

文章编号:1671-1637(2018)02-0139-09

基于 ASAE 深度学习预测海洋气象 对船舶航速的影响

王胜正, 申心泉, 赵建森, 冀宝仙, 杨平安

(上海海事大学 商船学院, 上海 201306)

摘要:为了有效地预测海洋气象对船舶航速的影响,在稀疏自编码(SAE)网络模型的基础上提出交替稀疏自编码(ASAE)网络模型;构建了海洋气象对船舶航速影响的预测框架,利用关联规则方法对航行数据进行特征选择,挖掘了船速影响因素及其隐含关系;整合了中国远洋海运集团有限公司提供的船舶航行数据以及美国国家海洋和大气管理局提供的气象数据,用训练样本对 ASAE 网络模型进行训练,用测试样本对 ASAE 网络模型进行验证,并与支持向量回归(SVR)模型、反向传播神经网络(BPNN)模型、深度信念网络(DBN)模型及 SAE 网络模型的预测结果进行了对比。研究表明:ASAE 网络模型的训练时间和海洋气象对船舶航速影响预测值的均方根误差分别为 8.2 s 和 0.287 3 kn,与 SVR 模型、BPNN 模型、DBN 模型及 SAE 网络模型相比,训练时间分别缩短了 1 683.1、66.9、2.0、1.5 s,预测准确度分别提高了 0.045 5、0.296 9、0.153 4、0.178 6 kn;ASAE 网络模型的预测结果更符合实际海况,可动态掌握海洋气象对船舶航速的影响;通过预测的航速影响值来推算实际航速可为气象导航优化船舶运输过程起到辅助作用,在进行航线规划、航速推荐等航行优化策略时能准确考虑海洋气象所产生的复杂影响,从而改善船舶运营能效指标,实现节能、低碳、绿色航行的宗旨。

关键词:交通信息工程;智能航行;船舶航速;深度学习;交替稀疏自编码;关联规则;气象因子

中图分类号:U675.79

文献标志码:A

Prediction of marine meteorological effect on ship speed based on ASAE deep learning

WANG Sheng-zheng, SHEN Xin-quan, ZHAO Jian-sen, JI Bao-xian, YANG Ping-an

(Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China)

Abstract: In order to effectively predict the marine meteorological effect on ship speed, the alternating sparse auto-encoders (ASAE) network model based on the sparse auto-encoders (SAE) network model was proposed. A framework for predicting the marine meteorological effect on ship speed was constructed, and the association rules method was proposed to feature the navigation data, so as to excavate the factors and implicit relations affecting ship speed. Through the integration of ship navigation data provided by China COSCO Shipping Group and the meteorological data provided by the National Oceanic and Atmospheric Administration, ASAE network model was trained with training samples and verified with test samples, and the

收稿日期:2017-11-02

基金项目:国家自然科学基金项目(51709167, 61304230);上海市曙光人才计划(15SG44);上海海事大学研究生学术新人培育项目(YXR2016089)

作者简介:王胜正(1976-),男,湖南双峰人,上海海事大学教授,工学博士,从事船舶智能航行研究。

prediction result was compared to the results gained by support vector regression (SVR) model, back propagation neural network (BPNN) model, deep belief network (DBN) model and SAE network model. Research result shows that the training time and the mean squared error of marine meteorological effect on ship speed gained by ASAE network model are 8.2 s and 0.287 3 kn, respectively. Compared to SVR model, BPNN model, DBN model, and SAE network model, ASAE network model can shorten the training time by 1 683.1, 66.9, 2.0 and 1.5 s, respectively, and can increase the prediction accuracy by 0.045 5, 0.296 9, 0.153 4 and 0.178 6 kn. The forecast result of ASAE network model is more in line with actual sea condition, and can dynamically master the marine meteorological effect on ship speed. Estimating the actual speed through the predicted values can optimize the ship transportation process in meteorological navigation. It plays an auxiliary role to accurately consider the complex impacts of marine meteorological on navigation optimization strategies such as route planning and speed recommendation. Thereby, it improves the energy efficiency indicator of ship operation and achieves the purpose of energy saving, low-carbon and green navigation. 5 tabs, 6 figs, 23 refs.

Key words: traffic information engineering; intelligence voyage; ship speed; deep learning; alternating sparse auto-encoder; association rule; meteorological factor

Author resume: WANG Sheng-zheng(1976-), male, professor, PhD, szwang@shmtu.edu.cn.

0 引 言

海上交通运输中影响船舶航速的因素众多,如通航环境、通航秩序、海洋气象以及船舶操纵性能等^[1]。其中海洋气象是随机性最大的航速影响因素,在航行过程中,航速、主机输出功率与油耗在海洋气象影响下不断发生变化,因而掌握海洋气象对船舶航速的动态影响是有效控制船舶能耗的重要手段。分析海洋气象对船舶航速的影响具有重要意义,也是航行优化中至关重要的环节,通过对其优化可以实现远洋船舶节能、低碳、绿色航行的目标。

近年来,研究机构及学者们围绕节能、低碳、绿色航行进行了广泛研究^[2-3]。在航行优化方面:Sheng 等设计与利用一种有效的动态策略优化方法解决了班轮航速优化问题^[4];Kobayashi 等提出了考虑最小化油耗和船舶运营指标的航线优化技术,通过求解物理模型得到了优化航线^[5];Li 等聚焦于航线优化中风力辅助船舶航行技术研究,通过建立船舶运动方程,对分段航线进行了最低油耗优化^[6]。在节能运输方面:Lu 等提出一种半经验且具有可操作性的船舶节能运输方法,首先预测了船舶在不同水域、不同速度和不同遭遇角情况下的操纵性能,然后结合操纵性能的预测结果和实时气象信息,得到了最佳航行决策^[7]。利用机器学习的方法解决节能、低碳航行的研究也初露锋芒:Veneti 等提出使用进化算法改善实时气象导航效果,其目标是在考虑实时海

