,2,3,\cdots,m \tag{13}$$

信号层层传递，隐含层输出 H_j 经过全连接层，其权重为 ω_{jk}，偏置为 b_k，产生输出 O_k。

$$O_k=\sum_{j=1}^{l}H_j\omega_{jk}-b_k,k=1,2,3,\cdots,m \tag{14}$$

将预测输出 O_k 与监督向量 Y_k 进行比较，得出预测误差 e_k。通过梯度下降算法，用式(16)修改权重参数 ω_{ij} 和 ω_{jk}，用式(17)修改偏置参数 a_{ij} 和 b_k。

$$e_k=Y_k-O_k,k=1,2,3\cdots,m \tag{15}$$

$$\omega_{ij}=\omega_{jk}+\eta H_j(1-H_j)x_i\sum_{k=1}^{m}\omega_{jk}e_k \tag{16}$$

$$\omega_{jk}=\omega_{jk}+\eta H_j e_k$$

$$a_{ij}=a_{jk}+\eta H_j(1-H_j)\sum_{k=1}^{m}\omega_{jk}e_k \tag{17}$$

$$b_k=b_k+e_k$$

式(13)－式(17)中，e_k 为预测误差，η 为学习率，ω_{ij} 和 a_{ij} 为输入层和隐含层之间的权重和偏置参数，ω_{jk} 和 b_k 为隐含层和输出层之间的权重和偏置参数。

为了加快收敛速度并防止局部最优，采用 Adam 优化器对网络参数进行优化。Adam 优化器的优化策略如式(18)－式(20)所示：

$$\begin{aligned}m_t&=\beta_1 m_{t-1}+(1-\beta_1)g_t\\ v_t&=\beta_2 v_{t-1}+(1-\beta_2)g_t^2\end{aligned} \tag{18}$$

$$\begin{aligned}\hat{m}_t&=\frac{m_t}{1-\beta_1^t}\\ \hat{v}_t&=\frac{v_t}{1-\beta_2^t}\end{aligned} \tag{19}$$

$$W_{t+1}=W_t-\frac{\eta}{\sqrt{\hat{v}_t}+\varepsilon}\hat{m}_t \tag{20}$$

其中，m_t 和 v_t 为一阶动量项和二阶动量项，β_1 和 β_2 为动力值，$\hat{m}_t$ 和 $\hat{v}_t$ 为修正后的一阶动量项和二阶动量项，W_t 表示第 t 次迭代时神经网络的权重参数，ε 为一个很小的常数，一般取 $\varepsilon=1\times10^{-8}$。

为了防止网络过拟合，采用 Dropout 对神经网络中隐含层中的任意神经元的权重以概率 p 随机归零，从而实现神经网络的正则化，其公式为[10]：

$$p=(p_a=1|x)=\sum_{i,j\in B_a}\frac{\exp(w_{i,j}^{l}*x_j^{l-1}+b_i^l)}{(1+\exp w_{i,j}^{l}*x_j^{l-1}+b_i^l)} \tag{21}$$

其中，p_a 为样本 a 生成 1 的概率，B_a 为第 i 类神经元中属于样本 a 的数量，$w_{i,j}^{l}$ 和 b_i^l 为第 l 层的权重和偏置参数，x_j^{l-1} 为第 $l-1$ 层的第 j 个输入。

3　实验验证与分析

3.1　实验平台

计算机配置为：英特尔酷睿 i7 1.8GHz CPU，8GB 内存，Windows10 操作系统；编程语言为 Python3.5；集成开发环境为 PyCharm1.1；Keras 版本为 1.1.0。

3.2　实验数据及其相关性分析

实验数据来自航运在线网站[1)]上的 2018 年全球船舶数据库和美国 marinetraffic 网站[2)]上的实时 AIS 数据。数据包含 1920 年到 2019 年建造的 18127 艘船舶，原始数据的基本情况如表 1 所列。