况、气象条件、船期限制的基础上最小化平均总风险和油耗^[8];Shi 等利用基于果蝇优化算法改进的支持向量回归机建立了一个经济航行预测模型,模型能根据外部多变量对远洋航行的影响,准确地预测经济航行的螺旋桨螺距^[9];Li 等通过分析船舶碳排放与航速之间的关系,建立了船东效益和航速之间的关系模型,获取了整体利益最大化的最优航速^[10];Li 等在考虑船舶载重和港口需求量双重约束条件的基础上,建立了基于禁忌搜索算法的航线优化模型^[11]。上述方法分别针对某些特定条件下的船舶航行优化起到了一定的成效,但是由于影响其安全与能效的因素众多且复杂,依然缺少可靠而准确的算法来预测海洋气象对船舶航速的影响。

通过对中国远洋海运集团有限公司近 1 年的跨洋航行数据与气象数据进行统计分析可以发现,有效改善船舶能效的最重要环节是控制不同气象条件下的船舶航速,但是由于数据量大,隐含关系较多,无法用通用统计学手段来挖掘这些数据内部的知识与模式,因此,较难准确预测海洋气象对船舶航速的影响,即航速损失。以往预测海洋气象对船舶航速影响的手段大多依然靠传统经验或数值计算,如利用计算流体力学方法分析船舶阻力,进而计算气象与海况对船舶航速的影响^[12]。该方法可以得到较高精度的预测结果,但是流体力学物理建模计算复杂,一般只能用于船舶设计,无法在线计算气象与海况对船舶航速的影响。深度学习的飞速发展使其在

预测领域取得了较好成果^[13-17],为预测海洋气象对船舶航速的影响提供了新思路。为了解决传统方法存在的弊端,采用交替稀疏自编码(Alternating Sparse Auto-Encoders, ASAE)网络模型来改善深度学习中普遍存在的梯度弥散问题,并通过构建海洋气象对船舶航速影响的预测框架来实现海洋气象对船舶航速影响的准确预测。

1 交替稀疏自编码

随着数据量的激增,浅层的人工神经网络已不能满足人们的需求,由多层非线性映射层组成的深度网络结构比浅层网络结构更有效^[18]。深层神经网络的优势在于不仅能表达更大更高维的数据集合,而且训练方式更加紧凑简洁。稀疏自编码(Sparse Auto-Encoders, SAE)网络模型^[19]是最常用的深度学习方法之一,通常深度学习利用逐层贪婪法^[20]训练整个网络。首先用无监督学习^[21]方法自下而上预训练每层网络,每次只训练 1 层;然后将

训练结果作为下一层训练的输入;最后将无监督学习到的参数进行权重迁移,再利用有监督学习方法自上而下调整所有层参数。SAE 网络模型利用自编码器的网络结构进行无监督学习,其训练流程见图 1,其中: x_{im} 为第 $i(i=1,2,\dots,n)$ 个样本的第 m 个属性,即输入神经元; $h_{l,j}$ 为第 l 层的第 $j(j=1,2,\dots,s_l)$ 个神经元输入,表示前一层神经元加权后的激活值, s_l 为第 $l(l=k-1,k-2,\dots,2)$ 层的神经元总数, k 为网络总层数; a_m 为训练隐藏层 1 的第 m 个神经元输出,它是对本次训练输入的重构; c_{s_1} 为训练隐藏层 2 的第 s_1 个神经元输出,它是对本次训练输入的重构; \hat{y}_i 为第 i 个样本的预测输出,是前一层神经元加权后的激活值。模型训练时首先以 a_m 近似于 x_{im} 为目标逐层调优,将优化后的隐藏层 1 作为下一层训练的输入层;然后以 c_{s_1} 近似于 h_{1,s_1} 为目标逐层调优,以此类推逐层贪婪训练所有隐藏层,并依次堆叠构成 SAE 网络模型;最终以 \hat{y}_i 近似于 y_i (第 i 个样本的实际输出)为目标逐层调优,完成模型训练。

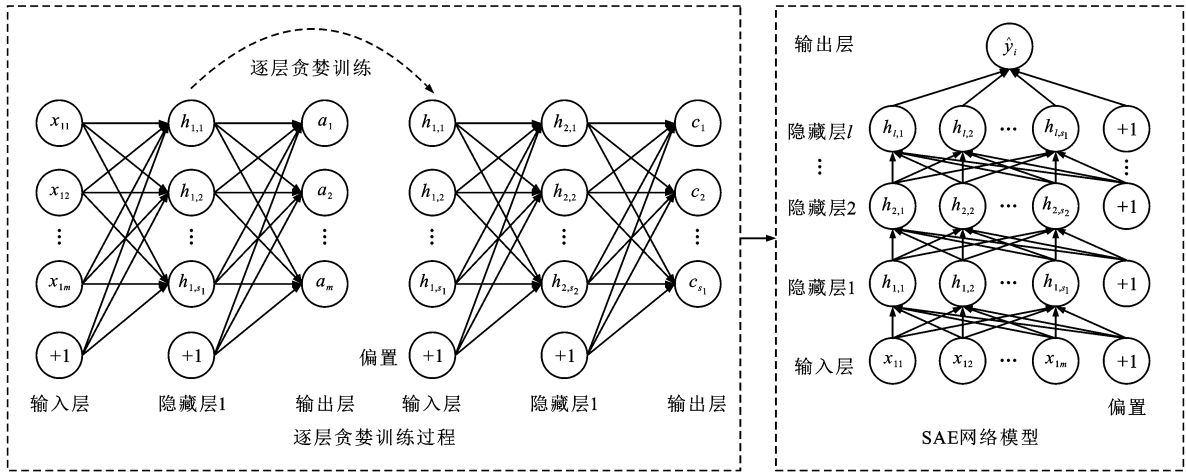


图 1 SAE 网络模型训练过程

Fig. 1 Training process of SAE network model

SAE 网络模型在目标函数中引入了稀疏性限制,使得隐藏层神经元过多时深层网络仍能发现输入数据中的有趣结构,这一限制令隐藏层的神经元有选择地被激活,且在大部分时间都是被抑制的。假设共有 n 个样本, $\hat{\rho}_j$ 为隐藏层神经元 j 的平均活跃度,则