表 1　实验数据的基本情况

Table 1　Basic information of experimental data

序号	数据项名称	最大值	最小值	平均值
1	船舶长度/m	477.00	17.00	161.97
2	船舶宽度/m	124.00	2.00	26.03
3	船舶类型(已编码)	10	1	4
4	建造时间/年	2019	1920	2004
5	最大吃水深度/m	29.70	1.08	9.19
6	船舶最大载重/ton	524272	789	37913.09
7	当前吃水深度/m	25.50	1.08	7.55

船舶长度、宽度、吃水深度、建造时间与船舶载重的关系分别如图 3 所示。

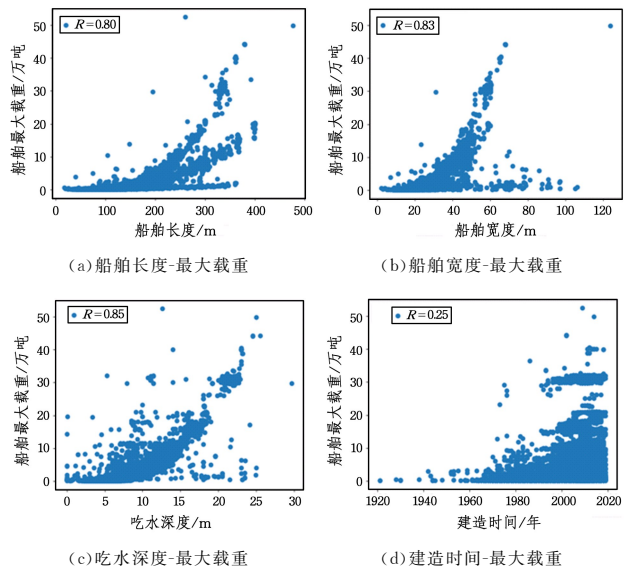

(a)船舶长度-最大载重　(b)船舶宽度-最大载重

(c)吃水深度-最大载重　(d)建造时间-最大载重

图 3　实验数据及其相关性

Fig. 3　Distribution and correlation of experimental data

对实验数据进行相关性分析，船舶长度、宽度、吃水深度与船舶载重呈强正相关(相关系数 $R\geqslant0.8$)。从图 3(d)可以看出，随着船舶建造时间变长，船舶的最大载重有变大的趋势，但其相关系数为 0.25。

3.3　实验内容

为了确定 ANN 在船舶最大载重和船舶动态载重预测上的有效性，本文设计了 4 个实验。

实验 1 对表 2 中 3 种不同的输入组合进行对比，确定船舶载重预测的最佳输入组合；实验 2 确定神经网络最佳的隐含层层数和神经元个数；实验 3 对不同类型的船舶的载重量分别进行预测，确定本文方法适用的船舶类型；实验 4 根据实验 1－实验 3 的结论，应用最佳的输入组合和最佳的模型参数预测船舶在任意吃水深度下的船舶载重的有效性。

3.4　实验步骤

第 1 步　数据预处理。将实时 AIS 数据和全球船舶数据库按 MMSI 号进行整合，根据船舶类型、长度、宽度、吃水深度对数据进行清洗，删除缺失数据和船舶长度小于 50 m 或大于 400 m 的船，对船舶类型进行 OneHot 编码，按

1) http://tool.sol.com.cn

2) www.marinetraffic.com

式(22)对数据进行归一化。

$$X_{scaler}=\frac{X-X_{min}}{X_{max}-X_{min}} \tag{22}$$

其中，X_{scaler}为 X 归一化后的数据，X_{max}和 X_{min}分别为样本的最大值和最小值。

第 2 步　建立模型。搭建 ANN，将输入设置为表 2 中的一种；隐含层为全连接神经网络，根据式(12)，隐含层神经元个数的设置范围为(3,13)，隐含层层数的设置范围为(1,50)。损失函数采用均方误差 MSE；激活函数采用 ReLu，其定义为：

$$f(x)=\max(0,x) \tag{23}$$

第 3 步　训练模型。将预处理后的数据按 7∶3 划分为训练集和测试集，随机初始化模型参数，利用反向传播算法进行训练。为了加快收敛速度并防止局部最优，在训练过程中使用自适应矩阵估计对模型参数进行优化。