$$\hat{\rho}_j = \frac{1}{m} \sum_{m=1}^m h_{l,j} x_{im} \quad (1)$$

此时可用相对熵惩罚因子即 KL 散度 $K(\rho, \hat{\rho}_j)$ ^[22] 作为模型的稀疏性约束,即

$$\sum_{j=1}^{s_l} K(\rho, \hat{\rho}_j) = \sum_{j=1}^{s_l} \rho \log_2 (\rho / \hat{\rho}_j) +$$

$$(1 - \rho) \log_2 \left(\frac{1 - \rho}{1 - \hat{\rho}_j} \right) \quad (2)$$

式中: ρ 为稀疏性参数。

相对熵惩罚因子随 $\hat{\rho}_j$ 与 ρ 之间差异的增大而增大,通常将 ρ 设置为一个接近于 0 的值,则 SAE 网络的目标函数 L_s 为

$$\min L_s = \frac{1}{2n} \sum_{i=1}^n |\hat{y}_i - y_i|^2 + \beta \sum_{j=1}^{s_l} K(\rho, \hat{\rho}_j) \quad (3)$$

式中: β 为稀疏性惩罚因子。

式(4)表示该模型既要使输出累积误差最小化,又要保证训练得到的参数满足稀疏约束,最后利用误差反向传播算法自上而下调优所有参数。

深度学习能够自动学习出高层次抽象意义的特征来解决复杂的机器学习问题。然而随着隐藏层数的增多,自上而下反向传播的梯度幅值会急剧减小,使得最初几层不能从样本中进行有效学习,这种问题通常称为梯度弥散,因此,一般的深层网络仍不能完全反映出抽象特征学习的优势。为了解决此问题,使 SAE 网络的底层也能进行完全学习,提出采用 ASAE 网络模型来进行优化。ASAE 网络模型的训练过程为:在每个隐藏层的预训练过程中,先进行自编码器的无监督学习,训练出隐藏层参数,再对训练后的隐藏层进行有监督学习(参数调优),实现逐层贪婪训练;将调优后的本隐藏层输出作为下一隐藏层的输入,每当增加一个新的隐藏层,就交替执行一次无监督学习和一次有监督学习;将优化后的隐藏层依次堆叠构建 ASAE 网络模型,在最顶层使用反向传播神经网络(Back Propagation Neural Network, BPNN)并对所有层进行参数调优。由于训练隐藏层时进行了有监督学习,并根据预测值与实际值的误差进行了反向传播参数调优,使得模型对底层参数实现了有效学习。

假设训练一个包含 n 个样本的数据集为 $D = \{x_i \in \mathbf{R}^m, y_i \in \mathbf{R} \mid (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ (\mathbf{R}^m 、 \mathbf{R} 分别为 m 维和一维实数集), $x_i = (x_{i1}, x_{i2}, \dots, x_{im})^T$, 为第 i 个样本的输入向量,则输入矩阵为 $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_n]^T$, 实际输出向量为 $\mathbf{y} = (y_1, y_2, \dots, y_n)^T$, 预测输出向量为 $\hat{\mathbf{y}} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n)^T$, 则第 l 层的权重矩阵 \mathbf{W}_l 为

$$\mathbf{W}_l = \begin{bmatrix} W_{l,11} & \dots & W_{l,1s_{l-1}} \\ \vdots & & \vdots \\ W_{l,s_l1} & \dots & W_{l,s_ls_{l-1}} \end{bmatrix} \quad (4)$$

式中: $W_{l,Ij}$ 为第 $l-1$ 层第 j 个神经元与第 l 层第 I ($I=1, 2, \dots, s_l$) 个神经元之间的权重。

设 $b_{l,j}$ 为第 l 层第 j 个神经元的偏置,则 $h_{l,j}$ 为

$$h_{l,j} = f(W_l X + b_{l,j}) = f(z_{l,j}) \quad (5)$$

式中: $z_{l,j}$ 为第 l 层第 j 个神经元的输入加权和; $f(\cdot)$ 为利用激活函数对输入加权和进行非线性映射。

参数过多会导致模型复杂度上升,产生过拟合现象,可通过增加 L2 范数使每个权重参数值接近 0 来改善,则 ASAE 网络模型的目标函数 L_A 为

$$\min L_A = L_S + \frac{\lambda}{2} \sum_{l=1}^{k-1} \sum_{j=1}^{s_{l-1}} \sum_{I=1}^{s_l} W_{l,Ij}^2 \quad (6)$$

式中: λ 为权重惩罚因子。

根据预测输出误差进行参数调优时,可先利用

式(7)计算输出层的残差向量 δ_k ,然后利用式(8)自上而下计算各隐藏层的残差向量 δ_l

$$\delta_k = \left[\hat{\mathbf{y}} - \mathbf{y} - \frac{\beta \rho}{\hat{\rho}} + \frac{\beta(1-\rho)}{1-\hat{\rho}} \right] f'(\mathbf{z}_k) \quad (7)$$

$$\delta_l = \left[\mathbf{W}_l^T \delta_{l+1} - \frac{\beta \rho}{\hat{\rho}} + \frac{\beta(1-\rho)}{1-\hat{\rho}} \right] f'(\mathbf{z}_l) \quad (8)$$

$$\hat{\rho} = (\hat{\rho}_1, \hat{\rho}_2, \dots, \hat{\rho}_{s_l})^T \quad (9)$$

$$\mathbf{z}_k = (z_{k,1}, z_{k,2}, \dots, z_{k,s_l})^T \quad (10)$$

$$\mathbf{z}_l = (z_{l,1}, z_{l,2}, \dots, z_{l,s_l})^T \quad (11)$$

式中: $\hat{\rho}$ 为隐藏层神经元的平均活跃度向量; \mathbf{z}_k 、 \mathbf{z}_l 分别为输出层、第 l 层的输入加权和向量; $z_{k,j}$ 为输出层第 j 个神经元的输入加权和。

然后根据式(12)、(13)进行参数更新,即

$$\mathbf{W}_l \leftarrow \mathbf{W}_l - \frac{\partial L_A}{\partial \mathbf{W}_l} = \mathbf{W}_l - \frac{\eta}{s_l} (\delta_{l+1} \mathbf{h}_l + \lambda \mathbf{W}_l) \quad (12)$$

$$\mathbf{b}_l \leftarrow \mathbf{b}_l - \frac{\partial L_A}{\partial \mathbf{b}_l} = \mathbf{b}_l - \frac{\eta}{s_l} \delta_{l+1} \quad (13)$$

$$\mathbf{b}_l = (b_{l,1}, b_{l,2}, \dots, b_{l,s_l})^T \quad (14)$$

$$\mathbf{h}_l = (h_{l,1}, h_{l,2}, \dots, h_{l,s_l})^T \quad (15)$$

式中: \mathbf{h}_l 为第 l 层的神经元输出向量; \mathbf{b}_l 为第 l 层的神经元偏置向量; η 为学习率。

将更新后的参数作为下一层 ASAE 网络输入的初始权重,重复上述过程直到训练完所有的隐藏层。ASAE 网络模型优化后的参数会使预测输出达到最小的训练累积误差,其训练学习过程见图 2。

2 海洋气象对船舶航行影响预测

海洋气象是对船速影响最大的随机性因素,由于航行中各因素之间存在复杂的牵连关系,实际航速变化对油耗、航线、航行时间、航行成本等都有一定的影响。如在主机功率不变的条件下,恶劣的气象条件使实际航速变慢,则在整体航行上油耗增多,成本变大。在航线设计方面,需要根据实际航速确定航行位置,并根据当前位置的海洋气象条件做出相应的航线调整。气象因素导致的航行时间延长必将导致靠港时间的变化,航行成本的增加,因此,预测海洋气象对船舶航速影响的意义重大,根据预测出的航速影响值可以推算出对地航速,使气象导航软件更准确地优化船舶推荐航速、推荐航线等,实现效益最大化的经济节能航行。结合航行优化知识与 ASAE 网络模型,设计了海洋气象对船舶航速影响的预测框架,如图 3 所示。