第 4 步　参数优化。按照实验内容，选用不同的训练参数对模型进行训练，采用正则化惩罚项(Dropout)优化器对网络进行优化，防止模型过拟合。

第 5 步　模型预测。在训练好的模型中输入实时船舶自动识别系统数据，预测出对应的船舶载重，并与实际值做比较，用式(24)－式(27)评价预测精度。

3.5　评价指标

本文的实验评价指标为预测误差、均方根误差、绝对百分误差和平均绝对百分误差。预测误差的定义为：

$$y_e=y_i-\hat{y}_i \tag{24}$$

均方根误差的定义为：

$$RMSE=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i-\bar{y})^2} \tag{25}$$

绝对百分误差的定义为：

$$APE=\left|\frac{y_i-\hat{y}_i}{y_i}\right|\times 100\% \tag{26}$$

平均绝对百分误差的定义为：

$$MAPE=\frac{1}{N}\sum_{i=1}^{N}\left|\frac{y_i-\hat{y}_i}{y_i}\right|\times 100\% \tag{27}$$

式(24)－式(27)中，N 为样本数，y_i 和 $\hat{y}_i$ 分别为第 i 个样本点的真实值和预测值，$\bar{y}$为样本的平均值。

3.6　实验结果

实验 1　设置参数：隐含层层数为 4，隐含层神经元个数为 11；批数据大小为 20；迭代次数为 100～1000，步长为 100，对每个输入组合进行 10 次实验并进行独立比较。

选择前 9 种船舶类型，实验结果如表 2 所列。可以看出，在 3 种不同的输入组合中，当 ANN 的输入为“长度、宽度、吃水深度、船舶类型”时，预测效果最好，训练集 *MAPE* 误差为 6.99%，测试集 *MAPE* 误差为 7.63%。

表 2　不同输入组合下的船舶载重预测结果

Table 2　Prediction of vessel load with different Input combinations

输入组合	训练集		测试集	
	RMSE/t	*MAPE*/%	*RMSE*/t	*MAPE*/%
长度、吃水深度	8616.69	16.10	9530.08	14.61
长度、宽度、吃水深度	4789.57	10.00	6737.93	11.36
长度、宽度、吃水深度、船舶类型	3215.52	6.99	3381.49	7.63

随机抽取 300 个样本验证预测效果，船舶载重的预测值和真实值的比较结果如图 4 所示。从中可以看出，预测值与真实值大部分已经重合，最大 *APE* 误差为 38.32%，最小 *APE* 误差为 0.05%。

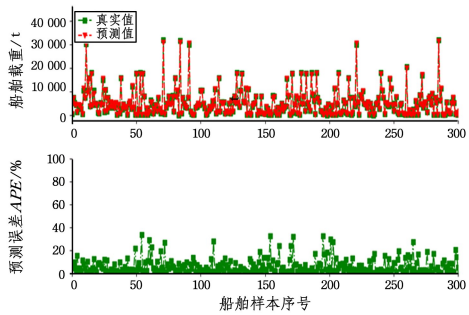

图 4　船舶载重预测值和真实值的比较

Fig. 4　Comparison of predicted values and real values

实验 2　设置参数：神经网络的训练次数为 100，隐含层层数为 1～50，隐含层神经元个数为 3～13。实验结果如图 5 所示，当隐含层层数为 4、隐含层神经元个数为 11 时，预测效果最好，预测 *RMSE* 误差最小，为 3525.66 t，*MAPE* 误差为 8.70%。