测试样本的预测效果用累计百分数 Q 来衡量,当误差容许值 e ($e=0.1, 0.2, \dots, 1$) 越小且 Q 越大

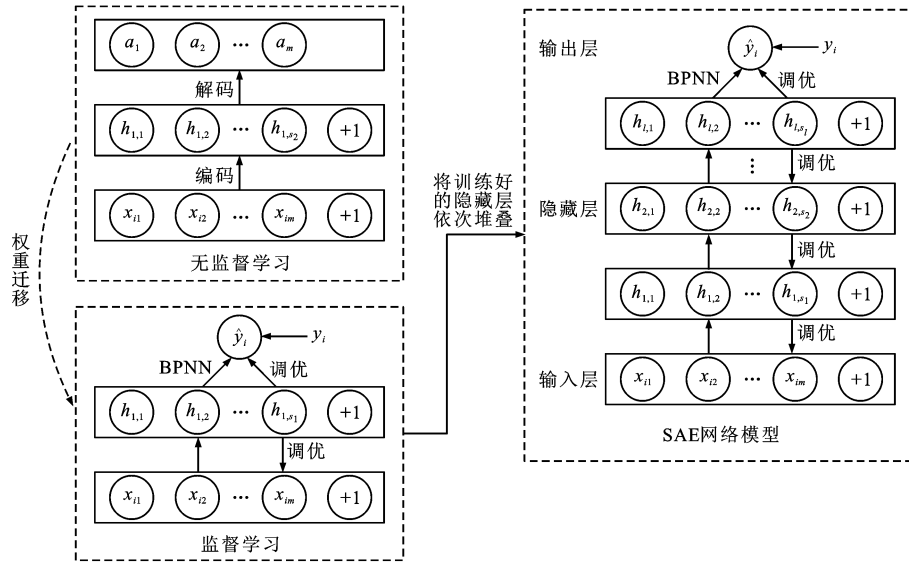


图 2 ASAE 网络模型训练过程

Fig. 2 Training process of ASAE network model

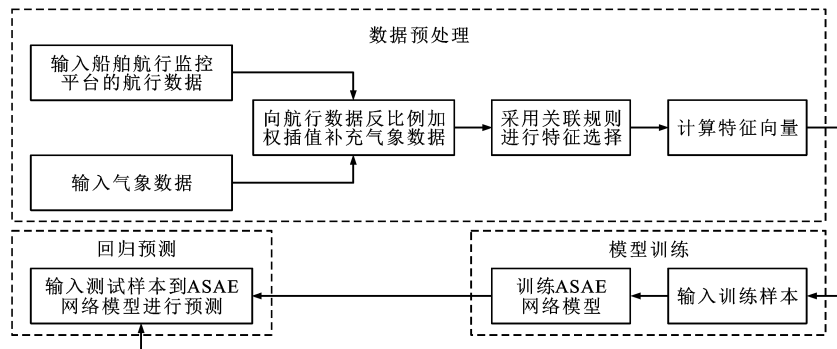


图 3 海洋气象对船舶航速影响预测框架

Fig. 3 Prediction framework of marine meteorological effect on ship speed

时说明预测效果越好,即

$$Q = \frac{q}{N} \quad (16)$$

式中: N 为测试样本数; q 为测试样本中预测误差小于 e 的样本数。

2.1 数据来源

试验数据来自 2 个部分,船舶航行数据由中远海运公司船舶航行监控平台提供的 2015 年 6 月到 2016 年 5 月的 73 艘集装箱船舶,共 486 航次 120 条航线的航行基本信息,这 486 航次都是跨洋航行,每个航次包含 76 个属性,共 7 000 条数据。表 1 为货船 COSCO ASIA 在 2015 年 8 月 5 日~17 日的部分航行信息。

气象数据源自美国国家海洋和大气管理局 (National Oceanic and Atmospheric Administration, NOAA),采集时间与采集点非常密集,每小时可采集上千条不同经纬度的数据,其数据按时间递增、纬度

递减的顺序排列,从中挑选出对船舶航行产生影响的 10 个属性数据,分别为风向、风速、能见度、历史天气状况、当前天气状况、浪周期、浪高、涌向、涌周期、涌高。表 2 为 2015 年 8 月 5 日 19:00、20:00 的部分气象数据,其中天气状况编码取值为 0、1、...、9,0 为云量覆盖天空的 1/2 或更少,1 为一部分时间云量覆盖超过 1/2 的天空,其他时间云量覆盖天空的 1/2 或更少,2 为云量覆盖超过 1/2 的天空,3 为沙尘暴或吹雪,4 为雾或冰雾或浓雾,5 为小雨,6 为雨,7 为雪或雨夹雪,8 为阵雨,9 为带雨或不带雨的雷暴。

利用 NOAA 提供的历史实时气象数据,对第 1 部分数据按照时间和经纬度联合搜索的方法确定插值域,根据反比例加权插值算法逐条补充航行数据中缺少的气象数据。插值完成后,将得到的包含气象信息的航行数据作为原始训练数据,每条船舶的原始训练数据有 86 个属性,部分训练数据见表 3。

表 1 货船 COSCO ASIA 的部分航行数据
Tab. 1 Part of voyage data of freighter COSCO ASIA

记录时间	纬度	经度	起始港	到达港	每天航行距离/n mile
2015-08-05 19:00	48°31'N	129°02'W	西雅图	釜山	301
2015-08-06 20:00	50°04'N	137°37'W	西雅图	釜山	360
2015-08-07 21:00	52°15'N	146°38'W	西雅图	釜山	366
2015-08-08 21:00	53°42'N	156°33'W	西雅图	釜山	368
2015-08-09 22:00	54°27'N	166°26'W	西雅图	釜山	351
2015-08-10 23:00	54°29'N	177°16'W	西雅图	釜山	379
2015-08-12 00:00	53°33'N	172°16'E	西雅图	釜山	373
2015-08-13 00:00	51°53'N	163°00'E	西雅图	釜山	353
2015-08-14 01:00	50°07'N	154°17'E	西雅图	釜山	369
2015-08-15 02:00	46°58'N	146°00'E	西雅图	釜山	378
2015-08-16 02:00	43°59'N	138°57'E	西雅图	釜山	357
2015-08-17 03:00	39°26'N	133°51'E	西雅图	釜山	356

表 2 NOAA 部分气象数据
Tab. 2 Part of meteorological data of NOAA

时间	纬度	经度	风向/(°)	风速/(m·s ⁻¹)	能见度/km	当天天气状况	浪向/(°)	浪周期/s	浪高/m
19:00	48°36'N	192°02'W	180	6.0	20	2	0	0	0.0
19:00	48°36'N	138°30'W	110	16.5	10	0	0	11	1.5
19:00	48°30'N	192°02'W	260	5.1	10	0	29	0	1.5
19:00	48°30'N	138°30'W	300	6.0	20	0	5	4	0.0
19:00	48°24'N	192°02'W	270	2.0	4	0	14	4	1.5
19:00	48°24'N	138°30'W	270	6.2	10	0	14	4	1.5
20:00	48°36'N	192°02'W	240	2.0	20	4	14	4	1.5
20:00	48°36'N	138°30'W	300	5.0	20	0	14	4	1.5
20:00	48°30'N	192°02'W	280	4.1	10	0	3	8	1.5

表 3 部分原始训练数据
Tab. 3 Part of original training data

记录时间	纬度	经度	船长/m	船宽/m	船舶向/(°)	风向/(°)	风速/(m·s ⁻¹)	能见度/km
2015-08-05 19:00	48°31'N	129°02'W	337.2	45.6	280.9	283	4.1	10.0
2015-08-06 20:00	50°04'N	137°37'W	337.2	45.6	285.4	231	5.6	10.0
2015-08-07 21:00	52°15'N	146°38'W	337.2	45.6	291.1	164	4.8	10.0
2015-08-08 21:00	53°42'N	156°33'W	337.2	45.6	283.6	232	8.0	2.0
2015-08-09 22:00	54°27'N	166°26'W	337.2	45.6	277.4	215	7.9	10.0
2015-08-10 23:00	54°29'N	177°16'W	337.2	45.6	270.3	265	6.5	4.0
2015-08-12 00:00	53°33'N	172°16'E	337.2	45.6	261.4	170	7.1	4.0
2015-08-13 00:00	51°53'N	163°00'E	337.2	45.6	253.5	222	4.3	0.5
2015-08-14 01:00	50°07'N	154°17'E	337.2	45.6	222.8	34	8.2	2.0
2015-08-15 02:00	46°58'N	146°00'E	337.2	45.6	252.2	90	5.1	1.0
2015-08-16 02:00	43°59'N	138°57'E	337.2	45.6	239.0	90	5.1	10.0
2015-08-17 03:00	39°26'N	133°51'E	337.2	45.6	240.2	100	8.7	20.0

2.2 关联规则进行特征选择

原始训练数据包含 86 个属性,其中包含许多对船舶航速影响不大甚至无影响的冗余属性,因此,有必要对原始训练数据进行筛选,剔除与目标数据无关的、负相关的属性数据,从而提升预测准确度。关联规则^[23]是一种有效发现相关数据的方法,能够挖掘出数据之间的因果关系,因此,采用关联规则的方法对原始数据进行特征选择,剔除与气象因素无关的、负相关的数据。对于形如 $A \rightarrow B$ 的规则(A 为先导, B 为后继),令规则频度 $S = P(A \cap B)$,称为支持度,令强度 $C = P(B|A)$,称为置信度。通常由经验设定最小支持度 S_{\min} 和最小置信度 C_{\min} ,所有满足 $S > S_{\min}$ 的项目集称为频繁项集,满足 $C > C_{\min}$ 的规则集称为强关联规则。为了提高剔除无用规则的速度,引入相关度 R 和杰卡德系数 J 来约束规则的产生,即

$$R = \frac{C}{P(B)} = \frac{S}{P(A)P(B)} \quad (17)$$

$$J = \frac{S}{P(A \cup B)} \quad (18)$$

关联规则的挖掘过程为:根据支持度挖掘出最大频繁项集;根据置信度、相关度和杰卡德系数从频繁项集中发现强关联规则。

2.3 计算特征向量

由于筛选出的特征数据测量单位不同,表征不同的实际意义,因此,受量纲的影响使得各个特征之间的数值差异较大,如吃水与离港载重的数值间可能有上万的差距,这会影响数据分析结果。而神经网络回归预测的本质是学习数据分布,所以需要对数据进行归一化处理。由于特征数据内部具有变化幅度小的特点,为了提高数据归一化后的差异性,采用离差标准化方法,即

$$t^* = \frac{255(t - t_{\min})}{t_{\max} - t_{\min}} \quad (19)$$

式中: t 为属性实际值; t_{\max} 为属性最大值; t_{\min} 为属性最小值; t^* 为属性归一化值。

将每个特征都划分为 256 个等级,即归一化后特征向量的取值范围为 $[0, 255]$,同时为了提高模型训练速度,将每个属性分级后的归一化值四舍五入转化为八位二进制的特征向量,形成稀疏矩阵。取值范围为 $[8.1, 15.8]$ 的吃水的归一化值和特征向量见表 4。

2.4 船舶航速影响预测

为了预测海洋气象对船舶航速的影响,将预处理后的特征向量按一定比例随机划分为训练样本和

表 4 不同吃水的归一化值和特征向量

Tab. 4 Eigenvectors and normalized values of different drafts

吃水/m	归一化值	特征向量
13.5	179	(1,0,1,1,0,0,1,1)
9.3	40	(0,0,1,0,1,0,0,0)
11.9	126	(0,1,1,1,1,1,1,0)
13.7	185	(1,0,1,1,1,0,0,1)
10.8	89	(0,1,0,1,1,0,0,1)

测试样本,通常训练样本的数据量远大于测试样本。将训练样本输入到 ASAE 网络中进行参数学习,得到各隐藏层的权重矩阵 W_i 和偏置向量 b_i ,然后将测试样本输入训练后的 ASAE 网络中,自下而上逐层计算输出值,预测出海洋气象对船舶航速影响的归一化值,并对其反归一化即可得到海洋气象对船舶航速的实际影响值。

3 试验结果分析

对完整航行数据集的 86 个属性进行关联规则分析,气象因素对船舶航速的影响值称为气象因子,设最小支持度为 0.1,最小置信度为 0.5,相关度大于 1.0,杰卡德系数大于 0.4,挖掘出按照支持度降序排列且后继为气象因子的规则有 15 条,衡量规则强度的支持度、置信度、相关度、杰卡德系数见图 4。

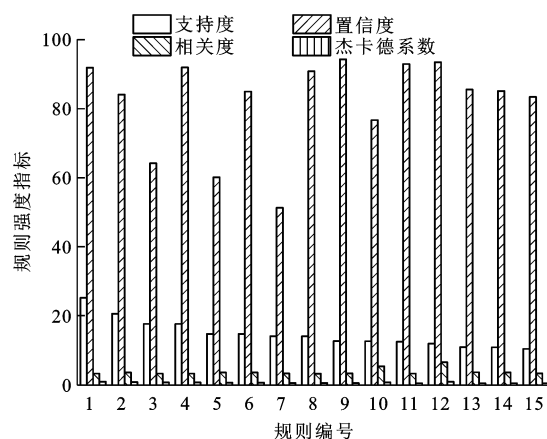


图 4 规则强度指标

Fig. 4 Rule strength indicators

后继为气象因子的部分规则筛选后得到 21 个属性,分别为船长、船宽、船艏向、吃水、纵倾角、离港载重、主机转速、最大持续功率、对地航速、总油耗、风级、风向、风速、能见度、当前天气状况、历史天气状况、浪周期、浪高、涌向、涌周期、涌高。