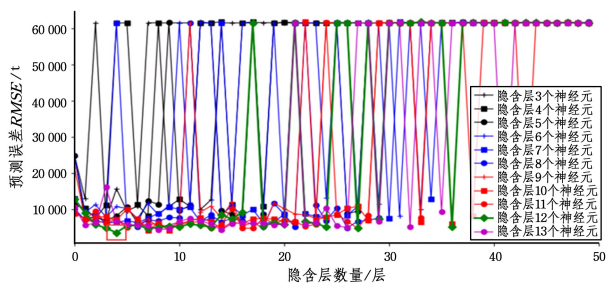

图 5　隐含层层数和神经元个数对预测的影响

Fig. 5　Influence of number of hidden layers and the number of neurons on prediction

实验 3　设置参数：隐含层层数为 4，隐含层神经元个数为 11，迭代次数的取值范围为(100,1000)，步长为 100，批数据大小为 20。实验数据按船舶类型进行分割后，对不同类型的船舶分别进行实验，实验结果如表 3 所列。

表 3　不同类型船舶的预测结果

Table 3　Prediction results of different types of vessel

船舶类型	数量/艘	训练集		测试集	
		RMSE/t	*MAPE*/%	*RMSE*/t	*MAPE*/%
原油船	1126	4150.43	1.88	6132.77	2.84
散货船	4283	2280.99	2.73	2793.77	4.79
化学品船	2431	1363.34	5.64	1637.97	4.91
集装箱船	2594	3316.01	5.64	17294.51	5.68
液化天然气船	170	5845.43	7.08	12202.10	8.12
液化石油气船	617	884.20	8.26	953.34	9.20
成品油船	1124	1473.43	9.67	2020.02	11.31
杂货船	3953	1086.82	11.77	3934.81	14.08
冷冻船	205	860.42	12.29	827.24	14.38
海上补给船	1624	550.89	32.81	771.80	34.78

从表 3 可以看出，本文方法对原油船、散货船、化学品船的预测效果较好，*MAPE* 误差在 5%以内；对集装箱船、液化天然气船、液化石油气船的预测 *MAPE* 误差为 5%～10%；对成品油船、杂货船、冷冻船的 *MAPE* 误差为 10%～15%；

对海上补给船的 *MAPE* 误差超过了 30%。随机抽取 50 个样本的 *APE* 误差，如图 6 所示。可以看出，除了海上补给船，本文方法对其余 9 种类型的船舶的 *APE* 误差均在 40%内，表明所提方法适用于对原油船、散货船、化学品船、集装箱船、液化天然气船、液化石油气船、成品油船、杂货船、冷冻船的载重量预测。

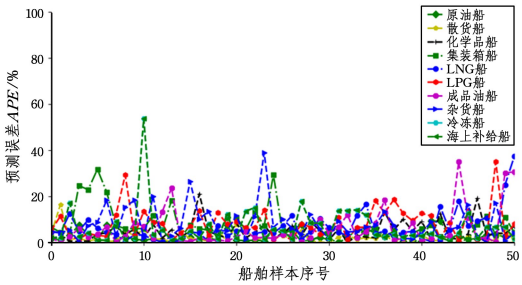

图 6　不同类型船舶的载重预测结果

Fig. 6　Load prediction results of different type of vessel

实验 4　由于无法获取全球每艘船舶在每一个吃水深度下的船舶重量，本文通过式(7)对实验数据进行扩充，即认为式(7)确定最小吃水深度，船舶载重量为 0 t，实验数据由 18127 扩充为 36254。

根据实验 1—实验 3 的结论，神经网络输入数据选用“船舶长度、宽度、吃水深度、船舶类型”，隐含层层数为 4，隐含层神经元个数为 11，预测的船舶类型选用原油船。

以某原油船(*MMSI*=353370000)为例，预测其在任意吃水深度下的船舶载重，输入的吃水深度的范围为 0～25 m，精度为 0.1 m，最大吃水深度为 22.29 m，预测效果如图 7 所示。