为了验证 ASAE 网络模型的有效性,对预处理后包含 21 个属性的 7 000 条航行数据按训练样本 90%、测试样本 10% 进行划分,用同样的数据对支持

向量回归 (Support Vector Regression, SVR) 模型、BPNN 模型、深度信念网络 (Deep Belief Networks, DBN) 模型及 SAE 网络模型进行回归预测, 后 3 个模型与 ASAE 网络层数和每层神经元数的设置相同。试验输入层神经元数为 168, 输出层神经元数为 1。模型选择较简单的 3 个隐藏层的网络结构, 隐藏层神经元数分别为 200、200、144, 每层神经元数的适度变化对结果没有显著影响, 学习率 η 设置为 0.10, 稀疏性惩罚因子 β 设置为 0.05, 权重惩罚因子 λ 设置为 0.10。

试验结果见图 5, 可知: 当 e 取值为 0.1 时, SVR 模型、BPNN 模型、DBN 模型、SAE 网络模型、ASAE 网络模型的累计百分数分别为 13.927 5%、4.735 3%、9.470 7%、12.813 3%、21.727 1%; 海洋气象对船舶航速影响预测效果最好的是 ASAE 网络模型, 最差的是 BPNN 模型; 从整体的变化趋势来看, 海洋气象对船舶航速影响的预测效果从好到差依次为 ASAE 网络模型、SAE 网络模型、SVR 模型、DBN 模型、BPNN 模型。

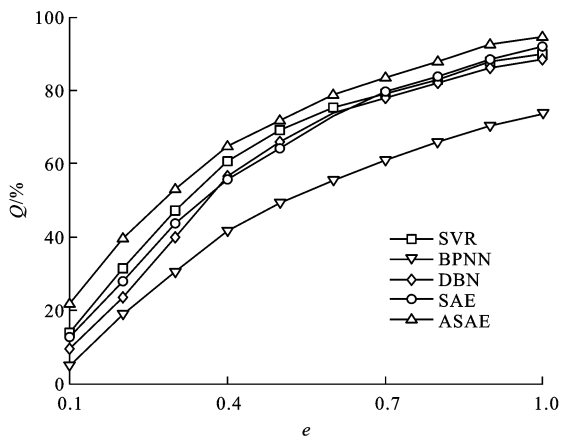


图 5 预测结果的累计百分数

Fig. 5 Accumulated percentages of predicted results

对于深度学习普遍存在的梯度弥散问题, 将 ASAE 网络模型与 SAE 网络模型进行对比, 其损失函数的变化趋势见图 6, 可知: ASAE 网络模型和 SAE 网络模型收敛时的迭代次数分别为 173、224, 即 ASAE 网络模型的收敛速度较快; ASAE 网络模型和 SAE 网络模型的最终损失函数值分别为 0.784 4、1.924 7, 即 ASAE 网络模型的训练效果优于 SAE 网络模型; 当训练迭代 300 次之后, ASAE 网络模型和 SAE 网络模型的振荡最大值分别为 0.245 5、0.302 2, 即 ASAE 网络模型的损失函数波动较小, 显著缓解了梯度弥散问题。

各个模型的预测性能见表 5, 可知: ASAE 网络

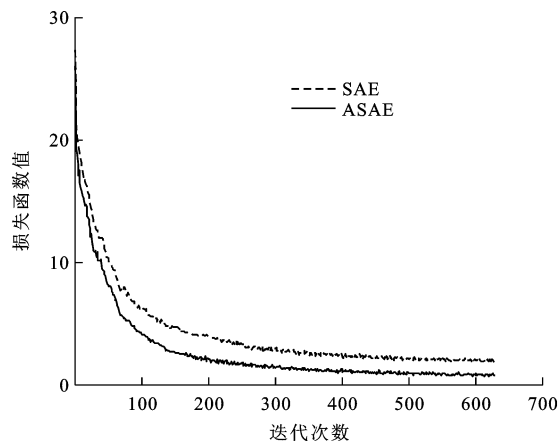


图 6 SAE 和 ASAE 损失函数

Fig. 6 Loss functions of SAE and ASAE

模型的训练时间为 8.2 s, 海洋气象对船舶航速影响预测值的均方根误差为 0.287 3 kn; 与 SVR 模型、BPNN 模型、DBN 模型及 SAE 网络模型相比, 训练时间分别缩短了 1 683.1、66.9、2.0、1.5 s, 海洋气象对船舶航速影响值的预测准确度分别提高了 0.045 5、0.296 9、0.153 4、0.178 6 kn。可见, ASAE 网络模型的预测性能良好, 预测结果符合实际海洋气象对船舶航速的影响, 可动态掌握海洋气象对船舶航速的影响。

表 5 各模型预测性能

Tab. 5 Prediction performances of each model

模型	训练时间/s	平均绝对误差/kn	均方根误差/kn
SVR	1 691.3	0.410 6	0.332 8
BPNN	75.1	0.585 3	0.584 2
DBN	10.2	0.495 5	0.440 7
SAE	9.7	0.478 2	0.465 9
ASAE	8.2	0.353 6	0.287 3

4 结 语

(1) 提出的 ASAE 网络模型具有最佳的训练时间及预测性能, 在训练调优过程中引入了相对熵惩罚因子和 L2 范数, 实现了网络训练的稀疏性限制且避免了过拟合, 有效提高了模型训练速度及预测准确度, 同时利用无监督和有监督交替训练, 使网络底层得到了完全学习, 缓解了参数更新中的梯度弥散问题。

(2) 结合航海领域中航行优化背景构建的预测框架, 预测了海洋气象因素对船舶航速的影响, 有效地将 ASAE 网络模型应用于航海领域, 通过航速影响值的准确预测来推算实际航速, 为航行优化策略提供了科学的数据支撑。

(3) ASAE 网络模型中网络参数的设置仍没有

科学性解释,目前参数设置中依靠经验的主观性干扰较大,应进一步对参数设置进行研究,以提高模型的预测性能。

参考文献:

References:

- [1] 孙健,王凤武,刘强,等.基于证据理论的船舶大风浪中航行的安全评价[J].大连海事大学学报,2013,39(1):53-56.
SUN Jian, WANG Feng-wu, LIU Qiang, et al. Safety assessment of ships navigating in heavy sea based on evidence theory[J]. Journal of Dalian Maritime University, 2013, 39(1): 53-56. (in Chinese)
- [2] 俞姗姗,汪传旭.不同碳排放调控政策下的船舶航速优化[J].大连海事大学学报,2015,41(3):45-50.
YU Shan-shan, WANG Chuan-xu. Speed optimization under different carbon emission control policy[J]. Journal of Dalian Maritime University, 2015, 41(3): 45-50. (in Chinese)
- [3] 孟晓东,袁章新.考虑不规则风浪影响的最小油耗航速模型[J].上海海事大学学报,2016,37(1):19-24.
MENG Xiao-dong, YUAN Zhang-xin. A minimum fuel consumption speed model considering effect of irregular wind and wave[J]. Journal of Shanghai Maritime University, 2016, 37(1): 19-24. (in Chinese)
- [4] SHENG X M, CHEW E P, LEE L H. (s, S) policy model for liner shipping refueling and sailing speed optimization problem[J]. Transportation Research Part E: Logistics and Transportation Review, 2015, 76: 76-92.
- [5] KOBAYASHI E, HASHIMOTO H, TANIGUCHI Y, et al. Advanced optimized weather routing for an ocean-going vessel[C]//IEEE. Proceedings of 2015 International Association of Institutes of Navigation World Congress. New York: IEEE, 2015: 1-8.
- [6] LI Yuan-kui, ZHANG Ying-jun, GAO Zong-jiang, et al. Optimal routing model for wind-assisted ship[C]//IEEE. Proceedings of 2013 International Conference on Mechatronic Sciences, Electric Engineering and Computer. New York: IEEE, 2013: 1567-1571.
- [7] LU R H, TURAN O, BOULOUGOURIS E, et al. A semi-empirical ship operational performance prediction model for voyage optimization towards energy efficient shipping[J]. Ocean Engineering, 2015, 110: 18-28.
- [8] VENETI A, KONSTANTOPOULOS C, PANTZIOU G. An evolutionary approach to multi-objective ship weather routing[C]//IEEE. Proceedings of the 6th International Conference on Information, Intelligence, Systems and Applications. New York: IEEE, 2015: 1-6.
- [9] SHI Bu-hai, GUO Xie-tao, ZHANG Ben. Research for economy shipping of oceangoing vessel based on the FOA-SVR[C]//IEEE. Proceedings of the 32nd Chinese Control Conference. New York: IEEE, 2013: 7563-7568.
- [10] LI Gang, XU Huan, LIU Wei. Option of operating speed for vessels under low-carbon economy[J]. Journal of Industrial Engineering and Management, 2013, 6(1): 289-296.
- [11] LI Xiao-ming, XIAO Jian-mei, WANG Xi-huai. Optimization of ship routing with tabu search algorithm[C]//IEEE. Proceedings of 2011 International Conference on Energy and Environment. New York: IEEE, 2011: 139-142.
- [12] CHEN Yuan-chao, WU Qi-rui, WANG Yu-cheng. A research on precise prediction method of high-speed craft resistance based on CFD[C]//IEEE. Proceedings of the 8th International Conference on Intelligent Computation Technology and Automation. New York: IEEE, 2015: 84-88.
- [13] YANG H F, DILLON T S, CHEN Y P P. Optimized structure of the traffic flow forecasting model with a deep learning approach[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10): 1-11.
- [14] GAN Shao-jun, LIANG Shan, LI Kang, et al. Long-term ship speed prediction for intelligent traffic signaling[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 18(1): 1-10.
- [15] SALMAN A G, KANIGORO B, HERYADI Y. Weather forecasting using deep learning techniques[C]//IEEE. Proceedings of 2015 International Conference on Advance Computer Science and Information Systems. New York: IEEE, 2015: 281-285.
- [16] KOESDWIADY A, SOUA R, KARRAY F. Improving traffic flow prediction with weather information in connected cars: a deep learning approach[J]. IEEE Transaction on Vehicular Technology, 2016, 65(12): 1-10.
- [17] HOSSAIN M, REKABDAR B, LOUIS S J, et al. Forecasting the weather of Nevada: a deep learning approach[C]//IEEE. Proceedings of 2015 International Joint Conference on Neural Networks. New York: IEEE, 2015: 1-6.
- [18] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-12.
- [19] JIANG Xiao-juan, ZHANG Yin-hua, ZHANG Wen-shen, et al. A novel sparse auto-encoder for deep unsupervised learning[C]//IEEE. Proceedings of 6th International Conference on Advanced Computational Intelligence. New York: IEEE, 2013: 256-261.
- [20] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks[J]. Advances in Neural Information Processing Systems, 2007, 19(3): 153-160.
- [21] FRIGUI H, NASRAOUI O. Unsupervised learning of prototypes and attribute weights[J]. Pattern Recognition, 2004, 37(3): 567-581.
- [22] KARANCE L, ERDEM A, ERDEM E. Image matting with KL-divergence based sparse sampling[C]//IEEE. Proceedings of 2015 IEEE International Conference on Computer Vision. New York: IEEE, 2015: 7-13.
- [23] CAI C H, FU A W C, CHENG C H, et al. Mining association rules with weighted items[C]//IEEE. International Symposium on Database Engineering and Applications. New York: IEEE, 1998: 1-10.