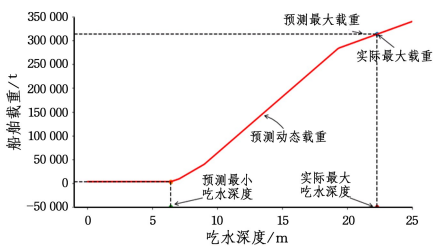

图 7　某原油船的动态载重量预测结果

Fig. 7　Dynamic load prediction result of crude oil vessel

从图 7 可以看出，在最大吃水深度 22.29 m 处，预测的船舶载重为 319226.44 t，与船舶资料中显示的该船的实际载重 313998 t 基本重合，*APE* 误差为 1.67%。

结束语　本文提出了基于船舶自动识别系统和人工神经网络的船舶载重预测方法，该方法比传统的获取船舶载重的方法简单高效，可用于全球任意船舶的实时载重量预测或全球港口吞吐量预测。本文的主要工作包括：

1)建立了船舶长度、宽度、吃水深度、船舶类型与船舶载重的数学关系，探究了 3 种不同输入组合对船舶载重预测结果的影响，得出当神经网络的输入为长度、宽度、吃水深度、船舶类型时，船舶载重预测效果最好，*MAPE* 误差为 7.63%，最小 *APE* 误差可达 0.05%；

2)确定了船舶载重预测模型中神经网络的最佳隐含层数为 4，隐含层神经元个数为 11；

3)确定了本文方法适用的船舶类型，比较了 10 种类型船舶的载重预测结果，得出原油船、散货船、化学品船、集装箱船、液化天然气船、液化石油气船、成品油船、杂货船、冷冻船的载重预测效果较好，*MAPE* 误差均小于 15%；

4)验证了船舶动态载重预测的有效性，以某原油船为例，用训练好的模型预测其在任意吃水深度下的动态载重，实验结果表明本文方法在任意吃水深度下的载重预测有效。

参 考 文 献

[1] ZHOU J H, YU X H, PENG K C. Research on the Single Floating Off-shore Ship Draft Detection System in Inland Navigation [J]. IOP Conference Series: Earth and Environmental Science, 2018, 170(2).

[2] ZHANG W, LI Y. Design of ship water gauge weighing system based on image processing [J]. Marine Engineering, 2019, 48(3): 175-178, 182.

[3] GONG G F, ZHANG J, HE Z H, et al. Application of Mixed Coding Immune Algorithms in Ship Load Measurement [J]. Control Theory and Application, 2009, 26(3): 349-352.

[4] KRISTENSEN H O. Determination of regression formulas for main dimensions of tankers and bulk carriers based on IHS fairplaydata[R]. Technical University of Denmark, 2010.

[5] REN J, ZHANG A, YAN L P, et al. Research on Recognition of Load State of Inland Vessels [J]. Instrument Technology, 2017(6): 38-40.

[6] DENG K, YUAN H L, YAN H M. Research on Design Method of Load Weight of Super Large Container Ship [J]. Ship and Ocean Engineering, 2018, 34(1): 43-48.

[7] GURGEN S, ALTIN I, OZKOK M. Prediction of main particulars of a chemical tanker at preliminary ship design using artificial neural network [J]. Ships and Offshore Structures, 2018, 13(5).

[8] CEPOWSKI T. Determination of regression formulas for main tanker dimensions at the preliminary design stage[J]. Ships and Offshore Structures, 2019, 14(3).

[9] MA X B, DAI R, SHOU Z Y, et al. Study on ballast draft value of bulk carrier based on AIS data [J]. Ship Science and Technology, 2017, 39(15): 51-54.

[10] YANG G C, YANG J, LI S B, et al. Improved CNN algorithm based on Dopout and ADAM optimizer [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(7): 122-127.

WANG Peng, born in 1990, postgraduate. His main research interests include machine learning and embedded system.

SU Wei, associate professor, Ph.D. His main research interests include deep learning, IoT technologies and natural language processing.